



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO

UENDER BARBOSA DE SOUZA

**APLICAÇÃO DA TRANSFORMADA DE
HILBERT-HUANG E DA SELEÇÃO PARA CONSISTENTE DE
CARACTERÍSTICAS NO CAMPO DA ENTOMOLOGIA
AGRÍCOLA: UMA ABORDAGEM PARA IDENTIFICAÇÃO E
ESTIMATIVA DE DENSIDADE DE CIGARRAS EM
LAVOURAS CAFEIEIRAS**

GOIÂNIA
2023



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

Dissertação Tese Outro*: _____

*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

Exemplos: Estudo de caso ou Revisão sistemática ou outros formatos.

2. Nome completo do autor

UENDER BARBOSA DE SOUZA

3. Título do trabalho

**“Aplicação da Transformada de Hilbert-Huang e da Seleção
Paraconsistente de Características no Campo da Entomologia Agrícola:
Uma Abordagem para Identificação e Estimativa de Densidade de Cigarras
em Lavouras Cafeeiras”**

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

a) consulta ao(a) autor(a) e ao(a) orientador(a);

b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.

O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;

- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Leonardo Da Cunha Brito, Professor do Magistério Superior**, em 06/12/2023, às 09:16, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Uender Barbosa De Souza, Discente**, em 06/12/2023, às 11:41, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4244373** e o código CRC **443B4E63**.

UENDER BARBOSA DE SOUZA

**APLICAÇÃO DA TRANSFORMADA DE
HILBERT-HUANG E DA SELEÇÃO PARA CONSISTENTE DE
CARACTERÍSTICAS NO CAMPO DA ENTOMOLOGIA
AGRÍCOLA: UMA ABORDAGEM PARA IDENTIFICAÇÃO E
ESTIMATIVA DE DENSIDADE DE CIGARRAS EM
LAVOURAS CAFEEIRAS**

Tese apresentada ao Programa de Pós-Graduação *Stricto Sensu* em Engenharia Elétrica e de Computação da Universidade Federal de Goiás, como requisito parcial para obtenção do Título de Doutor em Engenharia Elétrica e de Computação.

Área de Concentração: Engenharia de Computação.

Orientador: Prof. Dr. Leonardo da Cunha Brito.

CoOrientador: Prof. Dr. João Paulo Lemos Escola.

GOIÂNIA
2023

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Souza, Uender Barbosa de

Aplicação da Transformada de Hilbert-Huang e da Seleção Paraconsistente de Características no Campo da Entomologia Agrícola [manuscrito] : Uma Abordagem para Identificação e Estimativa de Densidade de Cigarras em Lavouras Cafeeiras / Uender Barbosa de Souza. - 2023.

CCLXXII, 272 f.: il.

Orientador: Prof. Dr. Leonardo da Cunha Brito; co-orientador Dr. João Paulo Lemos Escola.

Tese (Doutorado) - Universidade Federal de Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Goiânia, 2023.

Bibliografia.

Inclui siglas, símbolos, lista de figuras, lista de tabelas.

1. Processamento de Sinais. 2. Transformada de Hilbert-Huang. 3. Engenharia Paraconsistente de Características. 4. Aprendizado de Máquinas. 5. Manejo de Cigarras. I. Brito, Leonardo da Cunha, orient. II. Título.

CDU 62:61



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

ATA EMC Nº 09/2023

Ata Nº 09 da sessão de Defesa de Tese de **Uender Barbosa de Souza** que confere o título de Doutor em **Engenharia Elétrica e de Computação**, na área de concentração em **Engenharia de Computação**.

Ao **primeiro dia do mês de dezembro de dois mil e vinte e três**, a partir das 14h00min, realizou-se a sessão pública de Defesa de Tese intitulada “**Aplicação da Transformada de Hilbert-Huang e da Seleção Paraconsistente de Características no Campo da Entomologia Agrícola: Uma Abordagem para Identificação e Estimativa de Densidade de Cigarras em Lavouras Cafeeiras**”. Os trabalhos foram instalados pelo Orientador, Professor Doutor **Leonardo da Cunha Brito - (EMC/UFG)** com a participação dos demais membros da Banca Examinadora: Professor Doutor **Flávio Henrique Teles Vieira - (EMC/UFG)** Membro Titular Interno, Professor Doutor **Rodrigo Pinto Lemos - (EMC/UFG)** Membro Titular Interno, Professor Doutor **João Paulo Lemos Escola - (IFSP)** Membro Titular Externo e Professor Doutor **Douglas Henrique Bottura Maccagnan - (UEG)** Membro Titular Externo, cujas participações ocorreram através de videoconferência pelo link da videochamada: <https://meet.google.com/mri-kztr-ffi>. Durante a arguição os membros da banca **não fizeram** sugestão de alteração do título do **trabalho**. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Tese tendo sido o candidato **aprovado** pelos seus membros. Proclamados os resultados pelo Professor Doutor **Leonardo da Cunha Brito**, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, **Ao primeiro dia do mês de dezembro de dois mil e vinte e três**.



Documento assinado eletronicamente por **Rodrigo Pinto Lemos, Professor do Magistério Superior**, em 01/12/2023, às 17:22, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Flavio Henrique Teles Vieira, Professor do Magistério Superior**, em 01/12/2023, às 17:22, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leonardo Da Cunha Brito, Professor do Magistério Superior**, em 01/12/2023, às 17:23, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Douglas Henrique Bottura Maccagnan, Usuário Externo**, em 01/12/2023, às 17:29, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Uender Barbosa De Souza, Discente**, em 06/12/2023, às 16:50, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **João Paulo Lemos Escola, Usuário Externo**, em 07/12/2023, às 17:06, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4219512** e o código CRC **DB23A66B**.

*Este trabalho é dedicado às princesas da minha vida: minha esposa, Jéssica Luana, e
minha filha, Lara.*

Agradecimentos

O processo de desenvolvimento das ideias expressas nesta tese deve-se a um conjunto de fatores acumulados ao longo de minha vida acadêmica, que contaram com contribuições essenciais de diversas pessoas, às quais serei eternamente grato. Agradeço aos meus pais Sebastião e Maria e à minha irmã Lindiheyne pelo amor, carinho, educação e apoio que sempre me deram, os quais me conduziram. À minha amada esposa Jéssica Luana pelo constante apoio, incentivo e compreensão pelos momentos de ausência, nos quais estive me dedicando à produção deste trabalho. A todos os meus Professores que ao longo de minha vida escolar e acadêmica compartilharam seus conhecimentos, me inspiraram e me incentivaram a desenvolver minhas habilidades matemáticas. Acredito que isso foi um fator crucial para a escolha de minha profissão. Ao meu ex-aluno e agora colega de profissão, Renato Milhomem, que me apresentou a Transformada de Hilbert-Huang, parte essencial para o desenvolvimento desse trabalho. Aos Professores do PPG, em especial aos professores: Leonardo da Cunha Brito, meu orientador, pela oportunidade e confiança; Flávio Henrique Teles, que inspirou diversas das ideias presentes nos experimentos desta tese; Flávio Geraldo, que ministrou a disciplina Programação Linear que cursei como aluno especial e me recomendou através de uma carta enquanto pleiteei a vaga para o doutorado e Rodrigo Lemos, que ministrou a disciplina Processamento de Sinais II, oportunidade na qual produzimos um artigo científico que veio a ser publicado. Ao Professor Douglas Maccagnan, Doutor em Biologia e especialista em Entomologia e Bioacústica, amigo e parceiro de pesquisas. Sou grato por todas as contribuições e por ter me apresentado ao meu grande parceiro de pesquisas João Paulo Lemos Escola. Ao amigo, cientista e parceiro de pesquisas João Paulo Lemos Escola, que me ajudou imensamente nesta jornada, parceiro de muitas publicações. Ao Instituto Federal de Educação, Ciência e Tecnologia de Goiás, instituição da qual tenho orgulho de fazer parte. Sou grato pelo afastamento remunerado que me foi concedido durante o período que estive cursando o doutorado. À Universidade Federal de Goiás pelo ensino público, gratuito e de qualidade. Posso dizer com orgulho que alcanço agora um dos objetivos que planejei para minha vida há muitos anos. Foi um longo e árduo caminho, mas como diria Renato Russo, "... quem acredita sempre alcança...".

*“A tarefa não é tanto ver aquilo que ninguém viu, mas pensar
o que ninguém pensou sobre aquilo que todo mundo vê.”*
Arthur Schopenhauer

Resumo

SOUZA, U.B.; **Aplicação da Transformada de Hilbert-Huang e da Seleção Paraconsistente de Características no Campo da Entomologia Agrícola: Uma Abordagem para Identificação e Estimativa de Densidade de Cigarras em Lavouras Cafeeiras**. 2023. 272p. Tese (Doutorado) - Escola de Engenharia Elétrica, Mecânica e de Computação, Universidade Federal de Goiás, Goiânia, 2023.

Os sons emitidos por diversas espécies de insetos possuem características acústicas específicas e confiáveis. Por essa razão, a identificação acústica de insetos tem sido amplamente investigada pela comunidade científica no campo do reconhecimento de padrões. No Brasil, a espécie de cigarra *Quesada gigas* é considerada praga em lavouras de café devido à sua alimentação baseada na seiva das plantas, podendo causar prejuízos aos agricultores em ataques intensos. Diante do exposto e considerando o fato de que a característica mais marcante das cigarras é a emissão de sons para fins reprodutivos, este trabalho propõe um sistema destinado a auxiliar no manejo de insetos-praga em lavouras de café. Especificamente, este sistema visa detectar a presença de cigarras ou estimar sua densidade através de sinais acústicos. A abordagem combina de forma inovadora a extração e análise/seleção de características sonoras pela Transformada de Hilbert-Huang (Hilbert-Huang *Transform* - HHT) e a Engenharia Paraconsistente de Características, dois métodos emergentes de crescente interesse na comunidade científica. Foi realizado um estudo detalhado sobre a influência de oito critérios de parada para a *Empirical Mode Decomposition*, primeira etapa da HHT, considerando variações de parâmetros, temporalidade, amostragem dos sinais e também a codificação destes sinais em dois formatos. O primeiro define vetores pelas energias das *Intrinsic Mode Functions* (IMFs) em ordem de extração, enquanto o segundo distribui as energias das IMFs conforme as 25 faixas de frequência da Escala Bark. Adicionalmente, foi analisada a variação dimensional dos vetores. Os experimentos permitiram determinar configurações de baixo custo computacional, evidenciando a eficácia do sistema proposto, com modelos baseados em *Support Vector Machines* atingindo acurácias superiores a 98% tanto na identificação quanto na estimativa da densidade de cigarras. Assim, este documento detalha os fundamentos teóricos, o projeto, o desenvolvimento do sistema, discussões sobre possibilidades para sua aplicação prática, e uma análise inicial de um aplicativo desenvolvido para *smartphones*. Esta proposta tem potencial para incentivar a reutilização de equipamentos eletrônicos antigos, estimulando práticas sustentáveis e economicamente viáveis.

Palavras-chave: Processamento de Sinais. Transformada de Hilbert-Huang. Decomposição em Modo Empírico. Engenharia Paraconsistente de Características. Aprendizado de Máquinas. *Support Vector Machines*. Manejo de Cigarras.

Abstract

SOUZA, U.B.; **Application of Hilbert-Huang Transform and Paraconsistent Feature Selection in the Field of Agricultural Entomology: An Approach for Identification and Density Estimation of Cicadas in Coffee Crops.** 2023. 272p. Thesis (PhD) - School of Electrical, Mechanical, and Computing Engineering, Federal University of Goiás, Goiânia, 2023.

The sounds emitted by various insect species carry specific and reliable acoustic characteristics. For this reason, acoustic identification of insects has been widely investigated by the scientific community in the field of pattern recognition. In Brazil, the cicada species *Quesada gigas* is considered a pest in coffee crops due to its sap-feeding habits, which can cause losses to farmers during intense attacks. Given this scenario, and considering the fact that the most striking characteristic of cicadas is sound emission for reproductive purposes, this work proposes a system designed to assist in the management of pest insects in coffee crops. Specifically, this system aims to detect the presence of cicadas or estimate their density through acoustic signals. The approach innovatively combines the extraction and analysis/selection of sound features through the Hilbert-Huang Transform (HHT) and Paraconsistent Feature Engineering, two emerging methods of growing interest in the scientific community. A detailed study was conducted on the influence of eight stopping criteria for the Empirical Mode Decomposition, the first step of HHT, considering variations of parameters, temporality, signal sampling, and also the encoding of these signals in two formats. The first defines vectors by the energies of the Intrinsic Mode Functions (IMFs) in order of extraction, while the second distributes the energies of the IMFs according to the 25 frequency bands of the Bark Scale. Additionally, the dimensional variation of the vectors was analyzed. The experiments allowed determining low computational cost configurations, showcasing the efficacy of the proposed system, with models based on Support Vector Machines achieving accuracies above 98% in both identification and density estimation of cicadas. Thus, this document details the theoretical foundations, design, development of the system, discussions about possibilities for its practical application, and an initial analysis of a developed application for smartphones. This proposal has the potential to encourage the reuse of old electronic equipment, promoting sustainable and economically viable practices.

Keywords: Signal Processing. Hilbert-Huang Transform. Empirical Mode Decomposition. Paraconsistent Feature Engineering. Machine Learning. Support Vector Machines. Cicada Management.

Lista de ilustrações

Figura 1 – As três fases da <i>Quesada gigas</i>	51
Figura 2 – Representação das envoltórias superior e inferior (linhas tracejadas) de um sinal (linha contínua).	59
Figura 3 – IMF perfeita, definida pela Equação (2.1).	59
Figura 4 – Fluxograma do algoritmo da EMD.	61
Figura 5 – Exemplo de extração, passo a passo, da primeira IMF do sinal definido pela Equação (2.3).	62
Figura 6 – Representação tempo-frequência-amplitude da HHT aplicada ao sinal definido pela Equação (2.1). A curva tracejada representa a FI verdadeira, conforme definida na equação.	68
Figura 7 – Representação tempo-frequência-amplitude da HHT aplicada ao sinal definido pela Equação (2.3). As curvas tracejadas representam as FIs verdadeiras, conforme definidas na equação.	68
Figura 8 – Representação do PP. Os eixos G_1 e G_2 indicam os graus de certeza e contradição, respectivamente, como mencionado no passo P.5	71
Figura 9 – (a) Vetores de <i>features</i> das classes C_1 e C_2 representados no plano cartesiano pelos símbolos \times e \bullet , respectivamente. (b) Ponto P que representa o conjunto de vetores no PP.	73
Figura 10 – (a) Vetores de <i>features</i> das classes C_1 e C_2 representados no plano cartesiano pelos símbolos \times e \bullet , respectivamente. (b) Ponto P que representa o conjunto de vetores no PP.	74
Figura 11 – Estrutura SVM utilizada na abordagem proposta. A camada A é a camada de entrada, com m elementos passivos; a camada B é a camada oculta, com $n(X)$ elementos ativos; e a camada C é a camada de saída, com um elemento linear ativo. Na camada B , $\varphi_{-2} = \varphi_{n(X)-1}$, $\varphi_{-1} = \varphi_{n(X)}$, $w_{-2} = w_{n(X)-1}$ e $w_{-1} = w_{n(X)}$	82
Figura 12 – Esquema de Validação Cruzada por k -partes com $k = 6$	83
Figura 13 – Estrutura do sistema proposto.	85
Figura 14 – Estrutura proposta para o módulo MEF. As siglas utilizadas são explicadas no texto.	88
Figura 15 – Estrutura proposta para o módulo MNF. As siglas utilizadas são explicadas no texto.	89
Figura 16 – Estrutura proposta para o módulo MPFE. As siglas utilizadas são explicadas no texto.	90

Figura 17 – Estrutura proposta para o módulo MTT. As siglas utilizadas são explicadas no texto.	91
Figura 18 – Estrutura proposta para o módulo MVGR. As siglas utilizadas são explicadas no texto.	92
Figura 19 – Estrutura proposta para o módulo MAP. As siglas utilizadas são explicadas no texto.	93
Figura 20 – Exemplos de sinais acústicos normalizados: (a) correspondente à classe “cigarra” e (b) à classe “ruído”. Ambos possuem uma taxa de amostragem de 44.1 kHz e duração de 10 segundos.	96
Figura 21 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração SD-E1-G1.	105
Figura 22 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração EDT-E1-G1.	105
Figura 23 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração SSC-E1-G1.	106
Figura 24 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração TTC-E1-G1.	106
Figura 25 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração RFC-E1-G1.	106
Figura 26 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração OC-E1-G1.	107
Figura 27 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração VDS-E1-G1.	107
Figura 28 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração BWC-E1-G1.	107
Figura 29 – Diagramas de caixa ilustrando os IOs das decomposições para cada configuração. Em cada representação gráfica, a linha vertical situada no interior do retângulo denota a mediana, enquanto o símbolo “+” indica a média.	108
Figura 30 – Vetores de <i>features</i> da Tabela 13 representados em gráfico de radar. . .	111

Figura 31 – Gráficos de radar das <i>features</i> , em média, para as classes “cigarra” e “ruído” das configurações SD-E1-G1, SSC-E1-G1, TTC-E1-G1 e EDT-E1-G1.	111
Figura 32 – Gráficos de radar das <i>features</i> , em média, para as classes “cigarra” e “ruído” das configurações RFC-E1-G1, OC-E1-G1, VDS-E1-G1 e BWC-E1-G1.	111
Figura 33 – PPs para as configurações SD-E1-G1, SSC-E1-G1, TTC-E1-G1 e EDT-E1-G1. O ponto mais claro, em cada gráfico, indica os vetores com 2 <i>features</i> , enquanto o mais escuro representa vetores com o máximo M	112
Figura 34 – PPs para as configurações RFC-E1-G1, OC-E1-G1, VDS-E1-G1 e BWC-E1-G1. O ponto mais claro, em cada gráfico, indica os vetores com 2 <i>features</i> , enquanto o mais escuro representa vetores com o máximo M	112
Figura 35 – Resumo dos resultados do módulo MPFE. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exhibe as distâncias em relação ao VO.	113
Figura 36 – Resultados dos treinamentos com validação cruzada para a configuração SD-E1-G1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	115
Figura 37 – Resultados dos treinamentos com validação cruzada para a configuração SSC-E1-G1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	115
Figura 38 – Resultados dos treinamentos com validação cruzada para a configuração TTC-E1-G1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	116
Figura 39 – Resultados dos treinamentos com validação cruzada para a configuração EDT-E1-G1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	116
Figura 40 – Resultados dos treinamentos com validação cruzada para a configuração RFC-E1-G1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	117
Figura 41 – Resultados dos treinamentos com validação cruzada para a configuração OC-E1-G1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	117
Figura 42 – Resultados dos treinamentos com validação cruzada para a configuração VDS-E1-G1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	118
Figura 43 – Resultados dos treinamentos com validação cruzada para a configuração BWC-E1-G1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	118

Figura 44 – Resultados dos treinamentos utilizando validação cruzada para os modelos com maiores médias em todas as configurações de E1-G1. O número de <i>features</i> corresponde à ordem de extração das IMFs.	119
Figura 45 – Resultados dos testes dos melhores modelos em todos os cenários avaliados. O número de <i>features</i> é dado pela ordem de extração das IMFs.	119
Figura 46 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas. O número de <i>features</i> corresponde à sequência de extração das IMFs.	120
Figura 47 – MCs para as configurações SD-E1-G1, SSC-E1-G1, TTC-E1-G1 e EDT-E1-G1. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.	121
Figura 48 – MCs para as configurações RFC-E1-G1, OC-E1-G1, VDS-E1-G1 e BWC-E1-G1. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.	122
Figura 49 – Curvas ROC para as configurações SD-E1-G1, SSC-E1-G1, TTC-E1-G1 e EDT-E1-G1.	123
Figura 50 – Curvas ROC para as configurações RFC-E1-G1, OC-E1-G1, VDS-E1-G1 e BWC-E1-G1.	123
Figura 51 – Exemplos de vetores de <i>features</i> formados pelas configurações SD-E2-G1- $\{1,2,3\}$. Estes vetores correspondem aos representados na na Figura 30, porém resultantes dos sinais com frações de tempo reduzidas.	127
Figura 52 – Gráficos de radar das <i>features</i> , em média, para as classes “cigarra” e “ruído” das configurações SD-E2-G1- $\{1,2,3\}$	128
Figura 53 – Resumo dos resultados do módulo MPFE para E2-G1-1. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exhibe as distâncias em relação ao VO.	129
Figura 54 – Resumo dos resultados do módulo MPFE para E2-G1-2. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exhibe as distâncias em relação ao VO.	129
Figura 55 – Resumo dos resultados do módulo MPFE para E2-G1-3. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exhibe as distâncias em relação ao VO.	130
Figura 56 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E2-G1-1. O número de <i>features</i> corresponde à sequência de extração das IMFs.	131

Figura 57 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E2-G1-1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	131
Figura 58 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E2-G1-2. O número de <i>features</i> corresponde à sequência de extração das IMFs.	132
Figura 59 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E2-G1-2. O número de <i>features</i> é dado pela ordem de extração das IMFs.	132
Figura 60 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E2-G1-3. O número de <i>features</i> corresponde à sequência de extração das IMFs.	133
Figura 61 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E2-G1-3. O número de <i>features</i> é dado pela ordem de extração das IMFs.	133
Figura 62 – Exemplos de vetores de <i>features</i> formados pelas configurações SD-E3-G1- $\{1,2,3\}$. Estes vetores correspondem aos representados na Figura 51c, porém resultantes dos sinais com taxas de amostragem reduzidas.	138
Figura 63 – Gráficos de radar das <i>features</i> , em média, para as classes “cigarra” e “ruído” das configurações SD-E3-G1- $\{1,2,3\}$	139
Figura 64 – Resumo dos resultados do módulo MPFE para E3-G1-1. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.	140
Figura 65 – Resumo dos resultados do módulo MPFE para E3-G1-2. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.	140
Figura 66 – Resumo dos resultados do módulo MPFE para E3-G1-3. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.	141
Figura 67 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E3-G1-1. O número de <i>features</i> corresponde à sequência de extração das IMFs.	142
Figura 68 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E3-G1-1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	142

Figura 69 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E3-G1-2. O número de <i>features</i> corresponde à sequência de extração das IMFs.	143
Figura 70 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E3-G1-2. O número de <i>features</i> é dado pela ordem de extração das IMFs.	143
Figura 71 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E3-G1-3. O número de <i>features</i> corresponde à sequência de extração das IMFs.	144
Figura 72 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E3-G1-3. O número de <i>features</i> é dado pela ordem de extração das IMFs.	144
Figura 73 – Exemplos de vetores de <i>features</i> formados pelas configurações SD-E4-G1- $\{1,2\}$. Estes vetores correspondem aos representados na Figura 62c, porém, correspondem aos sinais decompostos com parâmetros mais flexíveis.	150
Figura 74 – Gráficos de radar das <i>features</i> , em média, para as classes “cigarra” e “ruído” das configurações SD-E4-G1- $\{1,2\}$	150
Figura 75 – Resumo dos resultados do módulo MPFE para E4-G1-1. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exhibe as distâncias em relação ao VO.	151
Figura 76 – Resumo dos resultados do módulo MPFE para E4-G1-2. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exhibe as distâncias em relação ao VO.	152
Figura 77 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E4-G1-1. O número de <i>features</i> corresponde à ordem de extração das IMFs.	153
Figura 78 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E4-G1-1. O número de <i>features</i> é dado pela ordem de extração das IMFs.	153
Figura 79 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E4-G1-2. O número de <i>features</i> corresponde à ordem de extração das IMFs.	154

Figura 80 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E4-G1-2. O número de <i>features</i> é dado pela ordem de extração das IMFs.	154
Figura 81 – Exemplos de vetores de <i>features</i> formados pelas configurações SD-E5-G1-1 à SD-E5-G1-6. Estes vetores correspondem aos representados na Figura 73b, porém, correspondem aos vetores normalizados por diferentes técnicas.	158
Figura 82 – Gráficos de radar das <i>features</i> , em média, para as classes “cigarra” e “ruído” das configurações SD-E5-G1-1 à SD-E5-G1-6.	159
Figura 83 – Resumo dos resultados do módulo MPFE para E5-G1-1. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	160
Figura 84 – Resumo dos resultados do módulo MPFE para E5-G1-2. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	161
Figura 85 – Resumo dos resultados do módulo MPFE para E5-G1-3. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	161
Figura 86 – Resumo dos resultados do módulo MPFE para E5-G1-4. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	162
Figura 87 – Resumo dos resultados do módulo MPFE para E5-G1-5. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	163
Figura 88 – Resumo dos resultados do módulo MPFE para E5-G1-6. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	163
Figura 89 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-1. O número de <i>features</i> corresponde à ordem de extração das IMFs.	165
Figura 90 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-2. O número de <i>features</i> corresponde à ordem de extração das IMFs.	165
Figura 91 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-3. O número de <i>features</i> corresponde à ordem de extração das IMFs.	166

Figura 92 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-4. O número de <i>features</i> corresponde à ordem de extração das IMFs.	166
Figura 93 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-5. O número de <i>features</i> corresponde à ordem de extração das IMFs.	167
Figura 94 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-6. O número de <i>features</i> corresponde à ordem de extração das IMFs.	167
Figura 95 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada SD. O número de <i>features</i> é dado pela ordem de extração das IMFs.	168
Figura 96 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada SSC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	168
Figura 97 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada TTC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	169
Figura 98 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada EDT. O número de <i>features</i> é dado pela ordem de extração das IMFs.	169
Figura 99 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada RFC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	169
Figura 100 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada OC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	170
Figura 101 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada VDS. O número de <i>features</i> é dado pela ordem de extração das IMFs.	170
Figura 102 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada BWC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	170
Figura 103 – Exemplos de vetores de <i>features</i> formados pelas configurações SD-E6-G2-1 à SD-E6-G2-7. Estes vetores correspondem aos representados na Figura 81, porém, no formato F2.	175

Figura 104 – Gráficos de radar das <i>features</i> , em média, para as classes “cigarra” e “ruído” das configurações SD-E6-G2-1 à SD-E6-G2-7.	176
Figura 105 – Resumo dos resultados do módulo MPFE para E6-G2-1. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	177
Figura 106 – Resumo dos resultados do módulo MPFE para E6-G2-2. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	177
Figura 107 – Resumo dos resultados do módulo MPFE para E6-G2-3. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	178
Figura 108 – Resumo dos resultados do módulo MPFE para E6-G2-4. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	178
Figura 109 – Resumo dos resultados do módulo MPFE para E6-G2-5. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	179
Figura 110 – Resumo dos resultados do módulo MPFE para E6-G2-6. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	179
Figura 111 – Resumo dos resultados do módulo MPFE para E6-G2-7. Em (a) apresentam-se os melhores pontos <i>P</i> ; em (b) os piores pontos <i>P</i> ; e (c) exibe as distâncias em relação ao VO.	180
Figura 112 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-1. O número de <i>features</i> corresponde às primeiras bandas críticas da EB.	181
Figura 113 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-2. O número de <i>features</i> corresponde às primeiras bandas críticas da EB.	181
Figura 114 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-3. O número de <i>features</i> corresponde às primeiras bandas críticas da EB.	182
Figura 115 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-4. O número de <i>features</i> corresponde às primeiras bandas críticas da EB.	182

Figura 116–Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-5. O número de <i>features</i> corresponde às primeiras bandas críticas da EB.	183
Figura 117–Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-6. O número de <i>features</i> corresponde às primeiras bandas críticas da EB.	183
Figura 118–Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-7. O número de <i>features</i> corresponde às primeiras bandas críticas da EB.	184
Figura 119–Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada SD. O número de <i>features</i> é dado pela ordem de extração das IMFs.	184
Figura 120–Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada SSC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	185
Figura 121–Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada TTC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	185
Figura 122–Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada EDT. O número de <i>features</i> é dado pela ordem de extração das IMFs.	185
Figura 123–Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada RFC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	186
Figura 124–Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada OC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	186
Figura 125–Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada VDS. O número de <i>features</i> é dado pela ordem de extração das IMFs.	186
Figura 126–Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada BWC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	187
Figura 127–MCs das melhores configurações em E6-G2 para os critérios de parada SD, SSC, TTC e EDT. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.	188

Figura 128 – MCs das melhores configurações em E6-G2 para os critérios de parada RFC, OC, VDS e BWC. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.	188
Figura 129 – Exemplo gerado aleatoriamente onde vetores compostos por cinco <i>features</i> produzem as combinações ilustradas, considerando-se duas configurações distintas.	192
Figura 130 – Melhores combinações de <i>features</i> em SD-E7-G2-K.	194
Figura 131 – Melhores combinações de <i>features</i> em SSC-E7-G2-K.	195
Figura 132 – Melhores combinações de <i>features</i> em TTC-E7-G2-K.	196
Figura 133 – Melhores combinações de <i>features</i> em EDT-E7-G2-K.	197
Figura 134 – Melhores combinações de <i>features</i> em RFC-E7-G2-K.	198
Figura 135 – Melhores combinações de <i>features</i> em OC-E7-G2-K.	199
Figura 136 – Melhores combinações de <i>features</i> em VDS-E7-G2-K.	200
Figura 137 – Melhores combinações de <i>features</i> em BWC-E7-G2-K.	201
Figura 138 – Resumo dos resultados do módulo MPFE para E7-G2-1. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO. . .	203
Figura 139 – Resumo dos resultados do módulo MPFE para E7-G2-2. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO. . .	203
Figura 140 – Resumo dos resultados do módulo MPFE para E7-G2-3. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO. . .	204
Figura 141 – Resumo dos resultados do módulo MPFE para E7-G2-4. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO. . .	204
Figura 142 – Resumo dos resultados do módulo MPFE para E7-G2-5. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO. . .	205
Figura 143 – Resumo dos resultados do módulo MPFE para E7-G2-6. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO. . .	205
Figura 144 – Resumo dos resultados do módulo MPFE para E7-G2-7. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO. . .	206
Figura 145 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-1. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	207
Figura 146 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-2. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	207

Figura 147	– Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-3. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	208
Figura 148	– Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-4. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	208
Figura 149	– Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-5. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	209
Figura 150	– Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-6. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	209
Figura 151	– Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-7. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	210
Figura 152	– Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada SD. O número de <i>features</i> é dado pela ordem de extração das IMFs.	210
Figura 153	– Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada SSC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	210
Figura 154	– Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada TTC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	211
Figura 155	– Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada EDT. O número de <i>features</i> é dado pela ordem de extração das IMFs.	211
Figura 156	– Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada RFC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	211
Figura 157	– Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada OC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	212

Figura 158 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada VDS. O número de <i>features</i> é dado pela ordem de extração das IMFs.	212
Figura 159 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada BWC. O número de <i>features</i> é dado pela ordem de extração das IMFs.	212
Figura 160 – MCs das melhores configurações em E7-G2 para os critérios de parada SD, SSC, TTC e EDT. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.	213
Figura 161 – MCs das melhores configurações em E7-G2 para os critérios de parada RFC, OC, VDS e BWC. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.	214
Figura 162 – Gráficos de radar das <i>features</i> , em média, para as classes “alta”, “baixa” e “ruído” das configurações SD-E8-G3-1 à SD-E8-G3-7.	217
Figura 163 – Melhores combinações de <i>features</i> em SD-E8-G3-K.	219
Figura 164 – Melhores combinações de <i>features</i> em SSC-E8-G3-K.	220
Figura 165 – Melhores combinações de <i>features</i> em TTC-E8-G3-K.	221
Figura 166 – Melhores combinações de <i>features</i> em EDT-E8-G3-K.	222
Figura 167 – Melhores combinações de <i>features</i> em RFC-E8-G3-K.	223
Figura 168 – Melhores combinações de <i>features</i> em OC-E8-G3-K.	224
Figura 169 – Melhores combinações de <i>features</i> em VDS-E8-G3-K.	225
Figura 170 – Melhores combinações de <i>features</i> em BWC-E8-G3-K.	226
Figura 171 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E8-G3. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	227
Figura 172 – Resultados dos testes para as configurações que exibiram os melhores resultados em pelo menos um dos cenários avaliados, para cada critério de parada da EMD, em E8-G3. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	228
Figura 173 – MCs para as configurações SD-E8-G3, SSC-E8-G3, TTC-E8-G3 e EDT-E8-G3. Os escalares 1, 0 e -1 representam, respectivamente, as classes “alta”, “ruído” e “baixa”.	229
Figura 174 – MCs para as configurações RFC-E8-G3, OC-E8-G3, VDS-E8-G3 e BWC-E8-G3. Os escalares 1, 0 e -1 representam, respectivamente, as classes “alta”, “ruído” e “baixa”.	229
Figura 175 – Comparação entre <i>features</i> , em média, extraídas a partir de sinais acústicos com taxas de amostragem de (a) 6 kHz e (b) 13 kHz.	231

Figura 176 – Gráficos de radar das <i>features</i> , em média, para as classes “alta”, “baixa” e “ruído” das configurações SD-E9-G3.	233
Figura 177 – Melhores combinações de <i>features</i> em SD-E9-G3-K.	236
Figura 178 – Melhores combinações de <i>features</i> em SSC-E9-G3-K.	237
Figura 179 – Melhores combinações de <i>features</i> em TTC-E9-G3-K.	238
Figura 180 – Melhores combinações de <i>features</i> em EDT-E9-G3-K.	239
Figura 181 – Melhores combinações de <i>features</i> em RFC-E9-G3-K.	240
Figura 182 – Melhores combinações de <i>features</i> em OC-E9-G3-K.	241
Figura 183 – Melhores combinações de <i>features</i> em VDS-E9-G3-K.	242
Figura 184 – Melhores combinações de <i>features</i> em BWC-E9-G3-K.	243
Figura 185 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E9-G3. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	244
Figura 186 – Resultados dos testes para as configurações que exibiram os melhores resultados em todos os cenários avaliados em E9-G3. O número de <i>features</i> é dado pelas melhores combinações segundo o módulo MPFE.	245
Figura 187 – MCs para as configurações SD-E9-G3, SSC-E9-G3, TTC-E9-G3 e EDT-E9-G3. Os escalares 1, 0 e -1 representam, respectivamente, as classes “alta”, “ruído” e “baixa”.	246
Figura 188 – MCs para as configurações RFC-E9-G3, OC-E9-G3, VDS-E9-G3 e BWC-E9-G3. Os escalares 1, 0 e -1 representam, respectivamente, as classes “alta”, “ruído” e “baixa”.	246
Figura 189 – Curvas ROC das melhores e piores configurações em E9-G3 para os critérios de parada SD, SSC, TTC e EDT.	247
Figura 190 – Curvas ROC das melhores e piores configurações em E9-G3 para os critérios de parada RFC, OC, VDS e BWC.	248
Figura 191 – Interface do protótipo de aplicativo desenvolvido. Em (a) as opções disponíveis após uma rodada de testes e em (b) a opção para nova leitura.	253

Lista de tabelas

Tabela 1 – Frequências dominantes da espécie <i>Quesada gigas</i>	50
Tabela 2 – Lista de trabalhos envolvendo técnicas de monitoramento	56
Tabela 3 – Bandas críticas da EB	75
Tabela 4 – Grupos de experimentos	99
Tabela 5 – Experimentos realizados em cada grupo	100
Tabela 6 – Hiperparâmetros considerados na busca em grade no módulo MTT	100
Tabela 7 – Configurações para o experimento E1 do grupo G1.	101
Tabela 8 – Número de IMFs e iterações do SP em cada configuração de E1-G1.	102
Tabela 9 – Exemplos de energias das IMFs	103
Tabela 10 – Quantidade máxima de IMFs por configuração em E1-G1	103
Tabela 11 – Média de iterações no SP para E1-G1	104
Tabela 12 – Distribuição dos IOs e o Tempo Médio de Decomposição em E1-G1	109
Tabela 13 – Exemplos de vetores de <i>features</i> em E1-G1	110
Tabela 14 – Melhores resultados em E1-G1.	123
Tabela 15 – Configurações para o experimento E2 do grupo G1.	125
Tabela 16 – Média de iterações no SP para E2-G1-3	125
Tabela 17 – Quantidade máxima de IMFs por configuração em E2-G1	126
Tabela 18 – Distribuição dos IOs e o Tempo Médio de Decomposição em E2-G1	127
Tabela 19 – Melhores resultados em E2-G1	134
Tabela 20 – Configurações para o experimento E3 do grupo G1.	135
Tabela 21 – Média de iterações no SP para E3-G1-3	136
Tabela 22 – Quantidade máxima de IMFs por configuração em E3-G1	137
Tabela 23 – Distribuição dos IOs e o Tempo Médio de Decomposição em E3-G1	137
Tabela 24 – Melhores resultados em E3-G1	145
Tabela 25 – Configurações para o experimento E4 do grupo G1.	147
Tabela 26 – Média de iterações no SP para E4-G1-2	148
Tabela 27 – Quantidade máxima de IMFs por configuração em E4-G1	148
Tabela 28 – Distribuição dos IOs e o Tempo Médio de Decomposição em E4-G1	149
Tabela 29 – Melhores resultados em E4-G1	155
Tabela 30 – Configurações para o experimento E5 do grupo G1.	157
Tabela 31 – Quantidade máxima de IMFs por configuração em E5-G1	158
Tabela 32 – Melhores resultados em E5-G1	171
Tabela 33 – Configurações para o experimento E6 do grupo G2.	174
Tabela 34 – Melhores resultados em E6-G2	189
Tabela 35 – Número de combinações para 25 de k em k , onde $2 \leq k \leq 25$ e $k \in \mathbb{Z}$	191

Tabela 36 – <i>Features</i> mais influentes segundo a análise PFE	202
Tabela 37 – Melhores resultados em E7-G2	215
Tabela 38 – Melhores resultados em E8-G3.	230
Tabela 39 – Configurações para o experimento E9 do grupo G3.	232
Tabela 40 – Distribuição dos IOs e o Tempo Médio de Decomposição em E9-G3	233
Tabela 41 – Melhores resultados em E9-G3. O termo “Poly” refere-se ao <i>kernel</i> Polinomial.	247
Tabela 42 – Comparação entre os tempos médios demandados para as decomposições nos experimentos iniciais e finais.	250
Tabela 43 – Acurácias obtidas nos testes do aplicativo em três modelos de marcas distintas de <i>smartphones</i> , variando as distâncias de emissão.	252

Lista de abreviaturas e siglas

AUC	<i>Area Under the Curve</i>
BWC	<i>Bandwidth Criterion</i>
EB	Escala Bark
EDT	<i>Energy Difference Tracking</i>
EMD	<i>Empirical Mode Decomposition</i>
FFT	<i>Fast Fourier Transform</i>
FN	Falso Negativo
FP	Falso Positivo
FT	<i>Fourier Transform</i>
GMM	<i>Gaussian Mixture Model</i>
HMMs	<i>Hidden Markov Models</i>
HHT	<i>Hilbert-Huang Transform</i>
HT	<i>Hilbert Transform</i>
Hz	Hertz
IA	Inteligência Artificial
ICA	<i>Independent Component Analysis</i>
IIQ	Intervalo Interquartil
IMFs	<i>Intrinsic Mode Functions</i>
IO	<i>Index of Orthogonality</i>

IoT	<i>Internet of Things</i>
LFCCs	<i>Linear Frequency Cepstral Coefficients</i>
LS	<i>Logistic Sigmoid</i>
MAP	Módulo de Aplicação
MC	Matriz de Confusão
MEF	Módulo de Extração das <i>Features</i>
MFCCs	<i>Mel Frequency Cepstral Coefficients</i>
MMN	<i>Min-Max Normalization</i>
MN	<i>Max Normalization</i>
MNF	Módulo de Normalização das <i>Features</i>
MPFE	Módulo PFE
MTT	Módulo de Treinamento e Testes
MVGR	Módulo de Visualização Gráfica dos Resultados
OC	<i>Orthogonality Criterion</i>
PCA	<i>Principal Component Analysis</i>
PDS	Processamento Digital de Sinais
PFE	<i>Paraconsistent Feature Engineering</i>
PNN	<i>Probabilistic Neural Network</i>
PP	Plano Paraconsistente
QG	<i>Quesada gigas</i>
RBA	<i>Rapid Biodiversity Assessments</i>
RBF	<i>Radial Basis Function</i>

RFC	<i>Resolution Factor Criterion</i>
ROC	<i>Receiver operating characteristics</i>
SD	<i>Standard Deviation</i>
SDC	<i>Softwares</i> ou Dispositivos em Campo
SL	<i>Softwares</i> em Laboratório
SP	<i>Sifting Process</i>
SSC	<i>Simplified Stoppage Criterion</i>
STFT	<i>Short Time Fourier Transform</i>
SVM	<i>Support Vector Machine</i>
TM	Técnicas Manuais
TMD	Tempo Médio de Decomposição
TTC	<i>3-Threshold Criterion</i>
VDS	<i>Valid Data Segment</i>
VN	Verdadeiro Negativo
VO	Vértice Ótimo
VP	Verdadeiro Positivo
WAV	<i>Waveform Audio File Format</i>
WT	<i>Wavelet Transform</i>

Lista de símbolos

α	Letra grega alfa
β	Letra grega beta
ϵ	Letra grega épsilon
γ	Letra grega gama
π	Letra grega pi
σ	Letra grega sigma
θ	Letra grega teta
\mathbb{R}	Conjunto dos números reais
\mathbb{R}_+	Conjunto dos números reais positivos

Sumário

1	INTRODUÇÃO	41
1.1	Manejo e Controle de Cigarras em Lavouras de Café	41
1.2	Análise em Tempo-Frequência	43
1.3	Vetores de Características para Reconhecimento de Padrões	44
1.4	Objetivos	45
1.5	Publicações relacionadas à pesquisa	46
1.6	Organização do trabalho	48
2	REVISÃO DE CONCEITOS	49
2.1	Revisão da Literatura sobre Técnicas e Desafios para Monitoramento de Pragas em Lavouras	49
2.1.1	Particularidades Bioecológicas das Cigarras	50
2.1.2	Monitoramento Manual	51
2.1.3	Monitoramento por <i>Software</i>	52
2.1.4	Discussões	55
2.2	Transformada de Hilbert-Huang	57
2.2.1	Definição de IMF e o algoritmo da EMD	58
2.2.2	Critérios de Parada da EMD	61
2.2.3	Ortogonalidade	66
2.2.4	A Transformada de Hilbert	66
2.2.5	Versão discreta da Transformada de Hilbert	68
2.3	Engenharia Paraconsistente de Características	69
2.3.1	Calcular P e sua Interpretação no PP	70
2.3.2	Exemplo Numérico sem Sobreposição	72
2.3.3	Exemplo Numérico com Sobreposição	72
2.4	Escala Bark	74
2.5	Normalizações	75
3	ABORDAGEM PROPOSTA	79
3.1	Estrutura do Sistema Proposto	79
3.2	Detalhes do sistema	84
3.2.1	MEF	85
3.2.2	MNF	87
3.2.3	MPFE	89
3.2.4	MTT	90

3.2.5	MVGR	91
3.2.6	MAP	92
4	TESTES E RESULTADOS	95
4.1	Materiais e Métodos	95
4.1.1	MEF	96
4.1.2	MNF	97
4.1.3	MPFE	97
4.1.4	MTT	98
4.1.5	MVGR	98
4.1.6	MAP	99
4.2	Experimentos Realizados	99
4.2.1	Grupo G1	101
4.2.1.1	Experimento E1	101
4.2.1.2	Experimento E2	124
4.2.1.3	Experimento E3	135
4.2.1.4	Experimento E4	146
4.2.1.5	Experimento E5	156
4.2.2	Grupo G2	172
4.2.2.1	Experimento E6	172
4.2.2.2	Experimento E7	190
4.2.3	Grupo G3	214
4.2.3.1	Experimento E8	215
4.2.3.2	Experimento E9	231
4.3	Comentários Gerais	248
4.3.1	Dispositivos IoT	251
4.3.2	Protótipo de Aplicativo para Celulares	252
5	CONCLUSÕES	255
	REFERÊNCIAS	259

1 Introdução

Esta pesquisa aborda a interseção de duas áreas: o reconhecimento de padrões, com ênfase na seleção generalizada de características, e o manejo agrícola, especificamente voltado ao combate de cigarras que prejudicam as lavouras de café. A introdução está estruturada em seções que detalham o manejo e controle de cigarras em lavouras de café, técnicas para Processamento Digital de Sinais (PDS), a elaboração de vetores de características para reconhecimento de padrões, os objetivos centrais da pesquisa, as publicações correlatas ao estudo e, por fim, a organização da tese. Esta abordagem multidisciplinar visa proporcionar uma compreensão profunda dos desafios e soluções propostas, estabelecendo um panorama claro e coeso.

1.1 Manejo e Controle de Cigarras em Lavouras de Café

O manejo integrado de insetos e pragas, que consiste em uma abordagem sistemática para prevenir, monitorar e controlar pragas através da combinação de múltiplas técnicas e estratégias, tem como objetivo não apenas minimizar os danos causados por esses organismos, mas também reduzir a aplicação de pesticidas, protegendo assim o meio ambiente e a saúde humana (GRAVENA, 1992). Tal abordagem é fundamental na agricultura, especialmente quando se refere ao cultivo de lavouras. No Brasil, há mais de um século, são documentados ataques a plantações de café por uma espécie de cigarra, a *Quesada gigas*, que pertence à ordem Hemiptera e à família Cicadidae (D'UTRA, 1908; MOULDS, 2005).

O ciclo de vida das cigarras pode se estender até 17 anos, dependendo da espécie, com a maior parte desse tempo passado no estágio de ninfa (WILLIAMS; SIMON, 1995). A fase adulta pode durar de algumas semanas a três meses. As fêmeas depositam seus ovos mais comumente em ramos secos, e as ninfas, após a eclosão, descem ao solo em busca de raízes, uma vez que a seiva é a única fonte de alimento durante toda a sua vida (MACCAGNAN, 2008).

O impacto econômico é causado principalmente por infestações em lavouras de café localizadas nos estados de São Paulo e Minas Gerais, onde a espécie *Quesada gigas* é considerada uma praga (MARTINELLI; LUSVARGHI, 1998). Posto isso, a implementação de estratégias de manejo, tais como o monitoramento, torna-se essencial. Em casos de ataques intensos, as plantas podem morrer devido aos danos causados. Para ilustrar a magnitude do problema, existem registros de que até a década de 1970 lavouras infestadas foram erradicadas ou abandonadas por produtores, pois não haviam técnicas eficientes de

controle ou combate às cigarras (SOUZA; REIS; SILVA, 2007).

Atualmente, existem várias técnicas de monitoramento de cigarras, no entanto, a maioria delas requer intervenção humana no processo de identificação e consiste basicamente na contagem não automatizada por meio de observação direta (ESCOLA et al., 2021). Quanto ao controle, a técnica mais utilizada e eficaz é a aplicação de inseticidas diretamente ao solo para eliminar as ninfas (GONÇALVES; FARIA, 1989; SOUZA; REIS; SILVA, 2007). No entanto, o uso sistemático ou inadequado de pesticidas pode causar sérios danos ambientais (FORNAZIER; ROCHA, 2000).

Outra abordagem de controle é o uso de armadilhas sonoras, pois uma das características mais marcantes das cigarras é a emissão de som (ESCOLA et al., 2021). Apenas os machos possuem uma estrutura específica para a produção e emissão de sinais acústicos, que são usados principalmente para atrair fêmeas para a reprodução (SUEUR, 2001). Portanto, a reprodução de gravações do som de determinadas espécies pode ser usada como isca sonora, atraindo um grande número de indivíduos adultos. Esta isca sonora, associada a uma armadilha, é capaz de compor um sistema de controle eficaz (MACCAGNAN, 2008).

O emprego de armadilhas sonoras pode ser otimizado se integrado a um sistema de monitoramento de áudio automatizado que detecte a infestação por meio de dispositivos implantados na lavoura, conforme proposto por Escola et al. (ESCOLA et al., 2020b; ESCOLA et al., 2021). Tal sistema pode possibilitar a determinação das áreas com maior incidência de insetos, auxiliando na tomada de decisões para um controle direcionado e evitando o uso excessivo de agrotóxicos. Embora essa solução não seja comum na literatura, conforme abordado no Capítulo 2, a identificação de insetos por meio da modalidade acústica tem sido amplamente estudada pela comunidade científica (GANCHEV; POTAMITIS, 2007; ZAMANIAN; POURGHASSEM, 2017), dado que os sons são características taxonômicas altamente confiáveis (RIEDE, 1998).

Implementações de soluções tecnológicas, como as de Escola et al. (ESCOLA et al., 2020b; ESCOLA et al., 2021), que visam otimizar a resolução de problemas relacionados à agricultura, estão em constante evolução. Essas inovações representam um esforço contínuo para melhorar a eficiência e a sustentabilidade das práticas agrícolas, estando em sintonia com conceitos emergentes como *Smart Farm*, *e-farm*, Agricultura Digital, Agricultura 4.0, entre outras variações, que compõem uma área bastante promissora, com vários estudos publicados recentemente (KODALI; YERROJU; SAHU, 2018; ALVES et al., 2019; ALONSO et al., 2020; ZGANK, 2020; GUPTA et al., 2020).

Nesse contexto, acredita-se que soluções que buscam integrar tecnologias avançadas, como Internet das Coisas (*Internet of Things* - IoT) (HOLLER et al., 2014), Inteligência Artificial (IA) (RUSSELL; NORVIG, 2022), o aprendizado de máquinas (ALPAYDIN,

2014), redes neurais (HAYKIN, 2001) e outras, no setor agrícola, com o objetivo de otimizar a produção, minimizar o impacto ambiental e aumentar a rentabilidade, podem auxiliar ainda na automação de processos que geralmente são manuais, economizando tempo e recursos (SOUZA; REIS; SILVA, 2007). Isso inclui a identificação de regiões infestadas e a indicação da densidade de indivíduos presentes em cada região. Adicionalmente, a automação pode facilitar a coleta e análise de dados em larga escala, produzindo informações valiosas para pesquisas e para o desenvolvimento de novas estratégias de manejo de pragas. Essas informações podem ser usadas para refinar e personalizar as estratégias, maximizando assim sua eficácia.

1.2 Análise em Tempo-Frequência

Para viabilizar a implementação de soluções como as mencionadas na seção anterior, o PDS é uma área de pesquisa de extrema importância, que tem aplicações em diversos campos, desde a agricultura (NODA et al., 2016) até a medicina (PROCHÁZKA; VYŠATA, 2014). As técnicas de PDS permitem a análise detalhada dos sinais no domínio tempo-frequência e a extração de informações úteis, possibilitando sua integração com outras áreas do conhecimento, como biologia e ecologia, para aplicações como a detecção de doenças em plantas através de imagens (KHIRADE; PATIL, 2015) ou a identificação de espécies de insetos através de sons (OHYA, 2004), além de outras.

No que diz respeito ao processamento de sinais acústicos para identificação de espécies, detecção, estimativa de densidade ou qualquer outra finalidade, as técnicas para análise em tempo-frequência representam uma parte crucial do processo, pois permitem a identificação de características únicas do sinal que podem ser usadas para classificação ou análise (UMAPATHY; GHORAANI; KRISHNAN, 2010). Nesse sentido, várias metodologias foram desenvolvidas ao longo dos anos. Exemplos notáveis incluem a Transformada de Fourier (*Fourier Transform* - FT) (STEIN; SHAKARCHI, 2011), a Transformada Wavelet (*Wavelet Transform* - WT) (GRAPS, 1995) e, recentemente, a Transformada de Hilbert-Huang (*Hilbert-Huang Transform* - HHT) (HUANG, 1996).

A FT é uma das ferramentas mais comuns para essa finalidade, fornecendo uma representação do sinal no domínio da frequência (OPPENHEIM; SCHAFFER, 2010). No entanto, ela não fornece informações sobre quando eventos específicos ocorrem no tempo e não é adequada para sinais não estacionários (COHEN, 1989). A WT, por outro lado, fornece uma representação tempo-frequência do sinal, permitindo a identificação de variações temporais no conteúdo de frequência do sinal (MALLAT, 2008) e é amplamente usada para a análise de sinais não lineares e não estacionários (ZHENG et al., 2020; ADHIKARI et al., 2020; ESCOLA et al., 2021). Já a HHT é uma alternativa mais recente que também fornece uma representação tempo-frequência, e foi especificamente

desenvolvida para analisar sinais não lineares e não estacionários (HUANG, 1996; HUANG et al., 1998).

Na literatura disponível, é possível encontrar publicações relacionadas à aplicação das transformadas mencionadas a sinais acústicos para identificação de espécies e detecção de indivíduos, tanto de insetos quanto de animais. Bardeli, Wolff e Clausen (2007) e Tey et al. (2022), por exemplo, aplicam a FT para reconhecimento de espécies de pássaros e cigarras, respectivamente. Por outro lado, Escola et al. (2021) aplicam a WT para detecção de cigarras e Nolasco et al. (2019) a HHT para identificar se há ausência de abelhas rainha em colmeias.

Acredita-se que, apesar de possíveis limitações impostas por uma pesquisa bibliográfica, existem poucas citações sobre o uso da HHT para a análise ou classificação de sons de cigarras. Um exemplo é o trabalho de Tu et al. (2020), que mencionam brevemente seu uso parcial, mas sem entrar em detalhes. Dada essa lacuna, esta tese explora a utilização da HHT para a extração de características de sinais acústicos de cigarras. É importante mencionar que, apesar de recente, a HHT tem sido bastante investigada e aplicada a diversas áreas do conhecimento nos últimos anos, como biomedicina (EGAMBARAM et al., 2016), Engenharia Elétrica (BABU; MOHAN, 2017), Engenharia Mecânica (TABRIZI et al., 2014; TABRIZI et al., 2016) e várias outras (SOUZA; ESCOLA; BRITO, 2022). Suas propriedades únicas, que são abordadas no Capítulo 2, ressaltam a relevância desta pesquisa, que pode contribuir significativamente para a área.

1.3 Vetores de Características para Reconhecimento de Padrões

Vetores de características são representações compactas de dados em vetores n -dimensionais, compostos por coordenadas, comumente chamadas de *features*, numéricas ou categóricas, que descrevem um objeto ou fenômeno (GUYON; ELISSEEFF, 2003). No contexto desta tese, o processamento de sinais acústicos, as *features* contêm informações de energia e frequência, conforme elucidado no Capítulo 3. Em outros contextos, as *features* podem também representar informações como amplitude, duração do sinal e outras propriedades. Posto isso, tais vetores serão denominados vetores de *features* no texto que segue.

A seleção de *features* é um processo que visa identificar e selecionar as *features* mais informativas e relevantes de um conjunto de dados. Este processo é crucial para melhorar a eficiência e a eficácia dos modelos de aprendizado de máquina. Ao reduzir a dimensionalidade dos dados, a seleção de *features* contribui significativamente para a diminuição do custo computacional, já que modelos com menos variáveis são computacionalmente menos custosos para serem treinados e aplicados. Além disso, este processo propicia a melhoria da precisão da previsão e previne o *overfitting* (GUYON; ELISSEEFF, 2003; SAEYS; INZA;

LARRAÑAGA, 2007).

Existem várias técnicas para a seleção de *features*, que podem ser categorizadas em três tipos principais, de acordo com Chandrashekar e Sahin (2014): métodos de filtro (*filter methods*), métodos de *wrapper* (*wrapper methods*) e métodos embutidos (*embedded methods*). Os métodos de filtro avaliam as *features* com base em suas propriedades estatísticas, independentemente de qualquer algoritmo de aprendizado de máquina. Os métodos de *wrapper*, por outro lado, avaliam as *features* com base em seu desempenho quando usadas por um algoritmo de aprendizado de máquina específico. Finalmente, os métodos embutidos realizam a seleção de *features* como parte do processo de treinamento do modelo.

Dentre as diversas técnicas de seleção, a Engenharia Paraconsistente de Características (*Paraconsistent Feature Engineering* - PFE) é uma abordagem recentemente proposta por Guido (2019) para a seleção de *features* que se baseia na Lógica Paraconsistente. A Lógica Paraconsistente é uma subárea da lógica que permite a manipulação de contradições de uma maneira controlada, tornando-a adequada para lidar com incertezas e inconsistências nos dados (CARNIELLI; CONIGLIO, 2016). A PFE utiliza essa propriedade para avaliar a relevância e a redundância das *features* intra e interclasses, proporcionando um critério robusto e generalista para a seleção das *features*.

A PFE pode ser classificada como um método de filtro, já que avalia a relevância e a redundância das *features* para definir uma estratégia quantitativa de investigação, observando eventuais conflitos intraclasses e interclasses (GUIDO, 2019), independentemente de qualquer algoritmo de aprendizado de máquina específico. Assim como outros métodos de filtro, a PFE é geralmente mais rápida e menos propensa a *overfitting* do que os métodos de *wrapper* e embutidos (SAEYS; INZA; LARRAÑAGA, 2007), embora possa não ser capaz de capturar interações complexas entre características que poderiam ser identificadas por esses outros métodos.

Assim sendo, junto à escolha estratégica da HHT para a construção dos vetores de *features*, nesta tese também se emprega a PFE para a seleção de *features*. O objetivo desta abordagem combinada é minimizar ainda mais o custo computacional, visando aumentar a precisão do modelo e garantir que as *features* mais informativas e relevantes sejam utilizadas para seu treinamento e implementação.

1.4 Objetivos

Com o intuito de aprimorar e contribuir com o manejo de insetos-praga em lavouras de café, especialmente na detecção da presença de cigarras, como mencionado na seção anterior, a principal meta desta pesquisa é a aplicação da HHT e da PFE para a extração, análise e seleção de *features* de sinais acústicos, que representam uma característica notável

das cigarras. Essa meta principal engloba os seguintes objetivos específicos:

- O.1:** Coletar sinais acústicos de cigarras em lavouras de café utilizando um gravador digital, com os dados sendo armazenados no formato WAV (*Waveform Audio File Format*) (FRANCIS, 2009);
- O.2:** Desenvolver um algoritmo para a extração de *features* dos sinais acústicos com base na HHT. Este algoritmo deve criar vetores de *features* a partir das energias e frequências instantâneas das componentes, obtidas pela HHT, em combinação com a Escala Bark (EB) (ZWICKER, 1961);
- O.3:** Analisar e selecionar as melhores combinações de *features* por meio da PFE;
- O.4:** Analisar o impacto da variação da taxa de amostragem dos sinais e da normalização dos vetores de *features* sobre os resultados da PFE e de modelos de classificação baseados em Máquinas de Vetores Suporte (*Support Vector Machine - SVM*) (ALPAYDIN, 2014);
- O.5:** Verificar a viabilidade do uso de configurações menos exigentes para a Decomposição em Modo Empírico (*Empirical Mode Decomposition - EMD*) e taxa de amostragem reduzida, com o intuito de reduzir o custo computacional do sistema proposto. A EMD é uma etapa, de duas, da HHT, os detalhes adicionais são introduzidos no [Capítulo 2](#).
- O.6:** Identificar qual critério de parada da EMD demanda menor custo computacional e comparar a influência de diferentes critérios sobre os resultados de classificação;
- O.7:** Constatar a viabilidade do sistema proposto para uso em microcontroladores que poderão ser implantados em lavouras de café;
- O.8:** Desenvolver um protótipo de aplicativo para celulares *Android* que seja capaz de capturar áudios e classificá-los através de um modelo previamente treinado. Este aplicativo possibilitará projetos futuros envolvendo o reaproveitamento de equipamentos eletrônicos (*e-waste*) (PERKINS et al., 2014; SHAHABUDDIN et al., 2023), como *smartphones*, para os fins desta pesquisa.

1.5 Publicações relacionadas à pesquisa

Artigos científicos associados a esta pesquisa foram publicados, possibilitando avaliações por parte de outros fóruns acadêmicos. Isso não apenas contribuiu para o aprimoramento da pesquisa em questão, mas também para a disseminação do conhecimento gerado, além de pavimentar caminhos para futuras colaborações. Segue a lista de artigos publicados em colaboração com pesquisadores parceiros:

- A.1:** ESCOLA, J. P. L. et al. Estado da arte no monitoramento acústico de Cicadidae em lavouras de café: State of the art in acoustic monitoring of Cicadidae in coffee crops. *Revista Macambira*, v. 5, n. 1, p. e051007, jun. 2021. ISSN 2594-4754.
- A.2:** SOUZA, U. B. de; ESCOLA, J. P. L.; BRITO, L. da C. A survey on hilbert-huang transform: Evolution, challenges and solutions. *Digital Signal Processing*, v. 120, p. 103292, 2022. ISSN 1051-2004.
- A.3:** ESCOLA, J. P. L. et al. A mesh network case study for digital audio signal processing in smart farm. *Internet of Things*, v. 17, p. 100488, 2022. ISSN 2542-6605.
- A.4:** ESCOLA, J. P. L. et al. The haar wavelet transform in iot digital audio signal processing. *Circuits, Systems, and Signal Processing*, Feb 2022. ISSN 1531-5878.
- A.5:** ESCOLA, J. P. L. et al. Macoffee: Sistema de monitoramento iot para dispositivos over-the-air. *Revista de Tecnologia Aplicada*, v. 10, n. 3, p. 33–47, 2022. ISSN 2237-3713.
- A.6:** SOUZA, U. B. de et al. Empirical mode decomposition applied to acoustic detection of a cicadid pest. *Computers and Electronics in Agriculture*, v. 199, p. 107181, 2022. ISSN 0168-1699.
- A.7:** ESCOLA, J. P. L.; SOUZA, U. B. d.; BRITO, L. d. C. Discrete wavelet transform in digital audio signal processing: A case study of programming languages performance analysis. *Computers and Electrical Engineering*, v. 104, p. 108439, 2022. ISSN 0045-7906.
- A.8:** SOUZA, U. B. de et al. Bidirectional EMD-RLS: Performance analysis for denoising in speech signal. *Journal of Computational Science*, v. 74, p. 102181, 2023. ISSN 1877-7503.

Como mencionado, essas publicações são o resultado da colaboração produtiva entre uma equipe de pesquisa e pesquisadores parceiros, atestando os avanços significativos no campo do manejo de insetos-praga em lavouras cafeeiras. A sinergia resultante permitiu a combinação de diferentes competências e perspectivas, enriquecendo o trabalho e estabelecendo uma base sólida para futuros estudos e colaborações na área. Ademais, a relevância e a contribuição desta pesquisa para o avanço do conhecimento na área são evidenciadas pelas publicações, listadas, em revistas de alto fator de impacto e pela originalidade. Até o momento, conforme identificado em um extenso levantamento bibliográfico, não há registros de estudos que combinem a PFE e a HHT para a análise de sinais acústicos, seja utilizando vetores de *features* definidos pelas energias, seja por vetores definidos pelas frequências instantâneas dispostas conforme a EB, para a finalidade proposta.

Adicionalmente, até a data de submissão desta tese à banca examinadora, foram registradas 38 citações (excluindo as autocitações) aos artigos publicados, conforme verificado na plataforma *ResearchGate*. Esse número corrobora a relevância e o impacto desta pesquisa no cenário acadêmico.

1.6 Organização do trabalho

Para proporcionar uma compreensão detalhada do proposto, a estrutura desta tese foi organizada da seguinte maneira:

O Capítulo 2 aborda o estado da arte para o manejo de cigarras e as tecnologias empregadas nesse processo. Além disso, apresenta uma breve revisão da literatura que contempla a HHT, a PFE e os detalhes utilizados para a extração de características de sinais acústicos aplicada no sistema proposto.

O Capítulo 3 é dedicado aos detalhes do sistema proposto e aos algoritmos desenvolvidos para a sua aplicação. No Capítulo 4, são apresentados os ensaios e resultados, além de materiais, métodos e discussões.

Finalmente, o último capítulo traz as conclusões e menciona possíveis trabalhos futuros.

2 Revisão de Conceitos

Neste capítulo, é apresentada uma revisão bibliográfica focada nas metodologias recentes empregadas no manejo de insetos-praga em lavouras cafeeiras. O objetivo é elucidar as práticas atuais e as estratégias de controle de pragas, proporcionando um panorama detalhado das técnicas convencionais e inovadoras utilizadas no campo. Além disso, também são abordadas as tecnologias emergentes que empregam sinais acústicos para lidar com insetos em lavouras. O intuito é explorar a intersecção entre a entomologia (ramo da biologia que estuda os insetos) e a acústica, discutindo como os avanços na tecnologia acústica podem ser aplicados para melhorar o manejo de pragas. Define-se por manejo integrado de pragas a metodologia que utiliza análises de custo benefício para a tomada de decisões.

Uma revisão concisa, porém abrangente, dos conceitos fundamentais da HHT também é apresentada. Esta revisão serve como uma base sólida para a compreensão do sistema proposto na tese, permitindo uma melhor apreciação das suas nuances técnicas e do seu potencial impacto.

Finalmente, o capítulo conclui com a introdução de outros conceitos relacionados ao sistema proposto. O objetivo é fornecer uma compreensão mais completa do contexto em que o sistema opera, bem como das teorias e práticas que o embasam.

Em resumo, este capítulo serve como uma introdução abrangente e detalhada aos vários conceitos que embasam a tese, preparando o terreno para uma discussão mais aprofundada e focada nos capítulos subsequentes.

2.1 Revisão da Literatura sobre Técnicas e Desafios para Monitoramento de pragas em Lavouras

Nesta seção, apresenta-se uma versão adaptada e atualizada do artigo científico, publicado sob o título “*Estado da arte no monitoramento acústico de Cicadidae em lavouras de café*” (ESCOLA et al., 2021), que compõe a pesquisa em questão.

Foram examinados vários artigos que discutem temas ligados ao rastreamento e identificação das cigarras em diferentes habitats. O foco principal dessas análises foi compreender a relação entre os processos de monitoramento e a aplicação de tecnologias avançadas, como *softwares* e equipamentos tecnológicos. O objetivo era determinar até que ponto os agricultores incorporam essas ferramentas em suas práticas agrícolas, especialmente quando cultivam plantas suscetíveis às cigarras como pragas. Além disso, buscou-se

fazer um panorama atual sobre as iniciativas e soluções propostas para enfrentar essa questão.

2.1.1 Particularidades Bioecológicas das Cigarras

A emissão de sinais acústicos é uma característica distintiva das cigarras, sendo esta capacidade restrita aos machos, que possuem um órgão específico para tal. Pringle (1954) foi pioneiro em detalhar a anatomia e fisiologia deste processo. O som é produzido através da deformação do tímalo, uma estrutura elástica situada dorso-lateralmente no abdome. Internamente, espaços preenchidos por ar amplificam o som, atuando como uma caixa de ressonância. A natureza do sinal emitido é determinada por diversos fatores, incluindo a morfologia do tímalo, a frequência de sua deformação e os movimentos abdominais durante a emissão. Cada espécie de cigarra possui um sinal acústico único, variando em frequência desde valores próximos a 1 kHz até ultrassônicos de cerca de 25 kHz, conforme observado por Sueur (2001). Por exemplo, a frequência dominante emitida pela espécie objeto de estudo nesta tese, a *Quesada gigas*, pode variar de acordo com as diferentes regiões onde a espécie pode ser encontrada, conforme Tabela 1. Além disso, a intensidade do sinal é notável, podendo, em algumas espécies, ultrapassar 100 dB (VILLET, 1987). Esta especificidade sonora é útil para a identificação taxonômica, avaliação da biodiversidade e estimativas populacionais (SUEUR, 2001).

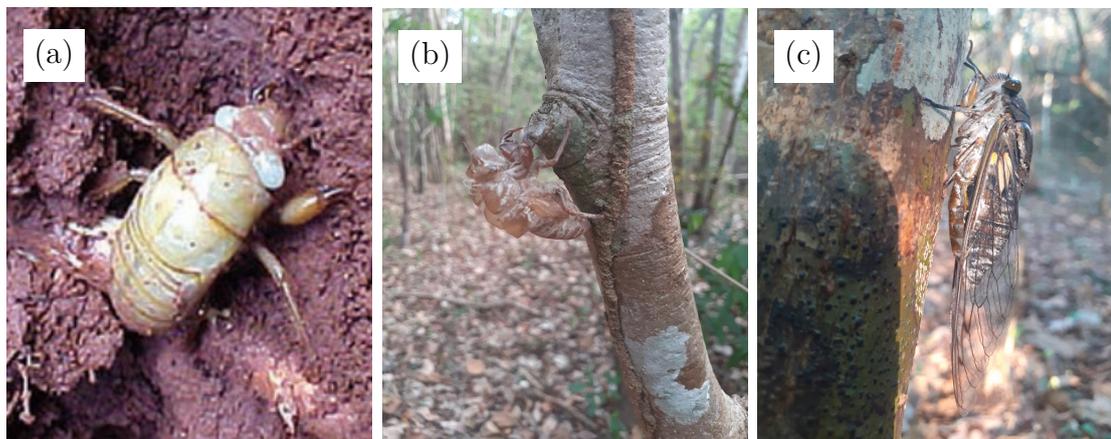
Tabela 1 – Frequências dominantes dos sons emitidos por *Quesada gigas* e as respectivas localidades de registro.

Referência	Frequência (Hz)	Localidade
(BOULARD, 1996)	2 600	Guiana Francesa
(SANTIS; URTEAGA; BOLCATTO, 2006)	1 290	Argentina
(SUEUR, 2008)	2 240	México
(MACCAGNAN, 2008)	1 705	SP/Brasil
(MACCAGNAN, 2013)	2 437	GO/Brasil

Fonte: Elaborada pelo autor.

A função primordial do sinal acústico, conforme mencionado por Claridge (1985), é atrair fêmeas para o acasalamento. Posteriormente, as fêmeas ovipositam no interior de ramos aéreos de plantas (JUNIOR et al., 2012). As ninfas emergentes se dirigem ao solo, buscando raízes para se alimentar de seiva. Durante anos, elas permanecem subterrâneas, junto às raízes, até se aproximarem da fase adulta. Neste estágio, retornam à superfície, aderindo-se a substratos verticais para passar pela metamorfose. Ao final deste processo, deixam para trás sua última exúvia, conforme descrito por Triplehorn, Johnson e Borror (2005). Seguem na Figura 1 as três fases da *Quesada gigas*.

Figura 1 – As três fases da *Quesada gigas*. (a) Ninfa de *Quesada gigas* localizada próxima à raiz de uma planta; (b) Exúvia; e (c) *Quesada gigas* em sua fase adulta.



Fonte: A imagem (a) foi extraída de (SOUZA; REIS; SILVA, 2007). As imagens (b) e (c) foram fornecidas pelo membro do grupo de pesquisa Douglas H. B. Maccagnan.

2.1.2 Monitoramento Manual

Diversos estudos têm se dedicado ao monitoramento e detecção das cigarras em variados ambientes, e muitos deles ainda se baseiam em técnicas manuais. Ao longo dos anos, diferentes metodologias foram propostas e aplicadas. Por exemplo, no final do século XX, Gonçalves e Faria (1989) focaram na eficácia de inseticidas granulados para controlar ninfas móveis em cafeeiros. Utilizando observação direta e contagem manual de insetos, eles abriram trincheiras aleatoriamente nos talhões, peneirando o solo para coleta e contagem de ninfas, um método que, embora trabalhoso, mostrou-se eficaz na identificação de infestações.

Reis e Souza (1991) e Martinelli et al. (1998) indicam que a presença de cigarras pode ser detectada observando-se os sintomas nas plantas, como clorose das folhas e queda precoce. Estes sintomas são indicativos da ação das cigarras, que sugam a seiva das plantas, enfraquecendo-as. Martinelli e Zucchi (1997) utilizaram armadilhas de ferro cobertas com tela de nylon, aliadas a coletas manuais para o monitoramento. Tal combinação proporcionou uma abrangência ampliada na obtenção de dados.

Já Fornazier e Rocha (2000) analisaram a eficácia de diferentes aplicações de inseticidas, fazendo covas sob as plantas para contagem manual das ninfas. Este método permitiu uma avaliação mais precisa da população inicial de ninfas e dos resultados após a aplicação dos inseticidas.

Almeida (2004) também adotou a coleta e contagem manual, após várias visitas a regiões produtoras em São Paulo. O autor destacou o grande dispêndio de tempo que essa técnica manual requer, mas também sua eficácia na detecção de infestações. Santos e Martinelli (2007) registraram uma espécie de cigarras em Tapiratiba, SP, coletando

exemplares manualmente com rede entomológica, uma ferramenta tradicional em estudos entomológicos.

Souza, Reis e Silva (2007) recomendam o método do entrincheiramento para monitorar infestações em cafezais. Este método envolve a escavação de covas nas plantações à procura de ninfas nas raízes. Após a escavação, as ninfas capturadas são contadas e o resultado é multiplicado por dois, considerando que a escavação é feita apenas de um lado da planta. Conforme recomendado pelos autores, em situações onde mais de 35 ninfas são encontradas, o controle químico deve ser realizado.

Lunz et al. (2010), por sua vez, inovaram ao empregar um implemento tratorizado para raspagem de solo, facilitando o processo de busca por ninfas. Maccagnan et al. (2014) detectaram cigarras observando exúvias presas ao tronco das árvores e galerias de ninfas no sistema radicular, enquanto Hou et al. (2015) monitoraram através da escavação em diferentes tipos de plantas, contando manualmente as ninfas a cada 10 cm de profundidade do solo. Sato e Sato (2015) monitoraram duas espécies de cigarras no Japão, coletando exúvias manualmente e usando uma rede para coleta em alturas elevadas.

Em resumo, apesar dos avanços tecnológicos, muitos estudos ainda se baseiam em técnicas manuais para monitorar e detectar cigarras. Estes métodos, embora trabalhosos, têm se mostrado eficazes ao longo dos anos, evidenciando a importância de métodos tradicionais no campo da pesquisa entomológica. O objetivo primordial desses monitoramentos e contagens é determinar a necessidade e o momento adequado para a aplicação de agrotóxicos, visando controlar a população de cigarras e minimizar os danos causados por elas às plantações.

2.1.3 Monitoramento por *Software*

Diversos estudos têm explorado técnicas modernas, especialmente *softwares*, para monitorar e detectar cigarras em diferentes ambientes. Estas técnicas digitais oferecem uma abordagem mais precisa e eficiente em comparação com os métodos manuais tradicionais. A seguir estão relacionadas algumas abordagens disponíveis na literatura que utilizam tecnologias diversas para a detecção e monitoramento de cigarras.

Ohya (2004) empregou a técnica de Análise de Componentes Principais (*Principal Component Analysis* - PCA) com o objetivo de analisar e diferenciar os sons emitidos por cigarras. Em sua pesquisa, o foco foi especificamente três espécies de cigarras que são frequentemente encontradas no Japão. Os resultados indicaram que, através da PCA, é possível não apenas identificar, mas também distinguir claramente essas espécies com base em suas assinaturas acústicas únicas.

Soares et al. (2008) utilizaram interpolação de unidades amostrais para analisar a distribuição de ninfas em plantações de paricá. A área analisada foi dividida para determinar

pontos de coleta de amostras. Embora a contagem tenha sido feita manualmente, os dados coletados foram usados para gerar mapas de dispersão com a ajuda do *software* ArcGIS, fornecendo uma visão clara da incidência das cigarras na área estudada.

Chen e Shiao (2008) apresentaram duas novas espécies de cigarras, capturando seus sons com um gravador digital e um microfone. O espectro de frequências foi analisado para diferenciar as espécies, mostrando a importância da análise acústica na taxonomia.

Cole (2008) também utilizou técnicas acústicas, capturando sons de cigarras com um microfone e gravador DAT. As frequências foram analisadas por espectrogramas gerados a partir da Transformada Rápida de Fourier (*Fast Fourier Transform* - FFT), permitindo uma comparação detalhada entre os sons de duas espécies de cigarras.

Lee (2008) realizou um levantamento das espécies de cigarras na península coreana, capturando e analisando seus sons por oscilogramas e sonogramas. Os dados coletados foram usados não para detecção, mas para diferenciar as espécies.

Sueur et al. (2008) propuseram uma solução econômica e não invasiva para o desenvolvimento de inventários *Rapid Biodiversity Assessments* (RBA). Utilizando gravações sonoras, eles aplicaram técnicas como o índice de Shannon e a Transformada de Fourier de Tempo Curto (*Short Time Fourier Transform* - STFT) para estimar populações de diferentes espécies.

Seabra, Quartau e Bruford (2009) focaram na variação de espécies de cigarras na região do Mar Mediterrâneo. Embora tenham abordado a similaridade morfológica e acústica entre as espécies *Cicada barbara* e *Cicada orni*, o estudo se concentrou mais na variação genética e geográfica das espécies. Os espécimes foram coletados manualmente ou fornecidos por instituições parceiras e, posteriormente, analisados em laboratório. *Softwares* específicos foram empregados para os estudos estatísticos.

Sanborn, Heath e Heath (2009) analisaram os sons emitidos pela cigarra *Beameria venosa*, destacando a vantagem evolutiva de sua alta frequência, que é inaudível para muitos de seus predadores. As gravações foram feitas em diferentes cidades dos EUA, utilizando um dispositivo *Uher* 4000 e um microfone colocado próximo aos insetos.

Dardar, Belal e Basheer (2013) coletaram cigarras adultas manualmente e também utilizaram armadilhas em formato de “tenda”. Os sons coletados foram analisados pelo *software* *Speech Analyzer*, permitindo uma análise detalhada dos ciclos de frequência.

Hill e Marshall (2013) utilizaram um gravador digital, um microfone e um GPS manual para capturar e analisar os sons das cigarras, enquanto Aide et al. (2013) desenvolveram um sistema de coleta de dados baseado em gravações de áudio, utilizando *softwares* e uma estação de monitoramento remota alimentada por energia solar. O processamento dos arquivos era feito por meio de uma STFT. A detecção foi realizada por um algoritmo

que utilizava *Hidden Markov Models* (HMMs), mostrando a aplicação prática e a eficiência da combinação de técnicas acústicas e análise de *software*.

Lampson et al. (2013) destacaram a identificação de insetos pelo uso dos sons que eles emitem. O objetivo principal era economizar tempo e custos com defensivos agrícolas. Em vez de capturar sons acústicos, o estudo utilizou um acelerômetro para detectar sinais vibratórios propagados através do substrato. Foram aplicados métodos de identificação como *Gaussian Mixture Model* (GMM) e *Probabilistic Neural Network* (PNN) para analisar os sinais. Os testes, realizados em laboratório, mostraram uma alta taxa de detecção, evidenciando a eficácia do método.

Chiavacci, Bednarz e McKay (2014) empregaram armadilhas com câmeras para estudar a relação entre a densidade populacional de cigarras e a escolha de locais de nidificação por papagaios, seus predadores naturais. Apesar do uso de tecnologia, a contagem era realizada manualmente a cada três dias, categorizando as cigarras adultas e suas exúvias.

Noda et al. (2016) empregaram uma SVM na classificação acústica de 88 espécies de cigarras. Utilizando *Mel* e *Linear Frequency Cepstral Coefficients* (MFCCs e LFCCs, respectivamente) para extrair características dos sinais, uma impressionante taxa de sucesso de mais de 99% na identificação das espécies foi obtida. Os autores mencionam dispositivos para controle de pragas e estudos biológicos, mas deixam em aberto para trabalhos futuros.

Prince et al. (2019) apresentaram um conjunto de algoritmos de detecção acústica para monitorar a ecolocalização de morcegos, espécies de cigarras ameaçadas e atividades predatórias em reservas naturais.

Por fim, recentemente, Escola et al. (2020a), Escola et al. (2020b) e Escola et al. (2021) usaram a WT para mapear as características de tempo-frequência dos sinais de áudio combinados com uma SVM para detecção acústica de *Quesada gigas* em lavouras de café, obtendo precisão acima de 96%.

A evolução das técnicas de monitoramento, com a integração de *softwares* e dispositivos tecnológicos, transformou o estudo e a interação com as cigarras. Tais inovações facilitam a coleta e análise de dados, além de auxiliar em tomadas de decisão, quando necessárias, para combates mais eficientes às pragas. É importante destacar que a otimização desses processos não só possibilita a redução de custos, mas também promove a minimização de impactos ambientais, conduzindo a uma abordagem mais sustentável e responsável no manejo desses insetos.

2.1.4 Discussões

Como mencionado anteriormente, a agricultura moderna tem passado por transformações significativas sob a influência de conceitos inovadores como *Smart Farm*, Agricultura Digital, entre outros. Estes avanços tecnológicos têm reconfigurado as práticas agrícolas, levando à necessidade de avaliar a eficácia das técnicas de monitoramento, sejam elas tradicionais ou automatizadas. A [Tabela 2](#), que apresenta a lista de trabalhos correlatos, abordados nas duas subseções anteriores, serve como uma referência visual para esta discussão. Nesta tabela, as siglas TM, SDC e SL são utilizadas para representar Técnicas Manuais, uso de *Softwares* ou Dispositivos em Campo e uso de *Softwares* em Laboratório, respectivamente. A análise evidencia que, mesmo diante dos progressos mencionados, a implementação de dispositivos para monitoramento em campo apresenta uma prevalência ainda reduzida. De todos os estudos examinados, somente uma fração recorre ao uso de SDC. Para ser mais preciso, dos cinco trabalhos que mencionam o uso de SDC, apenas quatro se dedicam ao desenvolvimento de dispositivos automatizados para enfrentar os desafios propostos, e é notável que três desses estudos referenciam o mesmo dispositivo ([ESCOLA et al., 2020a](#); [ESCOLA et al., 2020b](#); [ESCOLA et al., 2021](#)). No entanto, há uma concordância unânime quanto à persistência das técnicas manuais, seja para monitoramento, controle ou para coleta de dados, como áudios ou imagens.

A preocupação ambiental é uma temática recorrente nos estudos sobre controle de cigarras, como evidenciado por [Fornazier e Rocha \(2000\)](#). Os riscos associados ao uso de defensivos principalmente em áreas inclinadas, como montanhas, ressaltam a necessidade de métodos mais sustentáveis e menos invasivos. Nesse contexto, a importância de predadores naturais no manejo de insetos-praga é enfatizada por [Almeida \(2004\)](#) e [Sazima \(2009\)](#), que destacam aves como o gavião *Milvago chimchima*, o gavião-sovi (*Ictinia plumbea*), o frango-d'água (*Gallinula chloropus*) e o socozinho (*Butorides striata*) como predadores naturais de cigarras em seus diferentes estágios.

Apesar dos avanços tecnológicos, a maioria dos estudos ainda recorre a técnicas manuais, seja por observação direta, escavação ou audição de sons. No entanto, há uma crescente atenção às técnicas acústicas, como observado nos trabalhos de [Ohya \(2004\)](#), [Chen e Shiao \(2008\)](#), [Cole \(2008\)](#), [Lee \(2008\)](#) e [Hill e Marshall \(2013\)](#). Estes, registram a aplicação de processamento de áudio para fins de identificação de espécies em laboratório, mas não indicam qualquer procedimento de automação. Por outro lado, [Sueur et al. \(2008\)](#), [Lampson et al. \(2013\)](#), [Aide et al. \(2013\)](#), [Noda et al. \(2016\)](#), [Prince et al. \(2019\)](#) e ([ESCOLA et al., 2021](#)) sublinham a viabilidade de abordagens não invasivas e automatizadas.

A criação de dispositivos que combinem PDS e técnicas de reconhecimento de padrões para monitoramento de cigarras em lavouras de café, conforme discutido por [Escola et al. \(2020b\)](#) e [Escola et al. \(2021\)](#), representam inovação tecnológica no campo da agricultura moderna e são uma possível solução para automatização desse processo.

Tabela 2 – Lista de trabalhos correlatos. As siglas TM, SDC e SL significam Técnicas Manuais, uso de *Softwares* ou Dispositivos em Campo e uso de *Softwares* em Laboratório, respectivamente.

Referência	TM	SDC	SL
(GONÇALVES; FARIA, 1989)	Sim	Não	Não
(REIS; SOUZA, 1991)	Sim	Não	Não
(MARTINELLI; ZUCCHI, 1997)	Sim	Não	Não
(FORNAZIER; ROCHA, 2000)	Sim	Não	Não
(OHYA, 2004)	Sim	Não	Sim
(SOUZA; REIS; SILVA, 2007)	Sim	Não	Não
(SANTOS; MARTINELLI, 2007)	Sim	Não	Não
(LEE, 2008)	Sim	Não	Sim
(COLE, 2008)	Sim	Não	Sim
(CHEN; SHIAO, 2008)	Sim	Não	Sim
(SOARES et al., 2008)	Sim	Não	Sim
(SUEUR et al., 2008)	Sim	Não	Sim
(SEABRA; QUARTAU; BRUFORD, 2009)	Sim	Não	Sim
(SANBORN; HEATH; HEATH, 2009)	Sim	Não	Sim
(LUNZ et al., 2010)	Sim	Não	Não
(DARDAR; BELAL; BASHEER, 2013)	Sim	Não	Sim
(HILL; MARSHALL, 2013)	Sim	Não	Sim
(LAMPSON et al., 2013)	Sim	Não	Sim
(AIDE et al., 2013)	Sim	Sim	Sim
(MACCAGNAN et al., 2014)	Sim	Não	Não
(CHIAVACCI; BEDNARZ; MCKAY, 2014)	Sim	Não	Sim
(HOU et al., 2015)	Sim	Não	Não
(SATO; SATO, 2015)	Sim	Não	Não
(NODA et al., 2016)	Sim	Não	Sim
(PRINCE et al., 2019)	Sim	Sim	Sim
(ESCOLA et al., 2020a)	Sim	Sim	Sim
(ESCOLA et al., 2020b)	Sim	Sim	Sim
(ESCOLA et al., 2021)	Sim	Sim	Sim

Fonte: Elaborada pelo autor.

Dispositivos como o *Raspberry Pi* (RICHARDSON; WALLACE; WALLACE, 2012), ESP8266 e ESP32 (CAMERON, 2020), são ferramentas promissoras para acomodar *softwares* de redes neurais diretamente no campo, dada sua eficiência energética e capacidade de processamento. A energia pode ser fornecida por baterias ou placas fotovoltaicas, dependendo da localização e das necessidades do dispositivo.

Em resumo, a integração da tecnologia na agricultura moderna é evidente na evolução das técnicas de monitoramento e controle de cigarras em lavouras de café. A transição de métodos manuais tradicionais para abordagens automatizadas e não invasivas não apenas otimiza o monitoramento, mas também reduz os impactos ambientais. A combinação de dispositivos eletrônicos, PDS e a valorização de predadores naturais ilustra a inovação contínua neste domínio. Pesquisas e adaptações contínuas dessas tecnologias são cruciais para abordar os desafios do setor e assegurar uma produção agrícola robusta e

eficiente.

Em complemento aos trabalhos citados nesta seção, no artigo intitulado “*Empirical mode decomposition applied to acoustic detection of a cicadid pest*” (SOUZA et al., 2022), desenvolvido como resultado direto desta tese, foi proposto um sistema para automatização do monitoramento de cigarras empregando o PDS através da primeira etapa da HHT, a EMD. Esse sistema e os resultados obtidos são discutidos no [Capítulo 4](#).

2.2 Transformada de Hilbert-Huang

O PDS acústicos é um campo de estudo que explora a manipulação e análise de informações sonoras, com propósitos variados, desde a redução de ruído no interior de veículos (SINGH; MOHANTY, 2018), música (JO et al., 2015) até o reconhecimento de fala (BENZEGHIBA et al., 2007). Os sinais acústicos para estas análises são geralmente capturados por meio de dispositivos como microfones, hidrofones, ou através de técnicas de campo como *far-field* e *near-field* (WEI; RODRÍGUEZ-FORTUÑO, 2020). A qualidade do sinal captado pode ser influenciada por diversos fatores, como ambiente de gravação, qualidade do dispositivo de captação e características inerentes do som original. No que se refere ao processamento desses sinais, existem diversas ferramentas disponíveis na literatura, como filtros digitais, autocorrelação e transformada de Fourier (ZÖLZER, 2022). Recentemente, a HHT tem sido apontada como uma alternativa promissora (CHEN et al., 2021; CUOMO; BOCCACCIO; MEO, 2023).

A HHT, como proposto por Huang (1996), é composta por duas etapas fundamentais. A primeira é a EMD, que atua em sequências de extremos locais para extrair a energia local intrínseca, inerente às escalas de tempo do sinal (HUANG et al., 1998). Este processo resulta em componentes oscilatórias denominadas Funções de Modo Intrínseco (*Intrinsic Mode Functions* - IMFs), que são caracterizadas pela ortogonalidade e independência espectral. Cada IMF representa os detalhes do sinal em uma escala ou faixa de frequência específica, oferecendo uma análise detalhada e individualizada dos elementos que constituem o sinal (WU; HUANG, 2005). A segunda etapa do processo é a análise espectral, que é realizada através da Transformada de Hilbert (*Hilbert Transform* - HT). Este procedimento viabiliza a obtenção da representação tempo-frequência do sinal, proporcionando uma visão detalhada da evolução das frequências ao longo do tempo. Combinadas, estas duas etapas - a EMD e a HT - permitem uma análise robusta e detalhada de sinais, especialmente aqueles que são não lineares e não estacionários (HUANG et al., 1998; HUANG et al., 2003), características comuns em sinais acústicos.

A maioria dos avanços e resultados relacionados à EMD, disponíveis na literatura, são derivados de experimentos empíricos (HUANG; WU, 2008; LIU et al., 2021). Isso atesta a eficácia do método para o processamento de sinais e evidencia novas oportunidades

de pesquisa. A prevalência de experimentação empírica é amplamente atribuída ao fato de que a fundamentação matemática da EMD ainda não está totalmente consolidada (SOUZA; ESCOLA; BRITO, 2022).

O método é similar às decomposições tradicionais de Fourier ou *Wavelet* (AL-BADDAI et al., 2017) e pode ser interpretado como uma forma de decomposição *wavelet* em que sub-bandas são produzidas conforme necessário durante a extração das IMFs (BOUCHIKHI et al., 2008). As principais propriedades citadas na literatura incluem: completude (HUANG et al., 1998), deslocamento temporal (ZHANG; GAI, 2006), base adaptativa (KIZHNER et al., 2006; CHU; FAN; HUANG, 2014), ortogonalidade (PASCOAL; SOARES; VELTCHEVA, 2005; NIU et al., 2021), convergência (KIZHNER et al., 2006; GE et al., 2018), e filtragem (WU; HUANG, 2004; FLANDRIN; GONÇALVÈS, 2004; FLANDRIN; GONÇALVÈS; RILLING, 2005; WU; HUANG, 2005).

Um tratamento mais aprofundado sobre a evolução da HHT, os desafios encontrados e as soluções propostas por pesquisadores ao longo dos anos, foi abordado no artigo científico “*A survey on Hilbert-Huang transform: Evolution, challenges and solutions*” (SOUZA; ESCOLA; BRITO, 2022), relacionado a esta pesquisa. Nesse contexto, esta tese destaca aspectos fundamentais e cruciais, indispensáveis para a compreensão integral e detalhada do sistema proposto.

2.2.1 Definição de IMF e o algoritmo da EMD

Na EMD, as funções de base utilizadas são as IMFs, que são funções senoidais com amplitude e frequência variáveis, e diferentemente de métodos como Fourier e *Wavelets*, não são predeterminadas, mas sim adaptativas e dependentes do próprio sinal em análise.

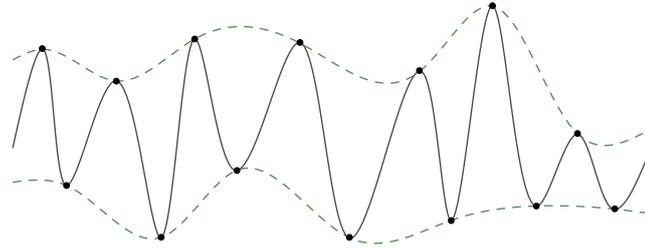
De acordo com Huang et al. (1998), uma função é considerada uma IMF quando cumpre as seguintes condições:

- (C1) o número de extremos e zeros deve ser igual ou diferir, no máximo, por um; e
- (C2) em qualquer ponto, o valor médio da envoltória definida pelos máximos locais (envoltória superior) e a envoltória definida pelos mínimos locais (envoltória inferior) é zero.

É importante ressaltar que uma envoltória é uma curva suave (CARMO, 2017) que envolve o sinal de forma a conter o menor número possível de oscilações. Essa curva deve estar localizada acima ou abaixo do sinal, exceto nos pontos de tangência (YANG et al., 2013), como ilustrado na Figura 2.

Considere, por exemplo, a função definida pela Equação (2.1) e representada na Figura 3. É notável que esta função cumpre as condições C1 e C2, as quais estabelecem

Figura 2 – Representação das envoltórias superior e inferior (linhas tracejadas) de um sinal (linha contínua).

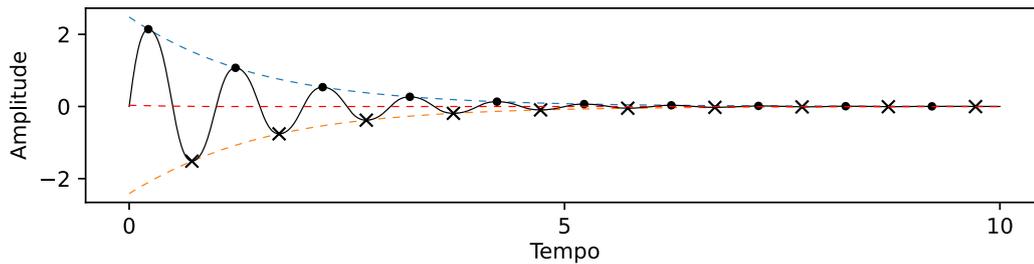


Fonte: Produzido pelo autor.

as características intrínsecas de uma IMF. Dessa forma, pode-se afirmar que esta função é, de fato, uma IMF.

$$x(t) = 3 \cdot 2^{-t} \cdot \sin(\sin(2\pi t)), \quad t \in [0, 10]. \quad (2.1)$$

Figura 3 – IMF perfeita, definida pela Equação (2.1).



Fonte: Produzido pelo autor.

O processo de decomposição é estruturado através de uma série de etapas, descritas a seguir (HUANG, 1996; HUANG et al., 1998; HUANG; SHEN; LONG, 1999):

P.1: Determine os máximos e mínimos do sinal para obter as envoltórias superior e inferior, respectivamente, por meio de interpolação spline cúbica (SCHUMAKER, 2007), como ilustrado na Figura 2;

P.2: Calcule a média $m_{1,1}(t)$ entre as envoltórias superior e inferior para determinar a proto-IMF $h_{1,1}(t) = x(t) - m_{1,1}(t)$. Se $h_{1,1}(t)$ satisfaz as condições **C1** e **C2**, ela é considerada a primeira IMF $c_1(t)$. Caso contrário, $h_{1,1}(t)$ toma o lugar do sinal original e o processo, chamado de Processo de Peneiração (*Sifting Process* - SP), é repetido até que a proto-IMF $h_{1,k}(t)$ se torne uma IMF, determinando assim $c_1(t) = h_{1,k}(t)$;

P.3: O resíduo é determinado pela diferença $r_1(t) = x(t) - c_1(t)$;

P.4: Considere o resíduo como o sinal original e repita os passos *P.1*, *P.2* e *P.3* para a extração das outras IMFs $c_i(t)$, $i = 2, \dots, n$. O processo é então repetido enquanto o resíduo não é uma função monótona ou possui mais que três extremos.

Ao final da extração, o sinal pode ser reconstruído pela soma das n IMFs com o resíduo $r_n(t)$, conforme [Equação \(2.2\)](#). O resíduo, também chamado de componente de tendência ([RATO; ORTIGUEIRA; BATISTA, 2008](#); [DIOP; ALEXANDRE; BOUDRAA, 2010](#)), pode ser desconsiderado se os aspectos físicos do sinal não o exigirem ([ZHANG; GAI, 2006](#)), uma vez que se trata de uma componente de frequência baixa ou nula.

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t). \quad (2.2)$$

A completude do processo de reconstrução de um sinal é verificada tanto teoricamente, através da identidade da [Equação \(2.2\)](#), quanto numericamente, pela comparação entre o sinal reconstruído e o sinal original. Geralmente, essa diferença é extremamente pequena, com um erro máximo na ordem de grandeza entre 10^{-35} e 10^{-30} , conforme observado nos experimentos realizados nesta tese. Esses resultados corroboram as afirmações feitas por [Huang et al. \(1998\)](#) em seus próprios experimentos. Vale ressaltar que esse erro é atribuído principalmente a arredondamentos realizados durante o SP.

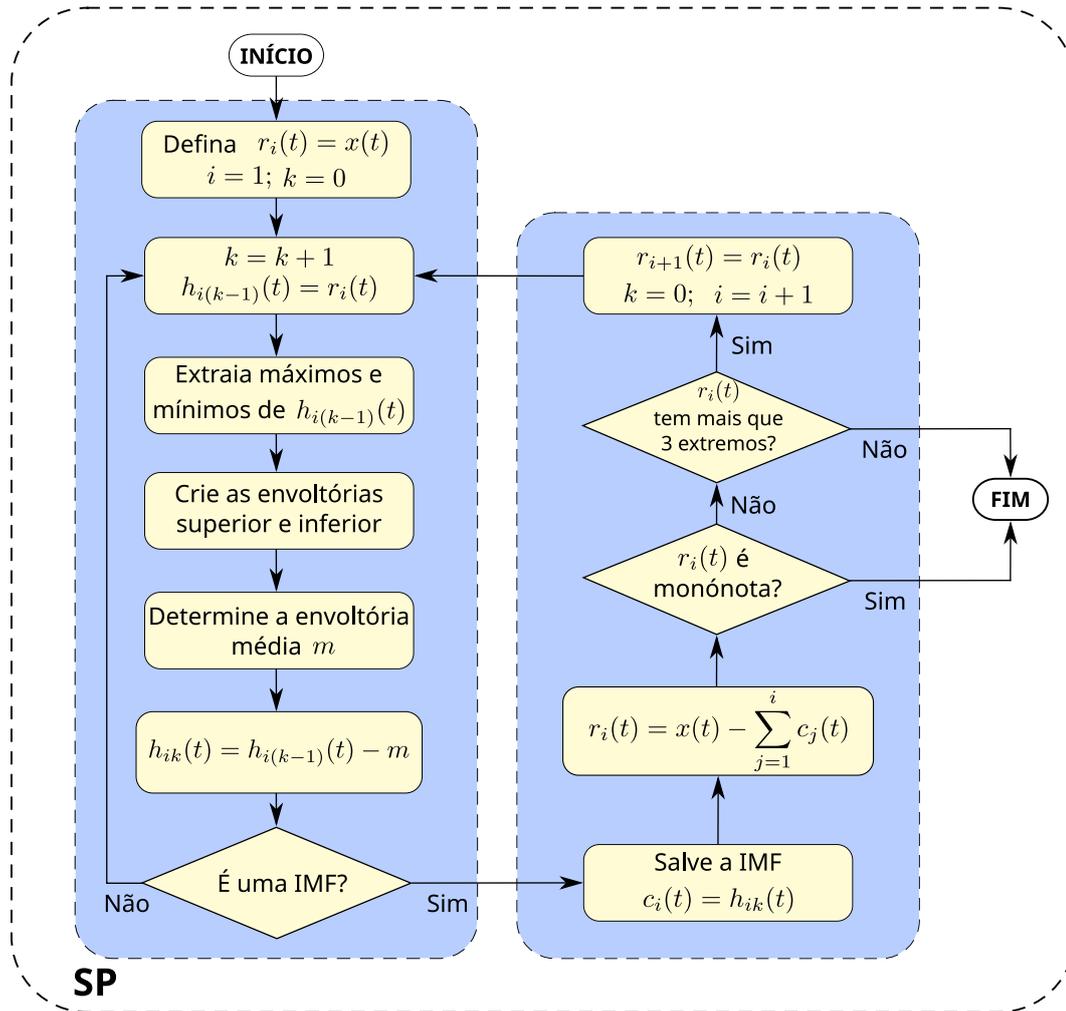
A [Figura 4](#) ilustra o algoritmo da EMD em detalhes por meio de um fluxograma. Esse diagrama esquemático oferece uma representação clara e intuitiva das etapas envolvidas no algoritmo.

Para melhor compreensão do algoritmo EMD, considere o seguinte exemplo do processo de decomposição. Seja $x(t)$ o sinal sintético definido pela [Equação \(2.3\)](#) e exibido na [Figura 5a](#).

$$x(t) = 5 \sin(2\pi \cdot 5 \cdot t) + 3 \sin(2\pi \cdot 1 \cdot t), \quad t \in [0, 6]. \quad (2.3)$$

Inicialmente, deve-se identificar todos os pontos de máximos e mínimos de $x(t)$, como ilustrado na [Figura 5b](#). Usando alguma técnica de interpolação, geralmente spline cúbica, cria-se as envoltórias superior e inferior, visualizadas na [Figura 5c](#). A média entre estas envoltórias define a envoltória média, destacada em vermelho. Em seguida, calcula-se a diferença entre o sinal original e essa envoltória média, obtem-se uma proto-IMF, retratada na [Figura 5d](#). Como esta proto-IMF satisfaz as condições **C1** e **C2**, evidenciado na [Figura 5e](#), a primeira IMF foi identificada, denotada por $c_1(t)$. O algoritmo processo para a próxima iteração, agora considerando o sinal residual $x(t) - c_1(t)$, representado na [Figura 5f](#).

Figura 4 – Fluxograma do algoritmo da EMD.



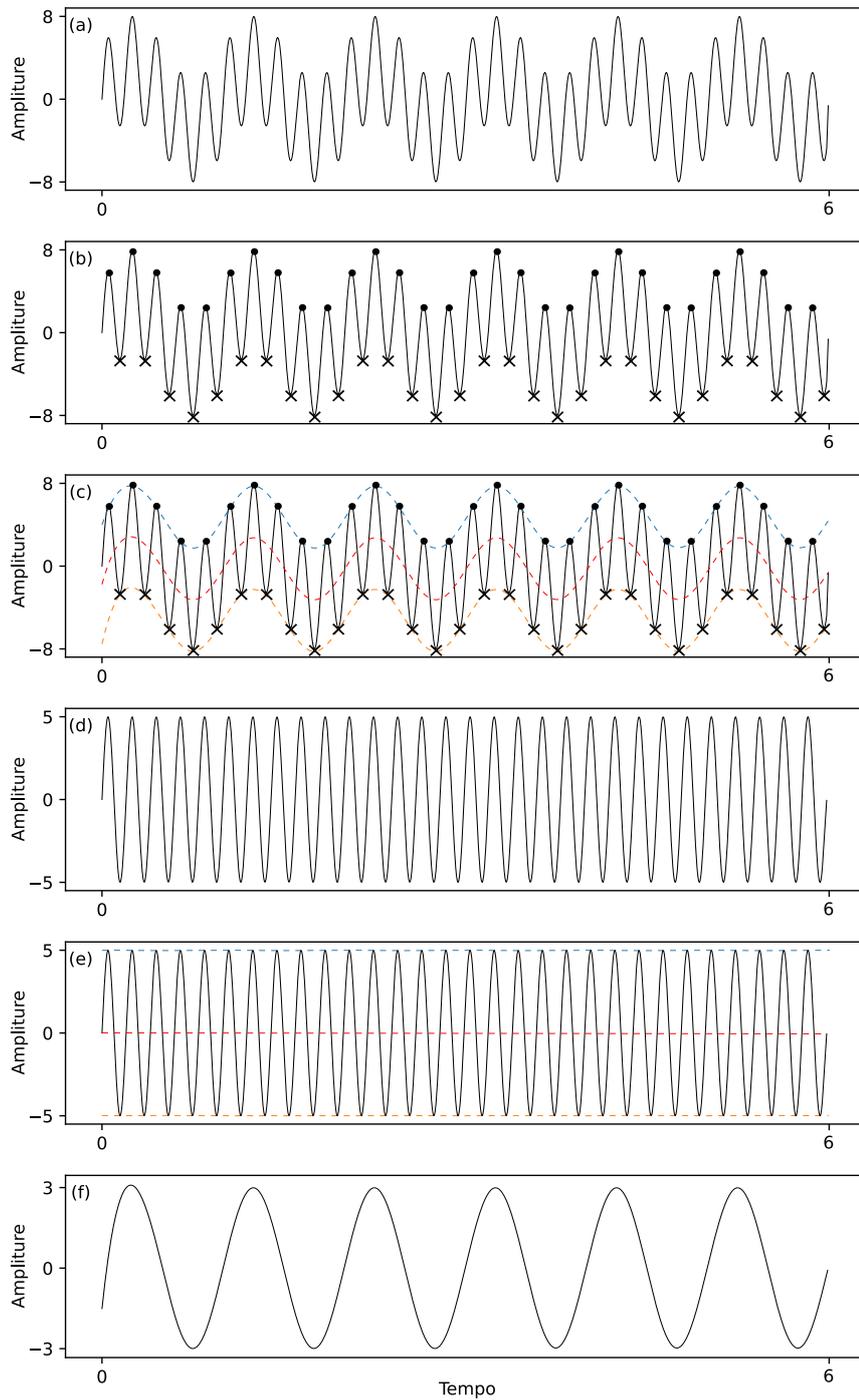
Fonte: Produzido pelo autor.

O uso de sinais sintéticos é comum na literatura para avaliar e entender métodos em um ambiente controlado, livre das variações e ruídos típicos de sinais reais. É importante ressaltar que o exemplo apresentado ilustra o processo de decomposição de uma função simples, demonstrando, passo a passo, como a técnica atua, visando oferecer uma clara compreensão da metodologia. No contexto de sinais reais, a situação torna-se mais complexa. Frequentemente, as proto-IMFs precisam ser avaliadas e reavaliadas múltiplas vezes antes que se possa identificar uma IMF verdadeira. Isso ocorre devido às irregularidades, variações e ruídos presentes nos sinais reais, que podem ocultar os padrões e compor o sinal de formas mais complexas.

2.2.2 Critérios de Parada da EMD

A média das envoltórias naturalmente converge para zero devido à construção do algoritmo. No entanto, para que isso ocorra efetivamente em todos os pontos, são necessárias um grande número de iterações. Na prática, determinar o momento ideal

Figura 5 – Exemplo de extração, passo a passo, da primeira IMF do sinal definido pela Equação (2.3).



Fonte: Produzido pelo autor.

para interromper o SP é realizado através de um critério de parada. Esse critério visa garantir que as componentes satisfaçam aproximadamente a definição de IMF, evitando iterações excessivas e fornecendo resultados satisfatórios em uma análise pós-decomposição (WANG et al., 2010). As questões relacionadas ao critério de parada do SP são de extrema importância para melhorar o desempenho do método e têm sido amplamente investigadas

na literatura (SOUZA; ESCOLA; BRITO, 2022).

Nas subseções seguintes, serão apresentados de forma sucinta os critérios de parada investigados no experimento proposto nesta tese. Optou-se por manter os nomes dos critérios em inglês e listá-los em ordem crescente de acordo com o ano de publicação.

Standard Deviation (SD)

Proposto por Huang et al. (1998), o SD foi o primeiro critério de parada (Equação (2.4)), baseado na análise de convergência de Cauchy, onde as diferenças quadradas entre duas proto-IMFs consecutivas visam limitar o desvio padrão entre as componentes. O SP é pausado quando $SD \leq \epsilon$, para algum $\epsilon > 0$ pré-definido.

$$SD = \sum_{t=0}^T \left[\frac{|h_{i,k-1}(t) - h_{i,k}(t)|^2}{h_{i,k-1}^2(t)} \right]. \quad (2.4)$$

Algumas variantes desse critério podem ser encontradas na literatura, como discutido por Huang e Wu (2008).

Simplified Stoppage Criterion (SSC)

Neste critério, o SP é interrompido quando o número de zeros e extremos das proto-IMFs se repetem por S iterações sucessivas e são equivalentes ou diferem no máximo por um (HUANG; SHEN; LONG, 1999), conforme mostrado nas Equações 2.5 - 2.7.

$$\overbrace{e[h_{i,k-S+1}(t)] = \dots = e[h_{i,k}(t)]}^S, \quad (2.5)$$

$$\overbrace{z[h_{i,k-S+1}(t)] = \dots = z[h_{i,k}(t)]}^S, \quad (2.6)$$

$$|z[h_{i,k}(t)] - e[h_{i,k}(t)]| \leq 1, \quad (2.7)$$

onde $k \geq S$, $e[\cdot]$ denota o número de extremos, $z[\cdot]$ o número de zeros e S o número de repetições a serem satisfeitas.

3-Threshold Criterion (TTC)

O critério TTC consiste em três entradas (θ_1 , θ_2 e α) e a função de avaliação $\sigma : \mathbb{R}_+ \rightarrow \mathbb{R}_+$ (Equação (2.8)).

$$\sigma(t) = \left| \frac{m(t)}{d(t)} \right|, \quad (2.8)$$

onde $m(t)$ é a envoltória média, $d(t) = [U(t) - L(t)]/2$, $U(t)$ é a envoltória superior e $L(t)$ a envoltória inferior da proto-IMF.

Neste caso, o SP deve ser iterado até que $\sigma(t) < \theta_1$, para uma fração $(1 - \alpha)$ do tempo total e $\sigma(t) < \theta_2$ para o tempo restante, garantindo pequenas flutuações globais na média ao considerar grandes desvios locais (RILLING; FLANDRIN; GONÇALVES, 2003).

Energy Difference Tracking Criterion (EDT)

O critério EDT opera de acordo com a ortogonalidade das IMFs. Junsheng, Dejie e Yu (2006) mostraram que, ao decompor um sinal, a variação de energia causada por uma iteração do SP é dada por Equação (2.9).

$$E_{err} = \left| \int h^2(t)dt - \int x(t)h(t)dt \right|. \quad (2.9)$$

Assim, quanto menor for E_{err} , melhor será a propriedade de ortogonalidade entre as IMFs. O SP termina quando o mínimo de E_{err} é encontrado ou quando $E_{err} < \epsilon$, para algum $\epsilon > 0$ pré-definido (BI et al., 2019).

Bandwidth Criterion (BWC)

Introduzido por Xuan, Xie e Peng (2007), este critério utiliza a largura de banda de frequência (Equação (2.10)) para determinar quando o SP deve parar.

$$B_f^2 = \int (\theta'_k(t) - \langle \omega \rangle)^2 a_k^2(t) dt, \quad (2.10)$$

com

$$\langle \omega \rangle = \int \theta'_k(t) a_k^2(t) dt. \quad (2.11)$$

As funções $a_k(t)$ e $\theta_k(t)$ são o módulo e o argumento, respectivamente, do sinal analítico composto pela proto-IMF de ordem k e sua Transformada de Hilbert, conforme descrito por Huang et al. (1998). Esses detalhes são apresentados na subseção 2.2.4.

O SP deve ser finalizado quando as seguintes condições são atendidas:

BWC 1: O critério TTC (Equação (2.8)) deve ser satisfeito ao usar entradas com valores altos, de modo que a proto-IMF corresponda aproximadamente à definição de IMF;

BWC 2: O mínimo de B_f^2 é encontrado.

Uma alternativa para acelerar a convergência do SP consiste em interrompê-lo quando a diferença entre a largura de banda de frequência de duas proto-IMFs consecutivas for suficientemente pequena (TABRIZI et al., 2014), conforme Equação (2.12). Nos

experimentos conduzidos para esta tese, tal estratégia não foi empregada, pois o objetivo era obter IMFs que aderissem integralmente às propriedades estabelecidas pelo critério. Alternativamente, foi estabelecido um limite máximo para o número de iterações e foram exploradas configurações que minimizassem as iterações excessivas.

$$\left| (B_f^2)_{h_{i,k}} - (B_f^2)_{h_{i,k-1}} \right| < \epsilon, \quad \epsilon > 0. \quad (2.12)$$

Resolution Factor Criterion (RFC)

Definido pela relação entre a energia do sinal no início do SP e a energia da envoltória média em cada iteração, o critério encerra o SP sempre que a relação exceder uma resolução R dB predefinida, ou seja, se a [Equação \(2.13\)](#) não for satisfeita. De acordo com [Rato, Ortigueira e Batista \(2008\)](#), o valor ideal de R pode variar de acordo com cada tipo de sinal.

$$10 \cdot \log_{10} \left(\frac{E_h}{E_m} \right) < R, \quad (2.13)$$

com $h = h_{i,0}(t)$ e $m = m_{i,k}(t)$.

Orthogonality Criterion (OC)

O critério OC usado neste trabalho é uma adaptação do proposto por [Li e Hongbing \(2009\)](#), que busca maximizar a ortogonalidade entre as IMFs e é dado por [Equação \(2.14\)](#).

$$OC = \left| \frac{\sum_{t=1}^N m_{i,k}(t) \cdot h_{i,k-1}(t)}{\sum_{t=1}^N m_{i,k}(t) \cdot (h_{i,k-1}(t) - m_{i,k}(t))} \right|. \quad (2.14)$$

O SP termina quando o OC está suficientemente próximo de 1, ou seja, $|OC - 1| < \epsilon$ com $\epsilon > 0$.

Valid Data Segment (VDS)

O segmento de dados válidos é o segmento de dados restante após a eliminação dos dados distorcidos perto das bordas do sinal, evitando a influência dos *end effects* ([CHEN et al., 2019](#)). O critério é dado pela [Equação \(2.15\)](#).

$$\|\tilde{m}_{k+1}\| < \delta, \quad (2.15)$$

onde $\|\cdot\|$ denota a norma Euclidiana, \tilde{m}_{k+1} o segmento de dados válido da $(k+1)$ -ésima envoltória média, ou seja, a envoltória média da k -ésima proto-IMF, e $\delta > 0$.

2.2.3 Ortogonalidade

Se comparadas duas a duas, todas as IMFs são localmente ortogonais. Essa propriedade é observada na prática, embora não seja garantida teoricamente, uma vez que as IMFs não são definidas de forma analítica (HUANG et al., 1998; HUANG; SHEN; LONG, 1999).

Ao realizar alterações nos parâmetros do processo de peneiração, é possível obter conjuntos diferentes de IMFs. Como não existe uma maneira precisa de determinar qual conjunto é o melhor, a ortogonalidade pode ser utilizada como critério para selecionar os resultados mais relevantes. Nesse contexto, Huang et al. (1998) propuseram o Índice de Ortogonalidade (*Index of Orthogonality* - IO), que avalia o desempenho do SP. O IO é definido pela Equação 2.16, conforme proposto por Pascoal, Soares e Veltcheva (2005), e indica que quanto mais próximo de zero for o valor do índice, melhor será o efeito da decomposição.

$$IO = \frac{\sum_{i=1}^{n+1} \sum_{\substack{j=1 \\ j \neq i}}^{n+1} \left| \sum_{k=1}^T c_i(t_k) c_j(t_k) \right|}{\sum_{k=1}^T x^2(t_k)} \quad (2.16)$$

A ortogonalidade das IMFs pode ser afetada por vários fatores, conforme demonstrado por Stevenson, Mesbah e Boashash (2005). Por exemplo, observou-se que quanto maior a taxa de amostragem, maior é a consistência da propriedade de ortogonalidade entre as IMFs.

2.2.4 A Transformada de Hilbert

Através da EMD, um sinal pode ser decomposto de forma adaptativa em IMFs, que retêm informações de frequência local. Quando combinado com a Análise Espectral de Hilbert (YOUNG, 1988), aplicada a essas IMFs geradas, esta abordagem se torna uma ferramenta importante na análise de séries temporais. Esta combinação permite a obtenção do espectro de frequência instantânea (FI) e amplitude, proporcionando uma descrição mais abrangente e precisa do comportamento temporal e espectral do sinal original (HUANG et al., 1998). Assim, a combinação da EMD com a Análise Espectral de Hilbert se estabelece como uma alternativa valiosa para a análise de tempo-frequência-energia.

Uma vez obtidas as Funções de Modo Intrínseco $c_i(t)$, $i = 1, \dots, n$, a Transformada de Hilbert, definida pela Equação (2.17), é aplicada a cada componente. O objetivo desta operação é determinar as amplitudes e FIs subsequentes.

$$\mathcal{H}c_i(t) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{c_i(\tau)}{t - \tau} d\tau, \quad (2.17)$$

onde P é o valor principal de Cauchy (KING, 2009). Assim, o par complexo conjugado $c_i(t)$ e $\mathcal{H}c_i(t)$ pode ser escrito como uma função analítica $z_i(t)$ (CHURCHILL, 2014), sendo

$$z_i(t) = c_i(t) + j\mathcal{H}c_i(t) = a_i(t)e^{j\theta_i(t)}, \quad (2.18)$$

com

$$a_i(t) = [c_i^2(t) + \mathcal{H}c_i^2(t)]^{1/2}, \quad \theta_i(t) = \arctan \left[\frac{\mathcal{H}c_i(t)}{c_i(t)} \right],$$

e j é a unidade imaginária. A FI de cada componente do sinal é dada por

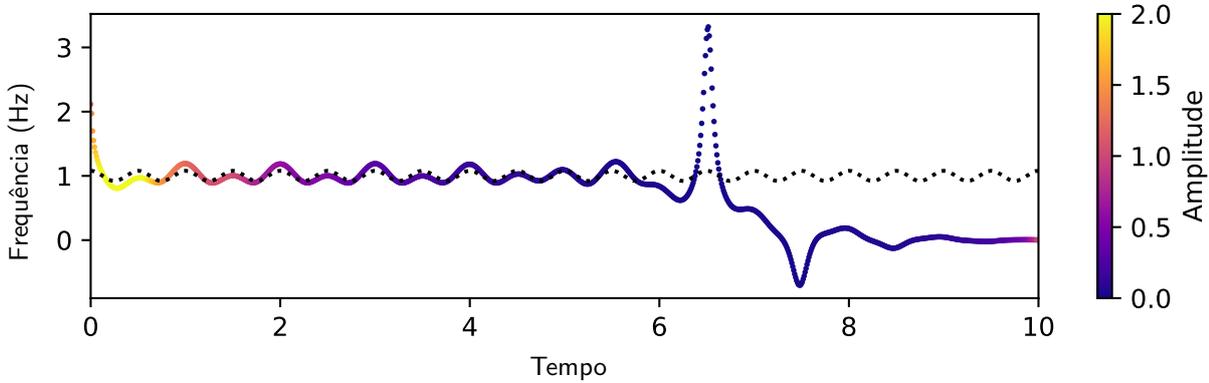
$$\omega_i = \frac{1}{2\pi} \frac{d\theta_i(t)}{dt}. \quad (2.19)$$

Baseando-se na Equação (2.18), Huang et al. (1998) observaram que a expansão do sinal utilizando a base de IMFs assemelha-se a uma versão generalizada da Análise de Fourier, mas com amplitude e frequências variáveis. Esta característica possibilita a expansão de sinais não-estacionários, os quais podem ser representados conforme descrito na Equação (2.20).

$$x(t) = Re \left[\sum_{i=1}^n a_i(t) \exp \left(j \int \omega_i(t) dt \right) \right]. \quad (2.20)$$

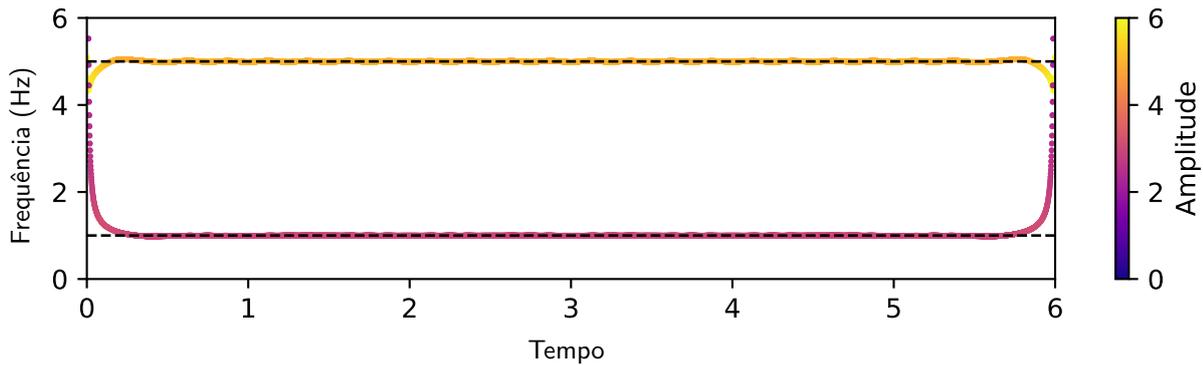
A Equação (2.20) expressa o sinal em termos de amplitudes e FIs, o que facilita a representação desses parâmetros em gráficos tridimensionais. A título de ilustração, as Figuras 6 e 7 exibem as FIs e amplitudes dos sinais sintéticos, definidos pelas Equações (2.1) e (2.3), respectivamente, em função do tempo. Em relação ao sinal da Equação (2.1), nota-se que, apesar de possuir uma FI constante ($\omega = 1$), a variação da amplitude provoca a tendência do sinal a zero conforme o tempo se estende. Como consequência, o método interpreta que a FI torna-se nula após um certo instante, fato evidenciado na Figura 6. Por outro lado, a Figura 7 destaca a habilidade da HHT em extrair com precisão as FIs das duas componentes do sinal, conforme definido na Equação (2.3).

Figura 6 – Representação tempo-frequência-amplitude da HHT aplicada ao sinal definido pela Equação (2.1). A curva tracejada representa a FI verdadeira, conforme definida na equação.



Fonte: Produzido pelo autor.

Figura 7 – Representação tempo-frequência-amplitude da HHT aplicada ao sinal definido pela Equação (2.3). As curvas tracejadas representam as FIs verdadeiras, conforme definidas na equação.



Fonte: Produzido pelo autor.

2.2.5 Versão discreta da Transformada de Hilbert

Em situações práticas, quando ao lidar com amostras discretas, obtidas a partir de sinais contínuos, usa-se uma versão discreta da HT. Essa variação facilita a implementação das operações envolvidas em um ambiente computacional, com a principal distinção sendo o seu funcionamento com sequências numéricas ao invés de funções contínuas. Na forma discreta, a HT é aplicada a uma sequência finita de valores, substituindo o tratamento de uma função contínua. A aproximação da HT contínua utilizada nesta tese para um conjunto de amostras $f(nT)$, onde $-N \leq n \leq N$, é definida conforme (KAK, 1970):

$$\mathcal{DH}f(nT) = g(kT) = \begin{cases} \frac{2}{\pi} \sum_{n \text{ ímpar}} \frac{f(nT)}{k-n}; & k \text{ par,} \\ \frac{2}{\pi} \sum_{n \text{ par}} \frac{f(nT)}{k-n}; & k \text{ ímpar.} \end{cases} \quad (2.21)$$

Dessa forma, $g(kT)$ é a k -ésima amostra da transformada da série temporal, onde $-N \leq k \leq N$.

2.3 Engenharia Paraconsistente de Características

Como mencionado no [Capítulo 1, seção 1.3](#), a seleção de *features* é um passo vital na construção de um modelo de aprendizado de máquina. Esse processo permite descartar dados redundantes ou irrelevantes que poderiam comprometer a precisão do modelo ou levar a uma complexidade excessiva. Quando bem executada, a seleção de *features* pode melhorar a qualidade do modelo, tornando-o mais eficiente, robusto e capaz de fazer previsões precisas ([SAEYS; INZA; LARRAÑAGA, 2007](#)). Além disso, de acordo com [Guido \(2019\)](#), presume-se que se um determinado conjunto de vetores de *features* demonstra eficácia satisfatória quando empregado em classificadores de estrutura mais simples, denominados classificadores fracos¹ (*weak classifier*), esse conjunto também apresentará um desempenho similar quando aplicado a um classificador mais complexo e flexível, denominado por classificador forte (*strong classifier*), desde que este esteja adequadamente configurado. Dessa forma, a seleção de *features* mais eficientes, baseada em um método menos complexo, garante uma generalização eficaz. Isso sugere que os vetores definidos dessa maneira serão apropriados tanto para classificadores fracos quanto para fortes. Portanto, um processo cuidadoso de seleção de *features* é essencial para a construção de modelos de aprendizado de máquina eficientes.

Nesse contexto, nesta tese optou-se pelo uso da PFE, um técnica proposta recentemente por [Guido \(2019\)](#), que tem se mostrado eficiente e tem sido aplicada em estudos diversos de PDS ([CAOBIANCO; GUIDO; SILVA, 2021](#); [SOUZA et al., 2022](#); [SILVA; BATISTA; RODRIGUES, 2022](#)). A escolha da técnica se justifica ainda por não ter sido aplicada para a finalidade proposta em combinação com a HHT.

Essencialmente, a PFE compreende dois procedimentos independentes: as análises interclasse e intraclasse. A variabilidade interclasse quantifica as diferenças entre as classes, enquanto a variabilidade intraclasse mensura a variação dentro de cada classe. Ambas as medidas são valiosas para a compreensão da estrutura dos dados e são convertidas em um único ponto P bidimensional. Este é representado no Plano Paraconsistente (PP) e sinaliza a qualidade do conjunto de *features*, conforme explicado adiante.

¹ Um classificador é dito fraco quando é esperado obter-se um desempenho ligeiramente melhor que ao acaso, ou seja, tem probabilidade de erro menor que $1/2$, o que o torna melhor que uma suposição aleatória em problemas envolvendo duas classes. Classificadores fracos têm baixa variância e alto viés ([ALPAYDIN, 2014](#)). Uma definição formal é dada por [Mohri, Rostamizadeh e Talwalkar \(2018\)](#). Nesse sentido, um classificador é dito forte quando este é capaz de alcançar alta precisão, com probabilidade de erro consideravelmente baixa. Classificadores fortes apresentam alta variância, baixo bias e exigem uma quantidade considerável de dados para treinamento. Exemplos de classificadores fracos incluem *Shallow Decision Trees* ([DOBKIN et al., 1997](#)) e Perceptrons ([BLOCK, 1962](#)). Por outro lado, exemplos de classificadores fortes incluem *Deep Neural Networks* ([CICHY; KAISER, 2019](#)) e SVMs.

2.3.1 Calcular P e sua Interpretação no PP

Considere um problema de classificação com N classes, no qual as classes $\{C_1, C_2, \dots, C_N\}$ são representadas, cada uma, por X vetores contendo T *features*. As etapas para o cálculo de P são, de acordo com Guido (2019):

P.1: Normalizar os vetores de *features* para que todas pertençam ao intervalo $[0, 1]$;

P.2: Calcular o número de sobreposições interclasses, denotado por R . Para isso, deve-se determinar os intervalos de variação correspondentes a cada *feature* para cada classe. Assim, R é calculado comparando cada vetor de *features* de cada classe com os intervalos correspondentes às outras classes. Caso alguma entrada pertença ao intervalo correspondente, R deve ser acrescido em uma unidade. Idealmente, não deveria haver sobreposições, pois elas tornam impossível a separação linear das classes;

P.3: Calcular o nível de dissimilaridade interclasse, denotado por β , sendo:

$$\beta = \frac{R}{N \cdot (N - 1) \cdot X \cdot T}. \quad (2.22)$$

Note que o denominador da fração indica o número de observações verificadas quanto a sobreposição no passo anterior, de modo que $0 \leq \beta \leq 1$;

P.4: Calcular o nível de similaridade intraclasse, denotado por α , sendo:

$$\alpha = \min\{\bar{Y}(C_1), \bar{Y}(C_2), \dots, \bar{Y}(C_N)\}, \quad (2.23)$$

com

$$\bar{Y}(C_k) = \frac{1}{T} \sum_{i=0}^{T-1} S_k[i], \quad 1 \leq k \leq N. \quad (2.24)$$

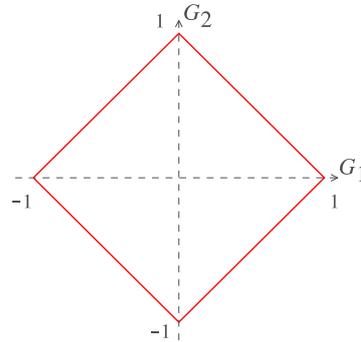
Os vetores $S_k[\cdot]$, definidos por $S_k[i] = 1 - A_k[i]$, $0 \leq i \leq T - 1$, $1 \leq k \leq N$, são chamados de vetores de similaridade e $A_k[i]$ indica a amplitude correspondente à i -ésima entrada dos vetores da k -ésima classe. Como os vetores são normalizados em **P.1**, a amplitude máxima possível é 1, conseqüentemente tem-se $0 \leq \alpha \leq 1$;

P.5: Calcular os graus de certeza $G_1 = \alpha - \beta$ e contradição $G_2 = \alpha + \beta - 1$, que formam o ponto $P = (G_1, G_2)$;

P.6: Plotar P no PP, representado na Figura 8.

O algoritmo com maiores detalhes pode ser encontrado nos artigos de Guido (2019) e Caobianco, Guido e Silva (2021).

Figura 8 – Representação do PP. Os eixos G_1 e G_2 indicam os graus de certeza e contradição, respectivamente, como mencionado no passo **P.5**.



Fonte: Produzido pelo autor.

Os vértices $(0, 1)$, $(0, -1)$, $(-1, 0)$ e $(1, 0)$ indicam ambiguidade, indefinição, falsidade e verdade, respectivamente. Dessa forma, um ponto P próximo a algum dos vértices pode ser interpretado como (GUIDO, 2019):

- Vértice $(0, 1)$ (Ambiguidade): Os vetores de *features* intraclasses e interclasses são consideravelmente semelhantes, assim, é provável que haja ambiguidade entre os vetores. O vértice representa crença absoluta ($\alpha = 1$) e descrédito total ($\beta = 1$);
- Vértice $(0, -1)$ (Indefinição): Os vetores de *features* intraclasses e interclasses são muito diferentes, assim, é provável que haja indefinição entre os vetores. O vértice representa nenhuma crença ($\alpha = 0$) e nenhum descrédito ($\beta = 0$);
- Vértice $(-1, 0)$ (Falsidade): Os vetores de *features* intraclasses estão dispersos e os interclasses se sobrepõem significativamente, portanto, é provável que um classificador forte seja necessário. O vértice representa nenhuma crença ($\alpha = 0$) e descrédito total ($\beta = 1$);
- Vértice $(1, 0)$ (Verdade): Os vetores de *features* intraclasses estão agrupados e os interclasses se sobrepõem minimamente, dessa forma, é provável que um classificador fraco resolva o problema. O vértice representa crença absoluta ($\alpha = 1$) e nenhum descrédito ($\beta = 0$).

Conclui-se que, quanto mais próximo P estiver do vértice $(1, 0)$, mais simples poderá ser o classificador usado (fraco), pois os vetores de *features* têm alta qualidade. Guido (2019) reforça que caso P se aproxime desse vértice de baixo para cima, é provável que um classificador linear seja suficiente para solucionar o problema, pois nesse sentido β é próximo de zero, o que não indica descrédito algum, já que os vetores de classes distintas não se sobrepõem ou se sobrepõem minimamente. O vértice $(1, 0)$ é denominado por Vértice Ótimo (VO).

Nas duas próximas subseções, seguem dois exemplos simples de avaliação para ilustrar o uso da técnica, sendo um sem sobreposições e outro com sobreposição.

2.3.2 Exemplo Numérico sem Sobreposição

Considere um problema de classificação com duas classes hipotéticas, C_1 e C_2 . Cada classe é caracterizada por três vetores bidimensionais cujas coordenadas estão normalizadas no intervalo $[0, 1]$ tais que:

$$C_1 = \{(0.27, 0.34); (0.34, 0.33); (0.29, 0.27)\},$$

$$C_2 = \{(0.9, 0.86); (0.86, 0.9); (0.93, 0.91)\}.$$

Como os vetores já estão normalizados, basta prosseguir para as análises interclasse e intraclasse. Para realizar a análise interclasse (**P.2**), inicialmente calcula-se os vetores que determinam os intervalos de variação de cada entrada de cada classe da seguinte maneira:

- Classe C_1 : $(0.27, 0.27)$ contém os menores componentes e $(0.34, 0.34)$ contém os maiores componentes de cada entrada;
- Classe C_2 : $(0.86, 0.86)$ contém os menores componentes e $(0.93, 0.91)$ contém os maiores componentes de cada entrada.

Comparando cada vetor de uma classe com o intervalo de variação da outra, constata-se que não há sobreposições, ou seja, $R = 0$. Portanto $\beta = 0$ (**P.3**).

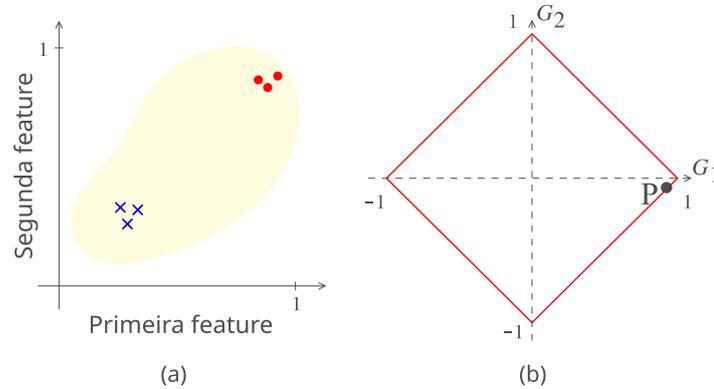
Prosseguindo com a análise intraclasse (**P.4**), calcula-se as amplitudes de cada entrada usando os intervalos definidos na etapa anterior, sendo $A_1 = (0.07, 0.07)$ e $A_2 = (0.07, 0.05)$. Daí, os vetores de similaridade são $S_1 = (1, 1) - A_1 = (0.93, 0.93)$ e $S_2 = (1, 1) - A_2 = (0.93, 0.95)$. Portanto, $\bar{Y}(C_1) = 0.93$ e $\bar{Y}(C_2) = 0.94$, conseqüentemente $\alpha = 0.93$.

Determinados α e β , calcula-se as coordenadas de P (**P.5**), obtendo $P = (0.93, -0.07)$. Observa-se que P está mais próximo do vértice $(1, 0)$ e está no quarto quadrante, indicando que as *features* são linearmente separáveis e que um classificador fraco é suficiente para solucionar o problema. Na [Figura 9](#) estão representados os vetores no plano cartesiano e o ponto P que os representa no PP.

2.3.3 Exemplo Numérico com Sobreposição

Considere uma variação do problema de classificação apresentado no exemplo anterior, com duas classes hipotéticas, C_1 e C_2 . Novamente, cada classe é caracterizada

Figura 9 – (a) Vetores de *features* das classes C_1 e C_2 representados no plano cartesiano pelos símbolos \times e \bullet , respectivamente. (b) Ponto P que representa o conjunto de vetores no PP.



Fonte: Produzido pelo autor.

por três vetores bidimensionais cujas coordenadas estão normalizadas no intervalo $[0, 1]$ tais que:

$$C_1 = \{(0.27, 0.34); (0.34, 0.33); (0.9, 0.92)\},$$

$$C_2 = \{(0.9, 0.86); (0.86, 0.9); (0.93, 0.91)\}.$$

Como os vetores já estão normalizados, basta prosseguir para as análises interclasse e intraclasse. Para realizar a análise interclasse (**P.2**), inicialmente calcula-se os vetores que determinam os intervalos de variação de cada entrada de cada classe da seguinte maneira:

- Classe C_1 : $(0.27, 0.33)$ contém os menores componentes e $(0.9, 0.92)$ contém os maiores componentes de cada entrada;
- Classe C_2 : $(0.86, 0.86)$ contém os menores componentes e $(0.93, 0.91)$ contém os maiores componentes de cada entrada.

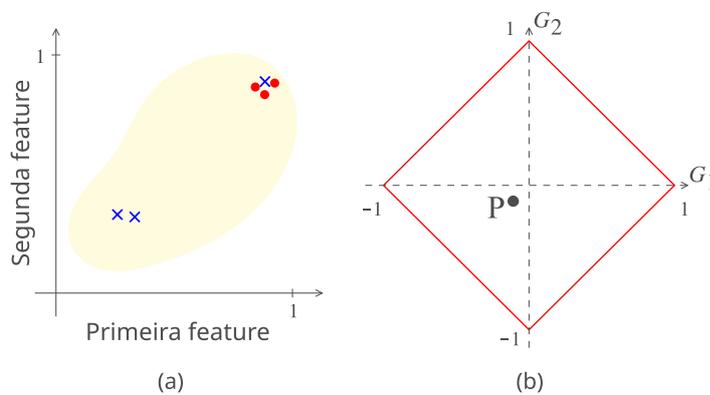
Comparando cada vetor de uma classe com o intervalo de variação da outra, constata-se que há 6 sobreposições, ou seja, $R = 6$. Portanto, de **P.3** segue que:

$$\beta = \frac{6}{2 \cdot (2 - 1) \cdot 3 \cdot 2} = 0.5.$$

Prosseguindo com a análise intraclasse (**P.4**), calcula-se as amplitudes de cada entrada usando os intervalos definidos na etapa anterior, sendo $A_1 = (0.63, 0.58)$ e $A_2 = (0.07, 0.05)$. Daí, os vetores de similaridade são $S_1 = (1, 1) - A_1 = (0.37, 0.42)$ e $S_2 = (1, 1) - A_2 = (0.93, 0.95)$. Portanto, $\bar{Y}(C_1) = 0.39$ e $\bar{Y}(C_2) = 0.94$, conseqüentemente $\alpha = 0.39$.

Determinados α e β , calcula-se as coordenadas de P (**P.5**), obtendo $P = (-0.11, -0.11)$. Observa-se que P está mais próximo dos vértices $(-1, 0)$ e $(0, -1)$, indicando falsidade e indefinição, respectivamente, ou seja, possivelmente os vetores de *features* intraclasses estão dispersos, os interclasses se sobrepõem significativamente e há grandes diferenças entre as *features*, conforme pode ser observado na [Figura 10](#). Isso sugere que um classificador forte é necessário para resolver o problema e que não há solução linear.

Figura 10 – (a) Vetores de *features* das classes C_1 e C_2 representados no plano cartesiano pelos símbolos \times e \bullet , respectivamente. (b) Ponto P que representa o conjunto de vetores no PP.



Fonte: Produzido pelo autor.

2.4 Escala Bark

A EB é um modelo psicoacústico concebido para subdividir a faixa de frequências sonoras processadas pelo ouvido humano. Ela é estruturada em torno do conceito de bandas críticas, que são faixas de frequência específicas dentro das quais o ouvido humano percebe o som ([ZWICKER, 1961](#)). A escala engloba 25 bandas críticas, que cobrem a gama de frequências audíveis para os seres humanos, até aproximadamente 20 kHz ([BOSI; GOLDBERG, 2002](#)). Esta escala é amplamente utilizada em várias áreas, como codificação de áudio ([HERRE; DICK, 2019](#)), análise de fala ([KOLLMEIER; BRAND; MEYER, 2008](#)) e música ([DORRAN; LAWLOR, 2003](#)), além de detecção acústica e identificação de ruído ([GRIGG et al., 2021](#)), pois fornece uma representação do som que está mais alinhada à percepção humana do que as medições de frequência baseadas estritamente em parâmetros físicos ([ZWICKER; FASTL, 2013](#)).

A relação entre a taxa de banda crítica denotada por z , com unidade “Bark”, e a frequência, f (Hz), é dada pela expressão analítica exibida na [Equação \(2.25\)](#), conforme descrito por [Zwicker e Fastl \(2013\)](#):

$$z/Bark = 13 \cdot \arctan(0.76 \cdot f/kHz) + 3.5 \cdot \arctan\left(\left(\frac{f}{7.5kHz}\right)^2\right). \quad (2.25)$$

A Equação (2.25) é frequentemente usada em aplicações envolvendo acústica. No entanto, na literatura disponível, é possível encontrar outras equações para a conversão de frequência em Hertz para Bark, como exposto por Traunmüller (1990) e Wang, Sekey e Gersho (1992). Essas equações fornecem resultados aproximadamente equivalentes, e a escolha de qual equação usar pode depender do contexto específico da aplicação.

Os valores exatos das bandas críticas, conforme Zwicker e Fastl (2013), variam de 0 a 24 e estão relacionados com os limites de frequência inferior (f_m) e superior (f_M), dispostos na Tabela 3. A primeira banda crítica abrange a faixa de 0 a 100 Hz, a segunda de 100 a 200 e assim por diante.

Tabela 3 – Bandas críticas da EB. f_m indica a frequência mínima, f_M a máxima.

z (Bark)	f_m (Hz)	f_M (Hz)	z (Bark)	f_m (Hz)	f_M (Hz)
0	0	100	13	2000	2320
1	100	200	14	2320	2700
2	200	300	15	2700	3150
3	300	400	16	3150	3700
4	400	510	17	3700	4400
5	510	630	18	4400	5300
6	630	770	19	5300	6400
7	770	920	20	6400	7700
8	920	1080	21	7700	9500
9	1080	1270	22	9500	12000
10	1270	1480	23	12000	15500
11	1480	1720	24	15500	22050
12	1720	2000			

Fonte: Elaborada pelo autor.

Nesta tese, a EB é empregada na elaboração de vetores de *features*. A hipótese subjacente é que, ao utilizar faixas de frequências sonoras que são processadas pelo ouvido humano, emula-se de certa forma a audição humana. Isso, por sua vez, pode potencializar a eficácia na identificação de padrões para o sistema proposto.

2.5 Normalizações

Ao trabalhar com vetores de *features* em aprendizado de máquina, é comum que *features* variem em diferentes intervalos. Nesse contexto, a normalização dos dados se torna uma etapa crucial. Esse processo evita que *features* com grandes intervalos numéricos dominem aquelas com intervalos menores, o que poderia influenciar negativamente a capacidade de generalização do classificador escolhido (SOLA; SEVILLA, 1997).

Na literatura, diversas técnicas estão disponíveis, como: Min-Max, Z-score, Decimal Scaling, Hyperbolic Tangent, Logistic Sigmoid e outras (SINGH; SINGH, 2020). Cada uma dessas técnicas tem suas particularidades e pode ser mais adequada para determinados tipos de dados ou aplicações específicas. É importante destacar que a escolha da técnica de normalização apropriada é uma etapa crucial, pois pode influenciar significativamente o desempenho do modelo de aprendizado de máquina.

Nesta tese, são analisadas três técnicas para a normalização das *features*. São elas: Normalização pelo Máximo Absoluto (Max Normalization - MN), Normalização Min-Max (Min-Max Normalization - MMN) e a Normalização Sigmoidal ou Softmax (Logistic Sigmoid - LS), que é baseada na função logística. As duas primeiras são transformações lineares, enquanto a terceira é uma transformação não-linear. A descrição detalhada de cada uma dessas técnicas será apresentada a seguir.

Começando pela MMN, uma técnica simples e bastante empregada na literatura (HAN; PEI; KAMBER, 2011; SINGH; SINGH, 2020), que atua através do reescalonamento das *features* para um intervalo $[a, b]$ desejado. Sejam f_i , $i = 1, \dots, n$, n vetores de *features*, a j -ésima *feature* do i -ésimo vetor normalizado é dada pela Equação (2.26).

$$f'_{ij} = \frac{f_{ij} - \min(f_i)}{\max(f_i) - \min(f_i)} \cdot (b - a) + a, \quad (2.26)$$

sendo a e b o mínimo e o máximo do intervalo alvo, respectivamente. É evidentemente que deve-se ter $\max(f_i) - \min(f_i) \neq 0$, caso contrário o vetor em questão possui *features* com valores constantes e deve ser desconsiderado, pois não será capaz de fornecer nenhuma informação relevante ao classificador (PRIDDY; KELLER, 2005).

A MN é uma variante da MMN, onde cada *feature* é reescalada no intervalo $[-1, 1]$, sendo dividida pelo maior valor absoluto das *features*, conforme Equação (2.27).

$$f'_{ij} = \frac{f_{ij}}{\max(|f_i|)}. \quad (2.27)$$

Por fim, a LS é baseada na função logística e ajusta os dados para o intervalo $[0, 1]$. A Equação (2.28) indica como calcular a j -ésima *feature* do i -ésimo vetor normalizado.

$$f'_{ij} = \frac{1}{1 + e^{-q_{ij}}}, \quad \text{sendo } q_{ij} = \frac{f_{ij} - \mu_i}{v \cdot \sigma_i}. \quad (2.28)$$

onde μ_i e σ_i denotam a média e o desvio padrão do i -ésimo vetor, respectivamente. A LS transforma os dados de modo que os *outliers* são “comprimidos” para valores mais próximos da média dos dados. Isso pode ajudar a reduzir o impacto dos *outliers* nos modelos de aprendizado de máquina, tornando-os mais robustos (SINGH; SINGH, 2020). Para as

aplicações desta pesquisa, foram investigados 5 valores de v , sendo eles $\{0.01, 0.1, 1, 10, 100\}$, conforme detalhado no [Capítulo 4](#).

3 Abordagem Proposta

Este capítulo, dedicado ao detalhamento da estrutura do sistema proposto, esboça não apenas os passos, mas também os fluxogramas necessários para a implementação de cada parte do sistema. A apresentação detalhada possibilita uma compreensão abrangente do funcionamento interno da proposta, permitindo uma análise profunda de suas componentes e interações. Isso não apenas facilita a replicação e adaptação do sistema em diferentes contextos, mas também serve como uma base sólida para futuras melhorias e otimizações.

3.1 Estrutura do Sistema Proposto

A pesquisa descrita nesta tese faz parte de um estudo mais amplo na área de entomologia agrícola, com foco na identificação de cigarras por suas características sonoras. Trabalhos nessa direção foram publicados pelo grupo de pesquisa usando a WT, como evidenciado por [Escola et al. \(2020b\)](#) e [Escola et al. \(2021\)](#).

A metodologia proposta tem o objetivo de desenvolver um sistema capaz de receber um arquivo de áudio e classificá-lo como “cigarra” ou “ruído”, no caso de identificação, ou “alta”, “média” ou “ruído”, no caso de estimativa de densidade.

Nesta tese, uma nova abordagem é explorada, indo além da WT adotada em pesquisas anteriores. Apesar do notável valor e eficácia da WT na identificação de cigarras ([ESCOLA et al., 2020b](#)), optou-se por empregar a HHT devido às suas características distintas que a tornam especialmente adequada para o proposto, já que foi desenvolvida para lidar com sinais não estacionários e não lineares, o que é crucial para o estudo de sinais biológicos, como os emitidos por cigarras. Sua representação no domínio tempo-frequência pode revelar sutilezas nas características sonoras, podendo levar a implicações significativas na entomologia agrícola. Adicionalmente, a escolha da HHT justifica-se por ser uma técnica amplamente utilizada em estudos recentes envolvendo PDS ([SAHANI et al., 2020](#); [AQAMOHAMMADI et al., 2023](#); [ZHANG et al., 2023](#)), além de representar uma abordagem inédita.

Quanto à representação dos sinais acústicos no formato de vetores de *features*, optou-se por investigar de duas formas: na primeira, as energias das componentes determinam as *features*. Esta forma é bastante comum na literatura ([TABRIZI et al., 2014](#); [GUIDO, 2016](#)) e será designada por F1. Secundariamente, designada por F2, as FIs das IMFs são dispostas de acordo com as faixas de frequências correspondentes às bandas críticas da EB, conforme proposto por [Escola et al. \(2020b\)](#).

O formato F1 se destaca pela sua simplicidade, menor complexidade e consistência com a literatura. Trata-se de uma representação direta que dispensa a etapa de análise com a HT e já foi validada em outras aplicações. No entanto, pode resultar em uma generalização excessiva para a aplicação proposta, levando à perda de nuances críticas, especialmente no caso da redução de dimensionalidade decorrente da exclusão de *features*, empregada nos experimentos conduzidos nesta tese. É essencial observar que, por definição, cada IMF representa uma faixa de frequência específica. Supondo que, para a aplicação proposta, uma outra espécie de inseto, denominada E1, emita um sinal sonoro em frequência superior àquela emitida pela *Quesada gigas*. Se ambos os sinais sonoros de E1 e *Quesada gigas* se combinarem, é evidente que, ao decompor esse sinal composto, as primeiras IMFs reflipam as características de E1. Isto porque a EMD tende a extrair as componentes de frequências mais altas inicialmente. Portanto, somente as IMFs de índices mais elevados iriam retratar as características da *Quesada gigas*. Contudo, caso o sinal seja composto unicamente pela frequência da *Quesada gigas*, as primeiras IMFs capturariam as suas características. Adicionalmente, supondo que a PFE indique que as *features* menos relevantes são as últimas, no exemplo fornecido, as *features* correspondentes à *Quesada gigas* seriam descartadas, gerando assim um vetor de *features* rotulado como “cigarra”, mas que não representa efetivamente essa classe.

Em contraste, o formato F2 adota uma abordagem mais detalhada e específica, levando em conta as FIs das IMFs organizadas de acordo com as faixas de frequência das bandas críticas da EB. Enquanto o F1 é caracterizado pela sua simplicidade inerente e pela capacidade de eliminar a etapa de análise com a HT, ele pode ser mais restritivo no que se refere à flexibilidade na combinação de *features*, mesmo proporcionando bons resultados. Ao considerar F2, por outro lado, a estrutura intrínseca das *features* permite combinações mais ricas e significativas. Esta abordagem resulta em uma representação mais alinhada à natureza dos sinais acústicos, conforme evidenciado em aplicações recentes (NANNI et al., 2016; ESCOLA et al., 2021), e é mais apta a explorar combinações entre diferentes características. Tal método não só minimiza o risco de generalizações excessivas, mas também potencializa a identificação de nuances nos dados que poderiam passar despercebidas no formato F1.

Após a formação dos vetores de *features* pelos formatos F1 e F2, é crucial a adoção de procedimentos de normalização, que é essencial para evitar que atributos em faixas numéricas muito grandes dominem atributos em faixas menores. Neste contexto, optou-se pelas técnicas de normalização MN, MMN e LS para os testes, detalhadas na seção 2.5. A implementação destas técnicas assegura que todas as *features* sejam tratadas de maneira equitativa, potencializando o desempenho do classificador nas tarefas subsequentes.

Outra etapa de extrema importância é a seleção de *features*, ou seleção de atributos. Ela consiste em identificar e selecionar as variáveis mais relevantes e informativas para a

construção de um modelo. Ao reduzir a dimensionalidade dos vetores, é possível acelerar o tempo de treinamento e otimizar a performance do modelo. Além disso, pode-se eliminar atributos irrelevantes ou redundantes que poderiam levar a *overfitting*, onde o modelo se ajusta excessivamente aos dados de treino e perde sua capacidade de generalização para novos dados. Dentre as técnicas disponíveis na literatura, como a PCA (BRO; SMILDE, 2014), *Independent Component Analysis* (ICA) (HYVÄRINEN, 2013), entre outras, optou-se pela PFE por tratar-se de uma técnica moderna de seleção de características, por sua simplicidade, pelo crescente interesse da comunidade científica e, evidentemente, por ser inédita sua combinação com a HHT. Todos os detalhes necessários para compreensão da técnica estão disponíveis na seção 2.3.

Como classificador do sistema, optou-se por uma SVM, que é um método supervisionado de aprendizagem de máquina amplamente utilizado em problemas de classificação de padrões, que também pode ser empregado em regressões (ALPAYDIN, 2014). A escolha do modelo SVM se justifica não apenas por sua reconhecida eficácia em publicações dedicadas à classificação de padrões, mas também por sua comprovada eficiência na classificação de sinais acústicos emitidos por cigarras (NODA et al., 2016; ESCOLA et al., 2020b). Importante ressaltar que, apesar do custo de treinamento poder ser alto, o custo para realizar previsões com um modelo SVM treinado é geralmente baixo, estando na ordem de $O(d)$ ¹ para *kernel* linear e $O(m \cdot d)$ para outras funções *kernel*, onde m é o número de vetores de suporte e d é a dimensionalidade dos vetores (MAJI; BERG; MALIK, 2013). Esta eficiência é fundamental em aplicações que requerem resposta em tempo real ou que contam com recursos computacionais limitados, como é o caso do sistema proposto, idealizado para ser empregado em campo, seja através de microcontroladores ou em *smartphones*, conforme mencionado anteriormente.

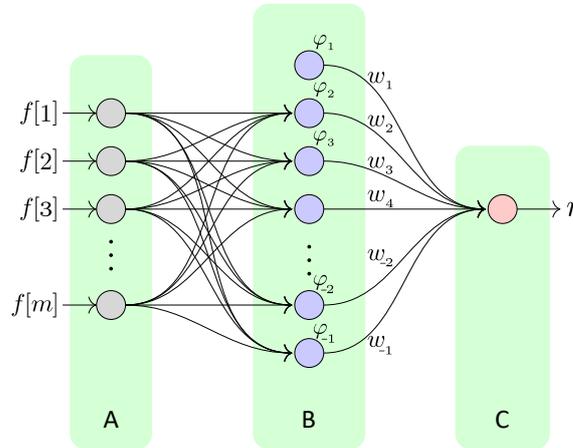
A arquitetura SVM adotada é ilustrada na Figura 11. A camada de entrada (**A**) é composta pelas m *features* de cada vetor, selecionadas durante a etapa PFE. Na fase de treinamento, os pesos sinápticos $\{w_k; 1 \leq k \leq n(X)\}$ da camada oculta (**B**) são otimizados conforme a Equação (3.1). Já na camada final ou de saída (**C**), a saída $r(\mathbf{x})$ indica a classe do vetor \mathbf{x} . Nesse contexto, $n(\cdot)$ representa o número de elementos em um conjunto e X se refere ao conjunto dos vetores de treinamento do modelo.

$$r(\mathbf{x}) = \sum_{k=1}^{n(X)} w_k \cdot \varphi_k(\mathbf{x}). \quad (3.1)$$

As funções $\varphi_k(\cdot)$, onde $1 \leq k \leq n(X)$, são definidas por uma função $K : X \rightarrow Z$, chamada função *kernel*, de modo que $\varphi_k(\cdot) = K(\mathbf{x}_k, \cdot)$, sendo $\mathbf{x}_k \in X$ o k -ésimo vetor de treinamento. Além disso, $Z \subset \mathbb{R}^{n(X)}$ é um espaço de dimensão $n(X)$ (ALPAYDIN, 2014).

¹ A notação Big O descreve o comportamento assintótico do tempo de execução de um algoritmo em relação ao tamanho da entrada (CORMEN et al., 2022).

Figura 11 – Estrutura SVM utilizada na abordagem proposta. A camada **A** é a camada de entrada, com m elementos passivos; a camada **B** é a camada oculta, com $n(X)$ elementos ativos; e a camada **C** é a camada de saída, com um elemento linear ativo. Na camada **B**, $\varphi_{-2} = \varphi_{n(X)-1}$, $\varphi_{-1} = \varphi_{n(X)}$, $w_{-2} = w_{n(X)-1}$ e $w_{-1} = w_{n(X)}$.



Fonte: Produzido pelo autor.

Dada a importância da escolha adequada da função *kernel* para cada problema específico (BISHOP, 1995), nesta pesquisa, foram adotadas quatro funções *kernel*: linear, Função de Base Radial (*Radial Basis Function* - RBF), polinomial e sigmoide, conforme apresentadas nas Equações 3.2 à 3.5, respectivamente.

$$K(\mathbf{x}_k, \mathbf{x}) = \langle \mathbf{x}_k, \mathbf{x} \rangle; \quad (3.2)$$

$$K(\mathbf{x}_k, \mathbf{x}) = \exp(-\gamma \cdot \|\mathbf{x} - \mathbf{x}_k\|^2), \quad \gamma > 0; \quad (3.3)$$

$$K(\mathbf{x}_k, \mathbf{x}) = (\gamma \cdot \langle \mathbf{x}_k, \mathbf{x} \rangle + c)^d; \quad (3.4)$$

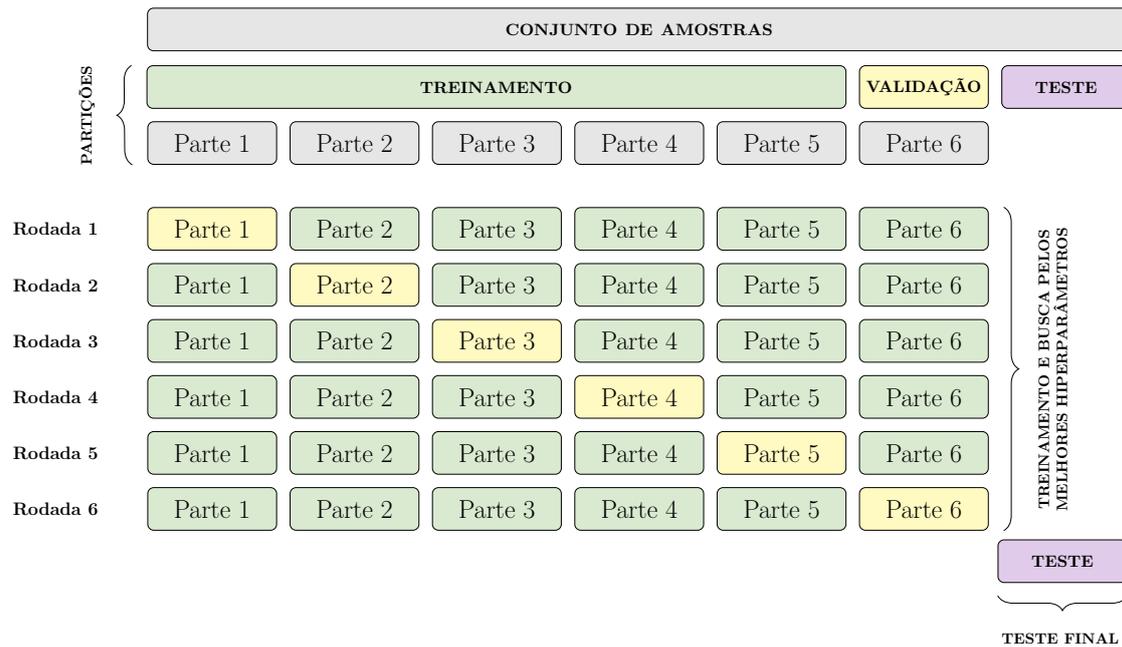
$$K(\mathbf{x}_k, \mathbf{x}) = \tanh(\gamma \cdot \langle \mathbf{x}_k, \mathbf{x} \rangle + c), \quad (3.5)$$

onde $\|\cdot\|$ indica a norma euclidiana. Os parâmetros d e c têm a função de ajustar, respectivamente, a flexibilidade e o deslocamento da fronteira de decisão, sendo essenciais pra otimizar a separabilidade entre as amostras e, conseqüentemente, melhorar a acurácia do sistema. O parâmetro γ também influencia na flexibilidade da fronteira de decisão, com valores menores resultando em uma fronteira aproximadamente linear.

A fim de simular condições reais de sensibilidade e especificidade de modo que os dados de teste não influenciem o treinamento do modelo, empregou-se o método de validação cruzada por k -partes (k -fold cross-validation) (FRIEDMAN, 1994; BERRAR,

2019), onde os dados são divididos em um conjunto para treinamento e outro para teste. O conjunto reservado para treinamento é então subdividido em k partições para que sejam executadas k rodadas de treinamento, nas quais $k - 1$ partes são empregadas para treinamento e uma parte, distinta a cada rodada, para validação. O modelo é treinado em k rodadas utilizando os conjuntos de treinamento e validação para determinação dos melhores hiperparâmetros. Logo após, é testado com o conjunto inicialmente reservado e não utilizado no treinamento, conforme ilustrado na Figura 12.

Figura 12 – Esquema de Validação Cruzada por k -partes com $k = 6$.



Fonte: Produzido pelo autor.

O conjunto de técnicas e procedimentos descrito é fundamental para a elaboração da solução apresentada nesta tese. Projetado de forma modular, o sistema é composto por seis módulos que contribuem conjuntamente para sua eficiência, cada um com uma função específica. A seguir, estão listados os módulos.

Módulo 1: Encarregado de pré-processar os arquivos de áudio, o primeiro módulo, denominado Módulo de Extração das *Features* (MEF), recebe os dados brutos e gera os vetores de *features*;

Módulo 2: O segundo é o Módulo de Normalização das *Features* (MNF), como o próprio nome indica, é responsável por normalizar os vetores de *features* criados pelo MEF utilizando as técnicas de normalização MN, MMN e LS, que foram descritas na seção 2.5 do capítulo anterior;

Módulo 3: O terceiro módulo, denominado Módulo PFE (MPFE), é encarregado de aplicar a PFE para todos os vetores normalizados pelo MNF, considerando

os subgrupos possíveis de *features*, tanto na ordem crescente quanto para as combinações de índices, possibilitando analisar a importância das *features* antes de treinar o classificador;

Módulo 4: Encarregado dos treinamentos e testes dos modelos SVM, o Módulo de Treinamento e Testes (MTT) opera usando a validação cruzada por k -partes, o que permite a realização de testes mais robustos e escolha de parâmetros mais precisos, tornando a avaliação do desempenho do modelo mais confiável;

Módulo 5: A representação dos resultados fica a cargo do Módulo de Visualização Gráfica dos Resultados (MVGR), encarregado de transformar os dados analíticos em ilustrações gráficas claras e interpretáveis. Este módulo recebe os resultados de MEF, MNF, MPFE e MTT e utiliza técnicas de visualização de dados para ilustrar os achados da HHT, importância das *features*, e as classificações, por meio de uma variedade de gráficos. Estas representações visuais abrangem gráficos de coordenadas paralelas (INSELBERG, 2009), gráficos de radar (SAARY, 2008), diagramas de caixa (KRZYWINSKI; ALTMAN, 2014), PP, curvas denominadas *Receiver operating characteristics* (ROC) e Matrizes de Confusão (MC) (FAWCETT, 2006). Esta variedade de representações enriquece a compreensão dos resultados, tornando-os acessíveis e intuitivos;

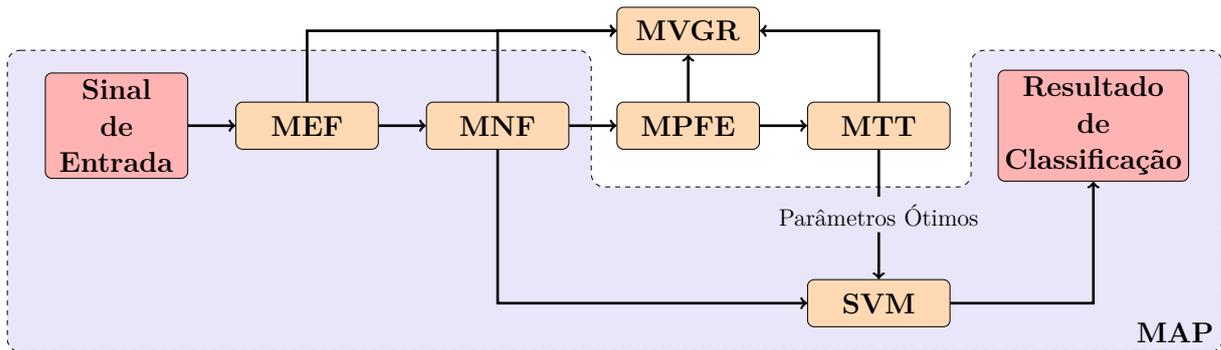
Módulo 6: Por fim, o Módulo de Aplicação (MAP) é responsável pela implementação prática do sistema contendo o modelo do classificador treinado, sendo composto pelos módulos MEF e MNF junto ao modelo SVM configurado com os melhores parâmetros definidos no MTT. Ele pode ser executado em um microcontrolador para ser utilizado no campo ou, alternativamente, pode ser implementado como um aplicativo compatível com *smartphones* antigos, provendo o reaproveitamento de equipamentos eletrônicos (*e-waste*) (PERKINS et al., 2014; SHAHABUDDIN et al., 2023), como mencionado no Capítulo 1.

A estrutura completa do sistema é ilustrada no diagrama da Figura 13. Detalhes adicionais são fornecidos na seção subsequente e os parâmetros mencionados são discutidos no próximo Capítulo.

3.2 Detalhes do sistema

Esta seção aborda os aspectos técnicos necessários para a implementação de cada módulo. A concepção desses módulos se baseia na estrutura detalhada na seção anterior e é projetada para corroborar a hipótese sustentada neste trabalho. Além disso, esta seção serve como uma fase preparatória para a execução dos testes que serão apresentados

Figura 13 – Estrutura do sistema proposto.



Fonte: Produzido pelo autor.

no capítulo subsequente. Esses testes são fundamentais para validar o sistema e para evidenciar sua eficácia na resolução do problema de identificação e estimativa de densidade populacional de cigarras, utilizando sinais sonoros.

3.2.1 MEF

Conforme destacado na seção anterior, o MEF é responsável por pré-processar os arquivos de áudio e gerar os vetores de *features*. Os parâmetros de entrada incluem o diretório dos arquivos WAV, taxa de amostragem desejada para os sinais a serem processados, critério de parada e parâmetros da HHT.

Este módulo lê os dados brutos, ajusta a taxa de amostragem quando necessário, aplica a HHT e calcula os vetores de *features* das formas F1 e F2. Em seguida, essas informações são salvas em um arquivo de texto, juntamente com um relatório que contém informações detalhadas sobre a EMD, como parâmetros utilizados, número de IMFs obtidas, iterações do SP, IO, erro de reconstrução do sinal e tempo despendido. Após o processamento de todos os arquivos de áudio, os arquivos de texto gerados são compactados no formato “zip”;

Os passos para a implementação do algoritmo proposto para o MEF, que são ilustrados na Figura 14, são descritos a seguir. Considere A o conjunto de amostras de sinais acústicos, no formato WAV, compreendendo as classes a serem consideradas no problema de classificação.

- **INÍCIO;**
- **MEF P.1:** Leitura dos Parâmetros de Entrada (LPE) e inicialização da variável M , que armazenará o número máximo de IMFs obtido em uma decomposição;

- **Repetir:**

- **MEF P.2:** Extração dos dados brutos (EDB) do i -ésimo sinal acústico de A , armazenados no vetor $\mathbf{s}_i \in S$, $i \in [1, n(A)]$. Aqui, $n(\cdot)$ denota o número de elementos em um conjunto.
- **MEF P.3:** Verificar a Taxa de Amostragem (VTA) do i -ésimo sinal pertencente a S e reajustá-la de acordo com os parâmetros de entrada, se necessário;
- **MEF P.4:** Aplicar a Decomposição ao Sinal (ADS) \mathbf{s}_i , $i \in [1, n(A)]$, considerando o critério de parada indicado em **P.1** para determinar as N_i IMFs \mathbf{c}_{ij} , $1 \leq j \leq N_i$, onde o índice superior sc indica a sigla do critério de parada correspondente. É importante ressaltar que cada IMF tem o mesmo comprimento que \mathbf{s}_i . Para simplificar a notação, o resíduo é considerado como uma das N_i componentes.
- **MEF P.5:** Atualizar Máximo de IMFs (AMI) obtido em uma decomposição, ou seja, se $M \leq N_i$ então $M = N_i$;
- **MEF P.6:** Formação do vetor de *Features* (FVF) \mathbf{f}_i correspondente ao sinal \mathbf{s}_i , $i \in [1, n(A)]$:
 - **Se F1:** As energias das N_i IMFs \mathbf{c}_{ij} , $1 \leq j \leq N_i$, determinam o vetor \mathbf{f}_i . Particularmente, a j -ésima *feature* $f_i[j]$ de \mathbf{f}_i corresponde à energia da j -ésima IMF de \mathbf{s}_i , conforme [Equação \(3.6\)](#).

$$f_i[j] = \langle \mathbf{c}_{ij}, \mathbf{c}_{ij} \rangle. \quad (3.6)$$

Evidentemente, o número de IMFs N_i não é o mesmo para todo $i \in [1, n(A)]$, conforme mencionado anteriormente, logo os vetores terão números de *features* diferentes. Este problema é contornado em um dos passos seguintes, completando os vetores com zeros até o maior número de IMFs obtido em todas as decomposições, de modo que todos os vetores tenham o mesmo número de *features*;

- **Senão (F2):** As N_i IMFs \mathbf{c}_{ij} são submetidas à HT para determinação de suas FIs \mathbf{F}_{ij} e amplitudes \mathbf{A}_{ij} , $1 \leq j \leq N_i$. Em seguida, as energias correspondentes a cada faixa de frequência conforme as bandas críticas da EB são distribuídas em um vetor \mathbf{f}_i com 25 coordenadas, conforme [Equação \(3.7\)](#).

$$f_i[k] = \sum_{j=1}^{N_i} \sum_{t=1}^T \mathbf{A}_i[j][t]^2 \cdot I(k, \mathbf{F}_i[j][t]), \quad k \in [0, 24], \quad (3.7)$$

onde T é dado pelo comprimento do vetor \mathbf{s}_i e I é a função indicadora dada por:

$$I(k, f) = \begin{cases} 1, & \text{se } |f| \in z[k]; \\ 0, & \text{caso contrário.} \end{cases} \quad (3.8)$$

Na [Equação \(3.8\)](#) $z[k]$ é a k -ésima banda crítica da EB, conforme a [Tabela 3](#).

- **Enquanto** houverem sinais acústicos no diretório indicado nos parâmetros de entrada que não foram processados (Rotina Último Arquivo de Áudio - UAA);

→ **Se F1**, então:

- **Repetir**:

- **MEF P.7:** Atualizar o i -ésimo Vetor de *Features* (AVF) \mathbf{f}_i , $i \in [1, n(A)]$, completando-o com zeros até que tenha comprimento M , conforme [Equação \(3.9\)](#):

$$f_i[j] = \begin{cases} f_i[j], & 1 \leq j \leq N_i, \\ 0, & N_i < j \leq M. \end{cases} \quad (3.9)$$

- **Enquanto** houverem vetores de *features* a serem completados com zeros até o máximo M (Rotina Último Vetor F1 - UVF1);

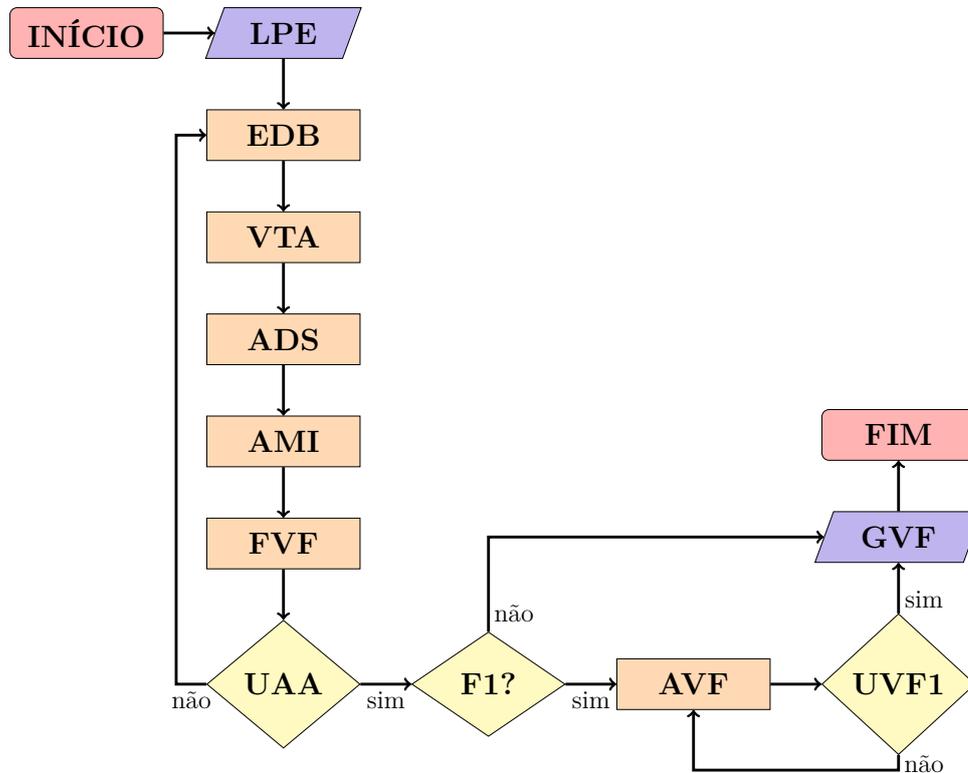
- **MEF P.8:** Gravar os Vetores de *Features* (GVF) em um arquivo de texto no padrão ASCII separando as *features* por ponto e vírgula, sendo a primeira entrada referente a classe do vetor. Em seguida compacta os arquivos gerados no formato “zip”;
- **FIM.**

3.2.2 MNF

Uma vez obtidos os vetores nos formatos F1 e F2, estes são normalizados utilizando as técnicas de normalização MN, MMN e LS, conforme mencionado anteriormente. Para cada uma dessas técnicas, é gerado um arquivo de texto contendo as *features* normalizadas. O módulo recebe o diretório dos arquivos gerados pelo MEF e os parâmetros a serem usados por cada técnica de normalização. Após o processamento de todos os arquivos que contêm os vetores de *features*, os arquivos de texto gerados são compactados no formato “zip”;

Os passos para a implementação do algoritmo proposto para o MNF, que são ilustrados na [Figura 15](#), são descritos a seguir.

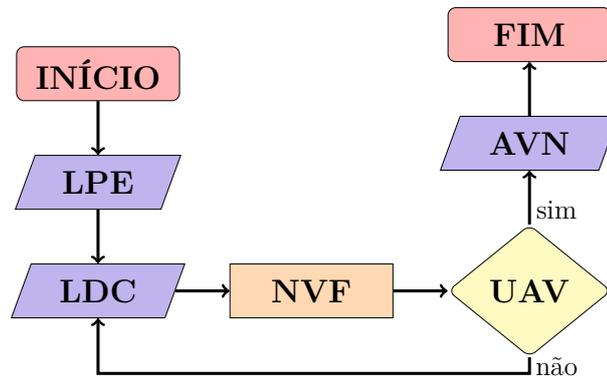
Figura 14 – Estrutura proposta para o módulo MEF. As siglas utilizadas são explicadas no texto.



Fonte: Produzido pelo autor.

- INÍCIO;
- MNF P.1: Leitura dos Parâmetros de Entrada (LPE);
- MNF P.2: Leitura dos Dados Compactados (LDC);
 - Repetir:
 - MNF P.3: Normalização dos Vetores de *Features* (NVF), conforme técnica indicada nos parâmetros de entrada;
 - Enquanto houver arquivos com vetores de *features* no diretório indicado nos parâmetros de entrada (Rotina Último Arquivo de Vetores - UAV);
- MNF P.4: Armazenar Vetores Normalizados (AVN) em um arquivo de texto no padrão ASCII separando as *features* por ponto e vírgula;
- FIM.

Figura 15 – Estrutura proposta para o módulo MNF. As siglas utilizadas são explicadas no texto.



Fonte: Produzido pelo autor.

3.2.3 MPFE

Após a normalização de todos os vetores, emprega-se a PFE para analisar a qualidade e a influência do conjunto de *features* obtido sobre o problema de classificação. O módulo recebe o diretório dos arquivos gerados pelo MNF e aplica a PFE considerando os subgrupos possíveis de *features*, tanto para os índices na ordem crescente quanto para suas combinações. Para cada subgrupo, gera-se um arquivo de texto para salvar as informações obtidas, como o número de *features* usadas, o ponto P , a distância de P ao vértice $(1, 0)$ e os índices das *features* consideradas.

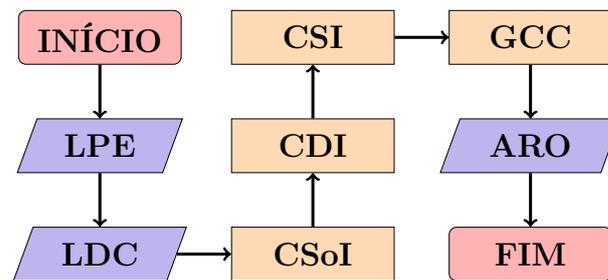
Os passos para a implementação do algoritmo proposto para o MPFE, que são ilustrados na [Figura 16](#), são descritos a seguir.

- **INÍCIO**;
- **MPFE P.1:** Leitura dos Parâmetros de Entrada (LPE);
- **MPFE P.2:** Leitura dos Dados Compactados (LDC);
- **MPFE P.3:** Cálculo das Sobreposições Interclasses (CSoI) conforme **P.2** descrito na [subseção 2.3.1](#). Esta rotina avalia o número de sobreposições entre as classes a fim de determinar se estas são ou não linearmente separáveis;
- **MPFE P.4:** Cálculo da Dissimilaridade Interclasse (CDI) conforme **P.3** descrito na [subseção 2.3.1](#) e denotado por β ;
- **MPFE P.5:** Cálculo da Similaridade Intraclasse (CSI) conforme **P.4** descrito na [subseção 2.3.1](#) e denotado por α ;
- **MPFE P.6:** Cálculo do Grau de Certeza e Contradição (GCC) conforme **P.5** descrito na [subseção 2.3.1](#). O ponto P resultante sinaliza a qualidade de cada conjunto analisado;

- **MPFE P.7:** Armazenar Resultados Obtidos (ARO) em um arquivo de texto no padrão ASCII separando as informações por ponto e vírgula;
- **FIM.**

Assim como os outros módulos, após o processamento de todos os arquivos contendo os vetores normalizados, os arquivos de texto gerados são compactados no formato “zip”.

Figura 16 – Estrutura proposta para o módulo MPFE. As siglas utilizadas são explicadas no texto.



Fonte: Produzido pelo autor.

3.2.4 MTT

Uma vez que todos os subconjuntos de vetores tenham sido obtidos, combinando as *features* tanto na ordem crescente dos índices quanto em suas combinações, além de aplicar a PFE, é importante que essas entradas sejam submetidas a um classificador para avaliar a eficácia da proposta. Esse é o papel do MTT. O módulo recebe os diretórios dos resultados de MNF e MPFE, a porcentagem de vetores a serem usados para treinamento da SVM, o número de *features*/atributos a serem considerados, o formato de seleção das *features* (ordem crescente ou combinação) e seus índices, *kernel* para o modelo (linear, RBF, polinomial ou sigmod), parâmetro C de regularização da superfície de decisão e o parâmetro γ , que indica a influência de cada vetor de treinamento (usado apenas nos kernels RBF, sigmoid e polinomial).

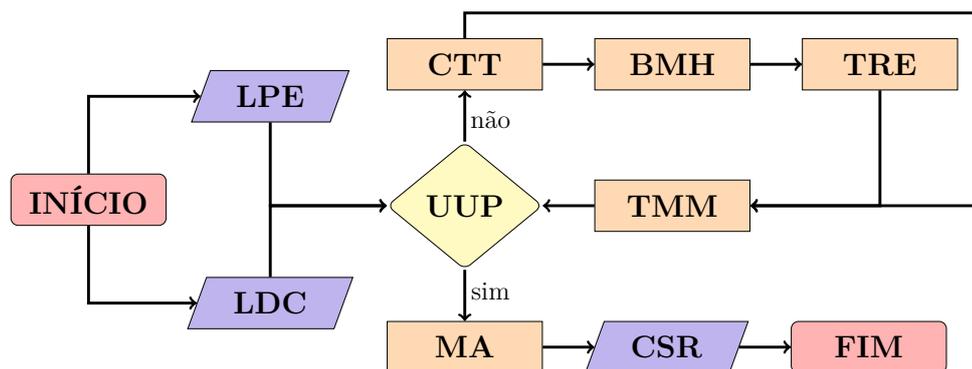
Os passos para a implementação do algoritmo proposto para o MTT, que são ilustrados na [Figura 17](#), são descritos a seguir.

- **INÍCIO;**
- **MTT P.1:** Leitura dos Parâmetros de Entrada (LPE);
- **MTT P.2:** Leitura dos Dados Compactados (LDC);

- **Repetir:**

- **MTT P.3:** Os Conjuntos de Treinamento e Testes (CTT) são divididos de acordo com a porcentagem especificada na etapa anterior;
 - **MTT P.4:** O processo de Buscar Melhores Hiperparâmetros (BMH) é realizado executando a função *GridSearchCV* da biblioteca *scikit-learn*. Esta função realiza uma busca exaustiva sobre os hiperparâmetros específicos indicados para o classificador, utilizando a técnica de validação cruzada por *k*-partes;
 - **MTT P.5:** Após a seleção do melhor modelo no passo anterior, este é reajustado com todos os dados de treinamento, utilizando os hiperparâmetros que apresentaram o melhor desempenho na validação cruzada. Esta etapa é denominada Treinamento (TRE);
 - **MTT P.6:** Executa o Teste do Melhor Modelo (TMM) com o conjunto de teste criado no passo **P.3**, treinado no passo anterior;
- Enquanto a Última Unidade de Porcentagem (UUP) para formar o conjunto de treinamento não tenha sido processada;
- **MTT P.7:** Ao final do processo, o sistema apresenta as porcentagens de amostras correspondentes para treino e os hiperparâmetros empregados para o modelo que obteve a Melhor Acurácia (MA).
 - **MTT P.8:** Compactar e Salvar os Resultados (CSR);
 - **FIM.**

Figura 17 – Estrutura proposta para o módulo MTT. As siglas utilizadas são explicadas no texto.



Fonte: Produzido pelo autor.

3.2.5 MVGR

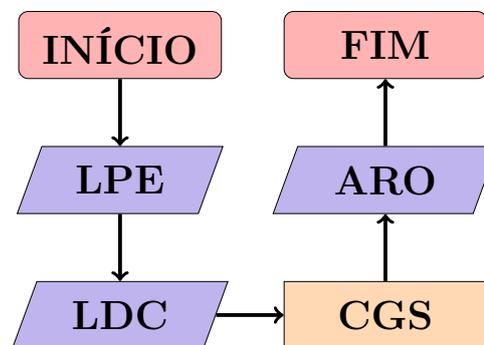
O módulo MVGR é importante principalmente para a visualização e interpretação dos dados produzidos pelo sistema, durante a busca pelos melhores parâmetros para o modelo classificador.

O processo se inicia com a leitura dos arquivos contendo os resultados dos módulos MEF, MNF, MPFE e MTT, produzindo os gráficos indicados nos parâmetros de entrada.

Os passos para a implementação do algoritmo proposto para o MPFE, que são ilustrados na [Figura 18](#), são descritos a seguir.

- **INÍCIO**;
- **MVGR P.1:** Leitura dos Parâmetros de Entrada (LPE);
- **MVGR P.2:** Leitura dos Dados Compactados (LDC);
- **MVGR P.3:** Criação dos Gráficos Solicitados (CGS) nos parâmetros de entrada;
- **MVGR P.4:** Armazenar Resultados Obtidos (ARO) em um arquivo no formato “pdf”;
- **FIM.**

Figura 18 – Estrutura proposta para o módulo MVGR. As siglas utilizadas são explicadas no texto.



Fonte: Produzido pelo autor.

3.2.6 MAP

A implementação prática do sistema contendo o modelo do classificador treinado compõe o MAP, que reúne os módulos MEF e MNF junto ao modelo SVM configurado com os melhores parâmetros definidos no MTT.

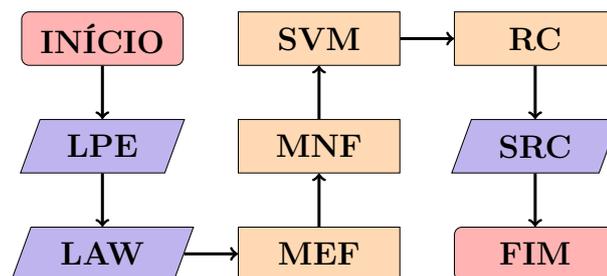
O módulo recebe um arquivo de áudio no formato WAV, a partir do qual são extraídas as *features* e que constituem o vetor que representa o sinal. Após a normalização, o vetor é submetido a um modelo previamente treinado, que classifica o sinal. Este módulo representa uma condensação dos procedimentos que foram aplicados de maneira exaustiva, explorando todas as combinações possíveis até a definição dos parâmetros ideais,

configurados para ótima performance em aplicações em campo. Os experimentos conduzidos para a determinação destes parâmetros serão detalhados no capítulo subsequente.

Os passos para a implementação do algoritmo proposto para o MAP, que são ilustrados na [Figura 19](#), são descritos a seguir.

- **INÍCIO**;
- **MAP P.1:** Leitura dos Parâmetros de Entrada (LPE);
- **MAP P.2:** Leitura do Arquivo WAV (LAW);
- **MAP P.3:** Extração das *features* pelo módulo MEF, descrito na [subseção 3.2.1](#);
- **MAP P.4:** Normalização das *features* pelo módulo MNF, descrito na [subseção 3.2.2](#);
- **MAP P.5:** Aplicação do modelo SVM configurado com os parâmetros que forneceram os melhores resultados na etapa de treinamento, executada pelo módulo MTT descrito na [subseção 3.2.4](#);
- **MAP P.6:** Resultado da Classificação (RC);
- **MAP P.7:** Salvar Resultados de Classificação (SRC) em um arquivo de texto no padrão ASCII nomeado com o mesmo nome do arquivo de áudio;
- **FIM.**

Figura 19 – Estrutura proposta para o módulo MAP. As siglas utilizadas são explicadas no texto.



Fonte: Produzido pelo autor.

Neste capítulo, delineamos a metodologia proposta para este estudo, elucidando os módulos criados e suas respectivas funções. O próximo Capítulo abordará os ensaios realizados e os resultados alcançados com a aplicação do sistema desenvolvido.

4 Testes e Resultados

Neste capítulo, descrevem-se os experimentos conduzidos em laboratório, objetivando a classificação acústica para detectar e estimar a densidade de cigarras. Os principais objetivos deste capítulo incluem:

1. Aplicar a HHT para extração de características dos sinais acústicos (módulos MEF e MNF);
2. Avaliar, via PFE (módulo MPFE), os conjuntos de vetores extraídos com intuito de:
 - a) Verificar se sinais com menor tempo e taxas de amostragem, bem como a variação dos parâmetros dos critérios de parada da EMD, podem alcançar resultados comparáveis aos de configurações mais rigorosas;
 - b) Investigar se diferentes técnicas de normalização (MN, MMN e NLS) e distintas abordagens de extração de *features* (F1 e F2) levam a uma melhor PFE;
 - c) Avaliar a eficácia de vetores com um número reduzido de atributos, selecionando as combinações mais otimizadas com base na PFE;
3. Determinar a acurácia do classificador SVM, selecionado para a detecção e estimativa da densidade das cigarras (módulo MTT).

Posto isto, detalham-se os procedimentos e ferramentas utilizados nos experimentos na seção “Materiais e Métodos”, que estabelece a base experimental e técnica do estudo. Em “Ensaio Realizados”, apresentam-se as etapas experimentais e os procedimentos testados. Na seção “Dispositivos IoT”, discorre-se sobre a integração da tecnologia no contexto da pesquisa. Continuando, aborda-se o desenvolvimento de um “Protótipo de Aplicativo para Celulares”, uma ferramenta essencial para estudos futuros. Por fim, comentários gerais sobre os resultados, consolidando os *insights* e descobertas mais significativos da pesquisa encerram o Capítulo.

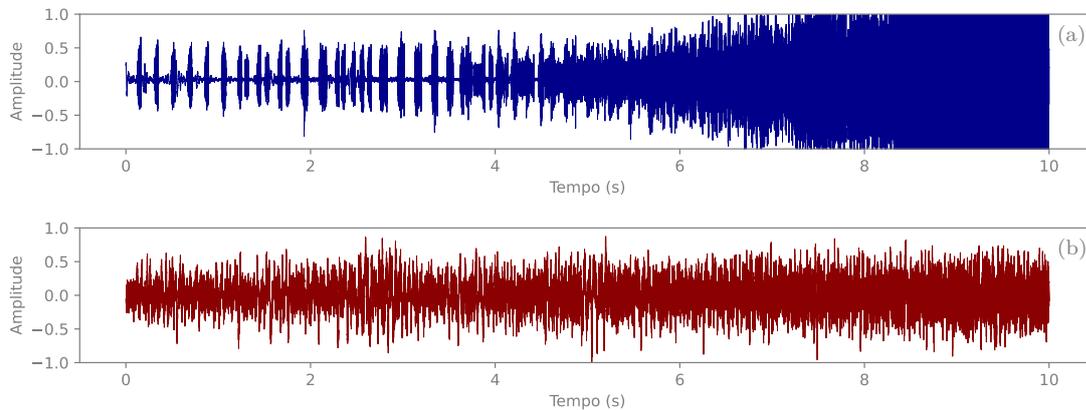
4.1 Materiais e Métodos

Os módulos descritos no Capítulo anterior e os experimentos detalhados neste Capítulo foram implementados na linguagem *Python*, versão 3.8.8. Os testes foram conduzidos em um computador equipado com Intel(R) Core(TM) i7-7700HQ CPU @ 2.80GHz, 16 GB RAM e sistema operacional *Windows* 10 de 64 bits. Vale destacar que, em todos os ensaios, seis processos foram executados em paralelo, cada um consumindo, em média,

15% da capacidade total do processador. Essa informação é relevante para a interpretação dos dados temporais discutidos nas seções subsequentes.

As amostras sonoras empregadas nos experimentos, coletadas no formato WAV, foram obtidas por um agrônomo membro do grupo de pesquisa usando *smartphones* e gravadores digitais com taxa de amostragem de 44.1 kHz e resolução de 16 bits por amostra. As coletas foram realizadas durante visitas entre os anos de 2016 e 2019 em plantações de café situadas nos Estados de São Paulo e Minas Gerais. Os arquivos, rotulados conforme cada classe para os experimentos subsequentes, foram cuidadosamente organizados e categorizados manualmente pelo mesmo agrônomo. A classe “cigarra” contém sons de *Quesada gigas*, apenas de machos ativos, enquanto a classe “ruído” é composta por sons de dispositivos mecânicos, pássaros, animais em geral, fala e outros, que serão considerados ruído pelo sistema proposto. A Figura 20 apresenta exemplos de dois sinais acústicos, correspondentes às classes “cigarra” e “ruído”, utilizados nos experimentos descritos neste Capítulo.

Figura 20 – Exemplos de sinais acústicos normalizados: (a) correspondente à classe “cigarra” e (b) à classe “ruído”. Ambos possuem uma taxa de amostragem de 44.1 kHz e duração de 10 segundos.



Fonte: Produzido pelo autor.

Conforme apresentado no Capítulo anterior, a proposta estrutura-se em seis módulos distintos: MEF, MNF, MEPC, MTT, MVGR e MAP. Nas próximas subseções, detalha-se a implementação de cada módulo, proporcionando uma visão mais aprofundada da abordagem adotada. Esse nível de detalhamento não só esclarece os mecanismos internos do sistema, mas também visa facilitar sua replicação e adaptação em diferentes cenários e contextos.

4.1.1 MEF

Conforme descrito no capítulo anterior, o módulo MEF tem a função de processar os arquivos no formato WAV. A partir dos dados brutos desses arquivos, o módulo realiza

as etapas da HHT seguindo um critério de parada estabelecido. Em seguida, a partir do sinal transformado, são gerados os vetores de *features*, os quais são empregados como variáveis de entrada nos módulos subsequentes. Para a elaboração do módulo em questão, recorreu-se às seguintes bibliotecas da linguagem *Python*:

- Biblioteca “*os*” (MARTELLI, 2003) para interagir com o sistema operacional, incluindo gerenciar leitura e gravação de arquivos, diretórios e outras funcionalidades dependentes do sistema;
- Biblioteca “*numpy*” (IDRIS, 2015) para operações numéricas com vetores e matrizes de forma otimizada e suporte a uma ampla variedade de funções matemáticas;
- Biblioteca “*scipy*” (AYYADEVARA et al., 2017), que oferece o método “*CubicSpline*” empregado na implementação da EMD, “*wavfile*” para leitura de arquivos de áudio e “*signal.resample*” para reamostragem de sinais.
- Biblioteca “*timeit*” (BEAZLEY, 2009) para medir o tempo gasto em cada processo;
- Biblioteca “*numba*” (ANTAO, 2023) para acelerar funções *Python*, incluindo suporte para aceleração via GPU.
- Biblioteca “*multiprocessing*” (NELLI, 2023) para execução de processos paralelos em múltiplos núcleos do CPU;
- Biblioteca “*zipfile*” (MARTELLI, 2003) para compactar os arquivos de texto gerados.

Embora existam bibliotecas específicas para os métodos EMD e HT, optou-se, no contexto desta pesquisa, por não utilizá-las. Ambas as metodologias foram desenvolvidas a partir dos princípios fundamentais discutidos no Capítulo 2, com base nos critérios de parada mencionados, conforme detalhado nas referências apresentadas. Este processo foi de extrema importância para o entendimento da teoria e implementação prática do estudo.

4.1.2 MNF

O módulo MNF tem a finalidade de normalizar os vetores gerados pelo módulo MEF. Para sua implementação, utilizaram-se as definições apresentadas na seção 2.5, bem como as bibliotecas “*os*”, “*numpy*”, “*multiprocessing*” e “*zipfile*” mencionadas na subseção anterior.

4.1.3 MPFE

O módulo MPFE permite o estudo da seleção de *features* com base na menor distância entre o ponto P calculado e o VO. Para seu desenvolvimento, utilizaram-se as

especificações descritas por Guido (2019), introduzidas na seção 2.3. Na implementação do módulo, empregaram-se as bibliotecas “os”, “numpy”, “numba”, “multiprocessing” e “zipfile”, mencionadas na subseção 4.1.1. Adicionalmente, a biblioteca “itertools” (HUNT, 2019) foi utilizada; ela oferece uma série de ferramentas para criação de iteradores que permitem operações eficientes com sequências. Essa biblioteca foi particularmente útil para listar todas as possíveis combinações entre as *features*, para a posterior análise individual através da PFE.

4.1.4 MTT

O módulo MTT é encarregado das etapas de treinamento e teste do modelo SVM. Também foi implementado usando as bibliotecas “os”, “numpy”, “multiprocessing” e “zipfile”, descritas na subseção 4.1.1. Adicionalmente, empregou-se a biblioteca *scikit-learn* (AMR, 2020), uma das ferramentas mais populares atualmente em *Python* para aprendizado de máquina. Ela oferece ferramentas simples e eficientes para análise de dados, com ênfase em métodos de aprendizado supervisionado e não supervisionado. Dentro desta biblioteca, foram particularmente utilizados:

- A classe “*svm*”, que permite a implementação e treinamento de SVMs para classificação e regressão;
- A função “*train_test_split*”, utilizada para dividir conjuntos de dados em subconjuntos de treinamento e teste, facilitando a validação do modelo;
- A ferramenta “*GridSearchCV*”, para busca e otimização de hiperparâmetros por meio de validação cruzada, permitindo encontrar os melhores parâmetros para o modelo;
- O método de particionamento de dados “*KFold*”, para realizar validação cruzada, dividindo o conjunto de dados em “*k*” subconjuntos;
- O módulo “*metrics*”, que oferece funções de avaliação, permitindo medir a acurácia e outras métricas de desempenho de um modelo.

4.1.5 MVGR

O módulo MVGR é encarregado de gerar as visualizações gráficas dos resultados fornecidos pelos demais módulos. Sua implementação contou com as bibliotecas “os”, “zipfile” e “*Matplotlib*” (YIM; CHUNG; YU, 2018). As duas primeiras, descritas na subseção 4.1.1, são empregadas para acesso e leitura dos dados gerados pelos outros módulos. Já a biblioteca “*Matplotlib*” é uma das principais ferramentas disponíveis atualmente em *Python* para criação de gráficos e visualizações de dados, permitindo a produção de uma

ampla variedade de visualizações estáticas, animadas e interativas em diversos formatos. Essa biblioteca foi essencial para a representação visual dos resultados, permitindo a análise e interpretação dos dados gerados.

4.1.6 MAP

Conforme detalhado na [seção 3.1](#), o módulo MAP é integrado pelos módulos MEF e MNF, juntamente com o modelo SVM ajustado conforme os melhores parâmetros determinados exaustivamente pelo MTT nos experimentos realizados. Este último processo envolve a exploração de todas as combinações viáveis até a identificação dos parâmetros ideais, otimizados para uma alta performance em aplicações no campo. Vale ressaltar que os algoritmos constituintes do módulo MAP podem ser adaptados conforme a linguagem de programação específica do dispositivo alvo.

4.2 Experimentos Realizados

Nesta seção, apresentam-se os resultados dos experimentos realizados em laboratório, organizados em três grupos: G1, G2 e G3. Estes visam a investigação sobre detecção de cigarras e estimativa de densidade, conforme [Tabela 4](#).

Tabela 4 – Grupos de experimentos. F1 indica os vetores de *features* definidos pelas energias das IMFs, F2 pelas energias dispostas conforme frequências das IMFs na EB e $C(25, N)$ a combinação de 25 *features* tomadas de N em N .

Grupo	Classificação	Classes	Amostras	Features	Vetores de <i>features</i>
G1	detecção	cigarras e ruído	1526	F1	primeiras N
G2	detecção	cigarras e ruído	1526	F2	primeiras N e melhor $C(25, N)$
G3	densidade	alta, baixa e ruído	315	F2	melhor $C(25, N)$

Fonte: Elaborada pelo autor.

Os grupos G1 e G2 dispõem de um total de 1526 sinais acústicos, divididos igualmente entre as classes “cigarra” e “ruído”, destinados aos treinamentos dos classificadores SVM para detecção de cigarras. Por outro lado, o grupo G3 dispõe de um total de 315 sinais acústicos, distribuídos igualmente entre as classes “alta”, “baixa” e “ruído”, destinados aos treinamentos dos classificadores SVM para estimativa de densidade de cigarras na lavoura.

Foram conduzidos 9 experimentos: 5 associados ao grupo G1, 2 ao G2 e 2 ao G3, conforme [Tabela 5](#). Essa sequência experimental visa demonstrar que sinais acústicos com características modificadas, como tempo e taxa de amostragem reduzidos, aliados a parâmetros da EMD menos rigorosos, têm potencial para produzir resultados comparáveis

àqueles obtidos com configurações mais complexas. Adicionalmente, explorou-se a otimização dos desempenhos dos modelos através da variação das técnicas de normalização dos vetores. A hipótese é que tais estratégias podem reduzir o custo computacional e, conseqüentemente, viabilizar o desenvolvimento de dispositivos práticos para aplicação em lavouras, conforme discutido anteriormente.

Tabela 5 – Experimentos realizados em cada grupo, onde F e V indicam as configurações fixas e variáveis, respectivamente.

Grupos Experimentos	G1					G2		G3	
	E1	E2	E3	E4	E5	E6	E7	E8	E9
Taxa de amostragem	F	F	V	F	F	F	F	F	F
Comprimento do sinal	F	V	F	F	F	F	F	F	F
Critério de parada da EMD	V	V	V	V	V	V	V	V	V
Parâmetros da EMD	F	F	F	V	F	F	F	F	F
Normalização das <i>features</i>	F	F	F	F	V	V	V	V	V
Número de <i>features</i>	V	V	V	V	V	V	V	V	V

Fonte: Elaborada pelo autor.

Os hiperparâmetros do modelo SVM são cruciais para o desempenho do modelo adotado. Como mencionado na [subseção 4.1.4](#), nesta pesquisa os hiperparâmetros foram determinados por meio de uma busca em grade utilizando a função “*GridSearchCV*” da biblioteca “*scikit-learn*”. Esta função analisa cada combinação possível de hiperparâmetros predefinidos. Durante este processo, é utilizada a técnica de validação cruzada por k -partes para garantir que o modelo seja robusto e não esteja apenas se ajustando bem aos dados de treinamento, mas que também possa manter uma boa performance em dados não vistos. O principal critério de seleção, neste contexto, é maximizar a acurácia do modelo. A [Tabela 6](#) detalha os hiperparâmetros considerados na busca em grade, os quais foram utilizados em todos os experimentos.

Tabela 6 – Hiperparâmetros considerados na busca em grade no módulo MTT. O termo “Poly” refere-se ao *kernel* Polinomial.

Atributos de Ajuste	Parâmetros
<i>kernel</i>	Linear, RBF, Poly, Sigmoid
C	10^{-3} , 10^{-2} , 1, 10^2 , 10^3
γ	10^{-3} , 10^{-2} , 10^{-1} , 1, 10^1 , 10^2 , 10^3
Amostras Treino (%)	20, 30, 40, 50, 60, 70, 80

Fonte: Elaborada pelo autor.

Em todos os experimentos, o número máximo de iterações para treinamento do modelo SVM foi estipulado em 2000. Esse parâmetro foi adotado visando evitar a convergência prolongada ou possíveis loops infinitos, assegurando assim eficiência computacional e tempos de treinamento aceitáveis. Relativamente ao processo de validação cruzada, para os grupos G1 e G2, estabeleceu-se um total de $k = 10$ partições. No entanto, para o grupo G3, devido ao menor volume de amostras, optou-se por um total de $k = 3$ partições. Quanto

aos escalares de saída para o modelo SVM, que representam cada classe, considerou-se para as classes “cigarra” e “ruído”, no caso de detecção, os escalares 1 e -1 , respectivamente. Já no caso de estimativa de densidade, considerou-se os escalares 1, 0 e -1 para representarem as classes “alta”, “ruído” e “baixa”, respectivamente.

Por fim, vale ressaltar que, os parâmetros “grau do polinômio” (denotado por d) e “deslocamento” (denotado por r), pertinentes aos *kernels* Polinomial e Sigmoid (conforme apresentados nas Equações 3.4 e 3.5, respectivamente), adotaram os valores preestabelecidos pela biblioteca “*scikit-learn*”, sendo especificados como: $d = 3$ e $r = 0$.

4.2.1 Grupo G1

Neste grupo, encontram-se os experimentos associados à detecção de cigarras através da discriminação entre as classes “cigarra” e “ruído”. Os vetores de *features* foram determinados a partir das energias das IMFs dos sinais acústicos, em ordem de extração, ou seja, no formato F1.

4.2.1.1 Experimento E1

O experimento E1 foi realizado com os sinais no formato original em que foram catalogados, possuindo uma taxa de amostragem de 44.1 kHz e duração de 10 segundos. A hipótese neste experimento é que o sistema proposto, empregando tais sinais, possa indicar com precisão a presença ou ausência de cigarras. Para o processamento pela EMD, foram adotados 8 critérios de parada distintos, os quais estão detalhados no Capítulo 2. Os parâmetros iniciais, específicos para cada critério foram definidos com base em exemplos disponíveis nos artigos científicos citados no Capítulo 2 e estão listados na Tabela 7.

Definir o número máximo de iterações por IMFs é importante, principalmente para o critério BWC, que interrompe o SP somente após encontrar o mínimo de B_f^2 , podendo, na maioria dos casos, resultar no excesso de iterações. Assim, estabeleceu-se o número máximo de iterações para o SP da EMD em 700.

Tabela 7 – Configurações para o experimento E1 do grupo G1.

Rótulos	Amostragem (kHz)	Tempo (s)	Configurações da EMD		Norma	It. Max.
			Critério de parada	Parâmetros		
SD-E1-G1			SD	$\varepsilon = 0.1$		
SSC-E1-G1			SSC	$S = 3$		
TTC-E1-G1			TTC	$\alpha = 0.05, \theta_1 = 0.05, \theta_2 = 0.5$		
EDT-E1-G1	44.1	10	EDT	$\varepsilon = 0.001$	MN	700
RFC-E1-G1			RFC	$R = 50$		
OC-E1-G1			OC	$\varepsilon = 0.05$		
VDS-E1-G1			VDS	95% de $m(t) < 0.005$		
BWC-E1-G1			BWC	mínimo de B_f^2 encontrado		

Fonte: Elaborada pelo autor.

Os vetores de *features* que representam cada sinal foram construídos no formato F1, ou seja, com base nas energias das IMFs obtidas pela EMD (módulo MEF). Posteriormente,

estas energias foram normalizadas utilizando a técnica MN (módulo MNF). Esse procedimento visa minimizar eventuais variações de escala que poderiam impactar negativamente as análises nos módulos subsequentes, MPFE e MTT. A seguir, os resultados dos módulos são apresentados.

E1-G1: Resultados do Módulo MEF

Conforme explanado, neste experimento, a taxa de amostragem e o comprimento dos sinais são fixos (Tabela 7). O módulo decompõe cada sinal acústico recebido em IMFs através da EMD, que é aplicada iterativamente até que as proto-IMFs satisfaçam um critério de parada ou se exceda 700 iterações por componente. Esse passo é repetido para todos os critérios de parada. Para cada sinal, os vetores de *features* são extraídos no formato F1 (explicado na subseção 3.2.1) e salvos junto a um relatório contendo o número de IMFs obtidas, as iterações por IMF e o IO de cada decomposição, conforme detalhado no Capítulo 3.

O impacto causado por cada critério de parada sobre o número de iterações e IMFs pode ser comparado na Tabela 8, a qual contém os resultados de decomposições do sinal acústico correspondente a classe “cigarra” apresentado na Figura 20.

Tabela 8 – Número de IMFs e iterações do SP em cada configuração de E1-G1.

Componentes	SD-E1-G1	SSC-E1-G1	TTC-E1-G1	EDT-E1-G1	RFC-E1-G1	OC-E1-G1	VDS-E1-G1	BWC-E1-G1
IMF 1	1	700	700	4	152	152	451	700
IMF 2	2	700	700	6	116	116	157	700
IMF 3	2	700	700	9	137	302	92	700
IMF 4	2	700	700	10	52	30	11	700
IMF 5	2	700	700	13	39	24	4	700
IMF 6	2	55	54	4	49	31	5	700
IMF 7	2	165	121	13	74	24	4	700
IMF 8	2	76	700	5	103	24	3	700
IMF 9	2	53	72	7	54	146	1	264
IMF 10	2	74	36	4	41	26	1	700
IMF 11	2	12	313	8	45	31	1	190
IMF 12	2	18	272	6	47	42	1	700
IMF 13	-	10	78	6	36	19	1	700
IMF 14	-	25	700	-	59	22	1	700
IMF 15	-	5	17	-	128	19	-	700
IMF 16	-	5	14	-	700	4	-	166
IMF 17	-	14	5	-	11	1	-	31
IMF 18	-	-	367	-	4	-	-	455
IMF 19	-	-	700	-	-	-	-	20
IMF 20	-	-	9	-	-	-	-	6
IMF 21	-	-	-	-	-	-	-	356
IMF 22	-	-	-	-	-	-	-	700

Fonte: Elaborada pelo autor.

Dado o conteúdo da Tabela 8, observa-se uma notável variabilidade entre os conjuntos, manifestada por diferentes quantidades de IMFs e iterações do SP. Tal variabilidade é atribuída às características singulares impostas por cada critério de parada e seus respectivos parâmetros, conforme elucidado na subseção 2.2.2. Em termos gerais, a configuração SD-E1-G1 resultou no menor número de IMFs e iterações, seguida pela configuração EDT-E1-G1. Em contrapartida, BWC-E1-G1 apresentou o maior número de IMFs e figura

entre as configurações que requerem um elevado número de iterações, implicando, assim, em um maior custo computacional.

É relevante destacar que as características intrínsecas de cada sinal podem conduzir a decomposições com diferentes quantidades de componentes sob um mesmo critério de parada, circunstância que se revela particularmente desafiadora e inconveniente (SOUZA; ESCOLA; BRITO, 2022). Tal desafio pode ser contornado mediante o ajuste criterioso dos parâmetros em cada decomposição, quando necessário. No contexto da pesquisa delineada nesta tese, optou-se por manter constantes os parâmetros da EMD. Adicionalmente, os vetores de *features*, determinados pelas energias das IMFs, foram preenchidos com zeros, conforme discutido na subseção 3.2.1.

Ao aplicar a EMD aos conjuntos de vetores que representam os sinais acústicos, determinam-se as energias das respectivas IMFs, o número máximo de IMFs por critério (incluindo o resíduo), o número de iterações por IMF e os IOs. Enquanto o número de iterações por IMF fornece uma perspectiva quantitativa da decomposição, o IO exprime sua qualidade.

Na Tabela 9, são ilustrados dois exemplos das energias das IMFs derivadas de sinais associados às classes “cigarra” e “ruído”, empregando a configuração SD-E1-G1. Observe que as decomposições produziram quantidades diferentes de IMFs, conforme discutido anteriormente.

Tabela 9 – Exemplos de energias das IMFs, extraídas de dois sinais correspondentes às classes “cigarra” e “ruído”, utilizando a configuração SD-E1-G1.

IMFs	1	2	3	4	5	6	7	8	9	10	11	12	13
Cigarra	5113.39252	370.96874	69.72392	20.72002	9.20611	3.27125	1.86296	1.19867	0.58929	0.08996	0.07289	0.20585	0.21090
Ruído	3574.43071	92.27654	110.33823	299.80177	3184.72808	6765.18416	3203.28722	470.58021	138.11117	40.88130	256.07933	276.71173	-

Fonte: Elaborada pelo autor.

A Tabela 10 apresenta os números máximos de IMFs alcançados por cada configuração. Conforme discutido anteriormente sobre a Tabela 8, as configurações BWC-E1-G1 e SD-E1-G1 retornaram, respectivamente, o maior e o menor número de IMFs.

Tabela 10 – Quantidade máxima de IMFs por configuração em E1-G1, incluindo o resíduo.

	SD-E1-G1	SSC-E1-G1	TTC-E1-G1	EDT-E1-G1	RFC-E1-G1	OC-E1-G1	VDS-E1-G1	BWC-E1-G1
M	14	24	26	18	21	20	21	29

Fonte: Elaborada pelo autor.

As iterações por IMF para cada configuração, cujas médias estão listadas na Tabela 11 e foram arredondadas utilizando a função teto (GRAHAM; KNUTH; PATASHNIK, 1994), são ilustradas nos subseqüentes gráficos de coordenadas paralelas (INSELBERG, 2009). Em tais gráficos, cada eixo denota uma IMF específica, e a intersecção de uma linha com um eixo indica o número de iterações necessárias para a extração da respectiva IMF. Dessa forma, uma linha que conecta dois eixos simboliza uma execução parcial da EMD.

Tabela 11 – Número máximo de IMFs, bem como a média de iterações do SP para cada classe em diferentes configurações. Onde “C” representa a classe “cigarra” e “R” a classe “ruído”.

Componentes	SD-E1-G1		SSC-E1-G1		TTC-E1-G1		EDT-E1-G1		RFC-E1-G1		OC-E1-G1		VDS-E1-G1		BWC-E1-G1	
	C	R	C	R	C	R	C	R	C	R	C	R	C	R	C	R
IMF 1	4	3	691	690	673	671	7	10	222	48	374	322	484	371	697	700
IMF 2	3	4	663	668	647	660	7	15	194	34	254	167	428	94	699	700
IMF 3	3	4	599	626	601	585	9	14	96	36	149	96	251	76	697	700
IMF 4	3	4	471	532	522	517	11	11	47	39	64	71	62	57	692	694
IMF 5	3	4	289	420	423	442	9	9	45	45	42	56	27	49	689	682
IMF 6	3	3	192	335	342	381	9	8	54	52	36	47	26	43	663	660
IMF 7	3	2	156	269	284	338	11	10	58	59	34	41	23	37	643	647
IMF 8	3	3	117	233	251	314	15	14	61	69	31	37	14	33	617	640
IMF 9	3	3	78	204	207	285	18	20	53	72	31	33	8	21	599	611
IMF 10	3	3	50	163	154	229	18	27	56	67	31	32	6	11	569	580
IMF 11	3	3	27	126	109	177	23	23	56	62	28	30	5	6	550	544
IMF 12	3	2	20	89	91	150	23	30	56	74	27	28	5	4	499	488
IMF 13	2	2	16	42	80	118	28	39	69	87	25	24	3	3	448	436
IMF 14	-	-	13	19	92	81	59	48	78	103	21	23	7	3	407	390
IMF 15	-	-	10	12	86	63	55	62	105	117	20	22	8	3	354	378
IMF 16	-	-	10	9	86	82	51	91	115	139	15	19	12	5	275	355
IMF 17	-	-	8	7	112	68	-	7	120	97	11	13	79	65	283	315
IMF 18	-	-	9	8	130	85	-	-	97	74	8	12	42	700	260	252
IMF 19	-	-	16	7	143	77	-	-	46	58	3	3	3	700	273	233
IMF 20	-	-	10	7	143	76	-	-	33	33	-	-	-	700	267	259
IMF 21	-	-	9	6	174	71	-	-	-	-	-	-	-	-	277	269
IMF 22	-	-	5	5	168	89	-	-	-	-	-	-	-	-	310	288
IMF 23	-	-	4	-	262	113	-	-	-	-	-	-	-	-	313	246
IMF 24	-	-	-	-	117	38	-	-	-	-	-	-	-	-	404	278
IMF 25	-	-	-	-	43	-	-	-	-	-	-	-	-	-	404	323
IMF 26	-	-	-	-	-	-	-	-	-	-	-	-	-	-	470	173
IMF 27	-	-	-	-	-	-	-	-	-	-	-	-	-	-	700	252
IMF 28	-	-	-	-	-	-	-	-	-	-	-	-	-	-	4	-

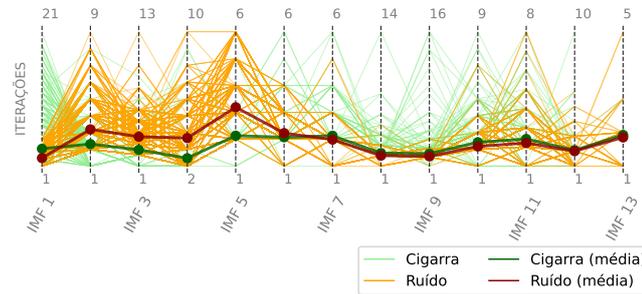
Fonte: Elaborada pelo autor.

Optou-se por esta representação devido à sua eficácia na análise quantitativa do processo em questão. Esta abordagem converte relações multivariáveis em padrões bidimensionais, que são mais acessíveis e adequados para exploração e análise. Tal representação permite avaliar o custo computacional associado à extração de cada componente do sinal. Além disso, é possível identificar padrões no número de iterações, oferecendo maior compreensão sobre o comportamento do SP da EMD em diferentes configurações. Vale ressaltar que, embora esta abordagem proporcione uma ilustração visual acessível do processo e uma perspectiva quantitativa, ela não oferece informações sobre a qualidade das IMFs extraídas. A avaliação da qualidade será realizada posteriormente por meio do IO.

Para a configuração SD-E1-G1, ilustrada na [Figura 21](#), observa-se que o número de iterações necessárias para a extração das IMFs é consideravelmente baixo, não excedendo 21 iterações, com média situada entre 2 e 4 para ambas as classes. Tal comportamento indica que, para esta configuração, a EMD demonstrou eficiência em termos de velocidade de processamento. Uma observação similar pode ser feita para a configuração EDT-E1-G1, conforme representado na [Figura 22](#). Embora esta última apresente picos relativamente altos para algumas decomposições das IMFs finais, sua média permanece baixa, alinhada à observada para a configuração SD-E1-G1, reforçando a eficiência da decomposição neste cenário.

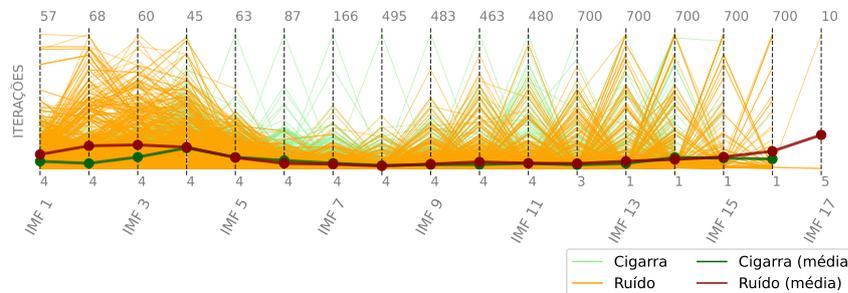
Na configuração SSC-E1-G1, conforme ilustrado na [Figura 23](#), observa-se um

Figura 21 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração SD-E1-G1.



Fonte: Produzido pelo autor.

Figura 22 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração EDT-E1-G1.



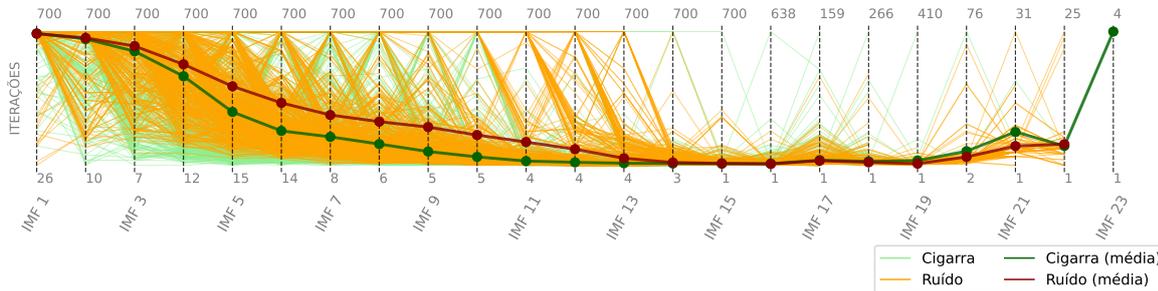
Fonte: Produzido pelo autor.

aumento significativo no número de iterações, particularmente para as primeiras IMFs, atingindo uma média próxima de 700 iterações para ambas as classes. Contudo, este número decresce progressivamente à medida que se extraem IMFs com índices mais elevados, sugerindo um maior esforço para extração das IMFs iniciais nesta configuração específica. Um aspecto notável é que a classe “ruído” apresenta um custo computacional mais elevado, visto que a extração de diversas componentes para esta classe alcança o limite de iterações até a IMF 13. Tal observação pode sinalizar a necessidade de refinamento nos parâmetros do algoritmo ao empregar o critério SSC. Uma tendência análoga é identificada na configuração TTC-E1-G1, representada na [Figura 24](#), embora a média de iterações seja ligeiramente inferior.

Para a configuração RFC-E1-G1, conforme ilustrado na [Figura 25](#), nota-se que o número de iterações é predominantemente elevado nas primeiras e últimas IMFs para a classe “cigarra”. Em contraste, para a classe “ruído”, o maior esforço concentra-se nas últimas IMFs. Embora esta configuração mostre-se mais eficiente quando comparada às configurações SSC-E1-G1 e TTC-E1-G1, ainda assim figura entre as que apresentam elevado custo computacional.

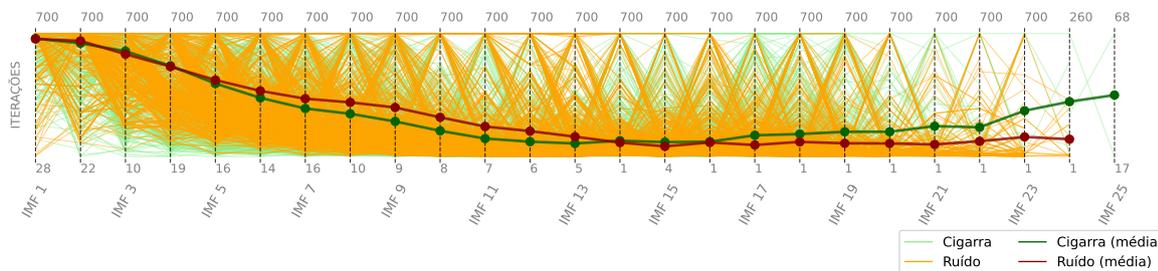
As configurações OC-E1-G1 e VDS-E1-G1 exibem padrões análogos, atingindo o limite de iterações para as primeiras IMFs e decrescendo progressivamente à medida

Figura 23 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração SSC-E1-G1.



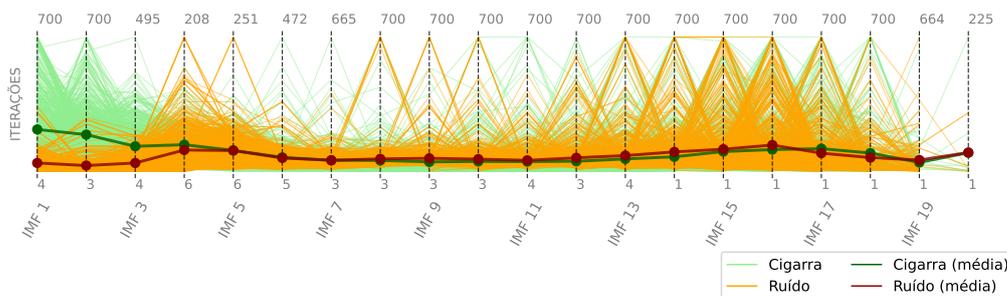
Fonte: Produzido pelo autor.

Figura 24 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração TTC-E1-G1.



Fonte: Produzido pelo autor.

Figura 25 – Gráfico de coordenadas paralelas que ilustra as iterações por IMF dos sinais acústicos empregados no experimento, utilizando a configuração RFC-E1-G1.



Fonte: Produzido pelo autor.

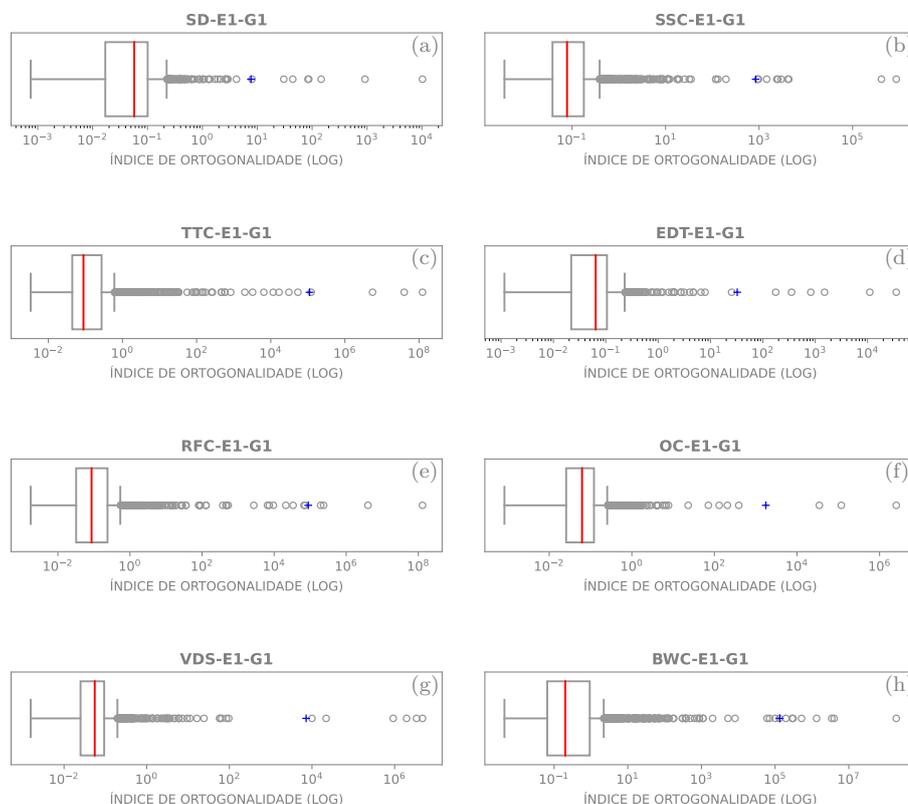
que as IMFs de índices elevados são extraídas, conforme ilustrado nas Figuras 26 e 27. Contudo, é importante destacar que, para a configuração VDS-E1-G1, a classe “ruído” atinge o limite de iterações para as três últimas IMFs em todos os sinais analisados. Tal observação pode indicar que os sinais pertencentes a essa classe apresentam componentes de baixa frequência dominantes, caracterizados por amplitudes elevadas que influenciam significativamente a forma global do sinal. Isso pode resultar em uma envoltória média que se mantém acima do limiar de parada por um período prolongado, culminando em um aumento no número de iterações.

fundamental.

Por outro lado, a qualidade das decomposições em cada configuração foi avaliada pelo IO entre as IMFs, conforme definido na [Equação \(2.16\)](#). Este índice reflete o desempenho do processo de decomposição. Como abordado na [subseção 2.2.3](#), valores de IO próximos a zero indicam que as IMFs possuem baixa correlação entre si, sugerindo que representam componentes independentes do sinal original. Esta independência é uma característica desejável, pois indica que a decomposição conseguiu separar de maneira eficaz as diferentes escalas presentes no sinal. Contudo, conforme destacado por [Huang et al. \(1998\)](#), na prática, as IMFs são “quase” ortogonais, o que implica que o IO raramente atinge o valor zero.

Os diagramas de caixa ilustrados na [Figura 29](#) exibem a distribuição dos IOs associados a cada decomposição, abrangendo todas as configurações consideradas. É perceptível que, na maioria dos cenários, os sinais decompostos possuem IOs relativamente baixos. No entanto, também se destaca a presença de um número considerável de *outliers* com valores substancialmente superiores a 1. A presença desses *outliers* pode indicar que:

Figura 29 – Diagramas de caixa ilustrando os IOs das decomposições para cada configuração. Em cada representação gráfica, a linha vertical situada no interior do retângulo denota a mediana, enquanto o símbolo “+” indica a média.



Fonte: Produzido pelo autor.

1. A energia de certos sinais é extremamente reduzida (inferior a 1), o que resulta em um valor elevado para o quociente da [Equação \(2.16\)](#). Nesse caso, isso ocorre mesmo quando se observa um valor moderado na soma dos produtos internos presentes no numerador;
2. A EMD não foi capaz de decompor os sinais de forma eficaz em componentes ortogonais, levando à geração de um número excessivo de IMFs que não estão plenamente descorrelacionadas ([HUANG et al., 1998](#); [NIU et al., 2021](#)). Tal situação é mais propensa a ocorrer em sinais de elevada complexidade que são submetidos à decomposição com critérios de parada orientados para a satisfação de propriedades mais estritas. Isso pode resultar em um número elevado de iterações no SP. Vale destacar que o SP fundamenta-se na técnica de interpolação para a formação das envoltórias. Assim, um número excessivo de iterações pode comprometer a qualidade da decomposição ([RILLING; FLANDRIN; GONÇALVES, 2003](#)). Erros na interpolação, particularmente nas extremidades dos sinais, têm potencial para se propagar ao longo das iterações, induzindo oscilações artificiais nas IMFs de baixa frequência ([ZHIDONG; YANG, 2007](#)).

Considerando que a menor energia registrada para os sinais analisados, após normalização, é de $1 + 9.65 \cdot 10^{-5}$, conclui-se que o primeiro item não é responsável pelos elevados valores de IO observados. Assim, as decomposições associadas a esses valores são categorizadas como de qualidade inferior. Detalhes sobre o número de *outliers*, bem como informações adicionais acerca da distribuição dos IOs e do tempo médio requerido para as decomposições em todas as configurações, estão elencados na [Tabela 12](#).

Tabela 12 – Detalhes sobre a distribuição dos IOs e o Tempo Médio de Decomposição (TMD), expresso em segundos, para todas as configurações. O termo “Lim. sup.” refere-se a $Q3 + 1.5 \cdot IIQ$, sendo $Q3$ o terceiro quartil e IIQ o intervalo interquartil.

Configuração	min(E)	min(IO)	Lim. sup. (IO)	Média (IO)	Outliers > 1	TMD (s)
SD-E1-G1		$7.44 \cdot 10^{-4}$	0.22656	7.67	23	4.39
SSC-E1-G1		$3.58 \cdot 10^{-3}$	0.39008	$8.47 \cdot 10^2$	135	465.26
TTC-E1-G1		$3.34 \cdot 10^{-3}$	0.61587	$1.11 \cdot 10^5$	190	699.09
EDT-E1-G1	$1 + 9.65 \cdot 10^{-5}$	$1.15 \cdot 10^{-3}$	0.23076	$3.24 \cdot 10^1$	23	30.73
RFC-E1-G1		$1.76 \cdot 10^{-3}$	0.54776	$8.86 \cdot 10^4$	144	146.88
OC-E1-G1		$8.22 \cdot 10^{-4}$	0.26432	$1.76 \cdot 10^3$	46	152.06
VDS-E1-G1		$1.56 \cdot 10^{-3}$	0.19645	$7.20 \cdot 10^3$	44	136.09
BWC-E1-G1		$4.49 \cdot 10^{-3}$	2.22788	$1.34 \cdot 10^5$	269	4006.91

Fonte: Elaborada pelo autor.

O tempo médio requerido por cada configuração, conforme indicado na [Tabela 12](#), corrobora as discussões anteriores sobre o custo computacional associado a cada configuração. A qualidade dos resultados, por outro lado, pode ser inferida pelo número de *outliers* que excedem o valor de 1. A análise dos dados tabulados revela que as configurações SD-E1-G1 e EDT-E1-G1, mesmo demandando menor custo computacional, proporcionam uma

decomposição de sinais de superior qualidade. Em contraste, as configurações SSC-E1-G1, TTC-E1-G1, RFC-E1-G1 e BWC-E1-G1 exibiram desempenhos menos otimizados, sendo a BWC-E1-G1 a que apresentou o maior contingente de *outliers*.

Estes resultados exibem a relevância de se selecionar adequadamente a configuração ao proceder com a decomposição de sinais via EMD. A decisão sobre a configuração pode impactar não apenas no custo computacional, mas também a qualidade da decomposição. As configurações SD-E1-G1 e EDT-E1-G1, por exemplo, destacaram-se por estabelecer um equilíbrio notável entre o tempo de processamento e a qualidade da decomposição, posicionando-as como alternativas promissoras para os propósitos deste estudo. Em contraste, outras configurações, ainda que demonstrando robustez na decomposição, revelaram um contingente elevado de *outliers*. Isto sugere que tais configurações podem não ser as mais propícias, sobretudo quando a eficácia e a precisão são primordiais.

E1-G1: Resultados do Módulo MNF

O módulo MNF tem como função principal a normalização vetores gerados pelo módulo MEF. É relevante ressaltar que a técnica de normalização empregada neste experimento foi a MN, conforme descrito na [Tabela 7](#). A [Tabela 13](#) apresenta as *features* que caracterizam dois sinais específicos, associados às classes “cigarra” e “ruído”. Para este exemplo, as energias das IMFs desses sinais foram previamente detalhadas na [Tabela 9](#).

Tabela 13 – Exemplos de vetores de *features*, correspondentes às energias representadas na [Tabela 9](#), para dois sinais associados às classes “cigarra” e “ruído”. A configuração empregada nas decomposições foi a SD-E1-G1.

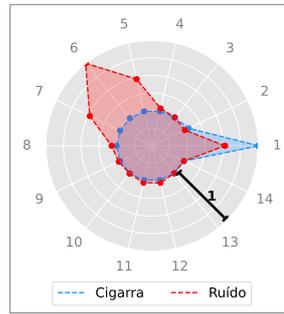
<i>Features</i>	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Cigarra	1.00000	0.07254	0.01363	0.00405	0.00180	0.00063	0.00036	0.00023	0.00011	1.759e-5	1.425e-5	4.025e-5	4.124e-5	0.00000
Ruído	0.52835	0.01363	0.01630	0.04431	0.47075	1.00000	0.47349	0.06955	0.02041	0.00604	0.03785	0.04090	0.00000	0.00000

Fonte: Elaborada pelo autor.

Conforme ilustrado na [Figura 30](#), os gráficos de radar derivados dos vetores da [Tabela 13](#) evidenciam distinções marcantes entre os vetores das classes “cigarra” e “ruído”. O vetor associado à classe “cigarra” exibe um perfil energético distintivo, com um pico evidenciado na primeira IMF seguido de um decrescimento acentuado nas IMFs subsequentes. Em contraste, o vetor relativo à classe “ruído” demonstra maior distribuição energética entre as IMFs, culminando em um pico na sexta IMF. Estas variações na distribuição energética entre as IMFs corroboram a ideia de que tais características são cruciais para a identificação e categorização destes sinais.

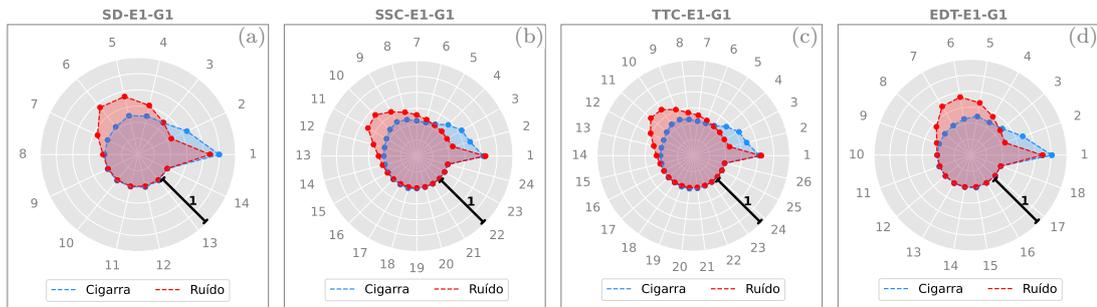
De modo geral, observa-se que, em média, os vetores de *features* de ambas as classes exibem um comportamento análogo ao descrito em relação à [Figura 30](#). Essa tendência se mantém mesmo em situações onde há um número ampliado de *features*, conforme ilustrado nas [Figuras 31a à 31d](#) e nas [Figuras 32a à 32d](#).

Figura 30 – Vetores de *features* da Tabela 13 representados em gráfico de radar.



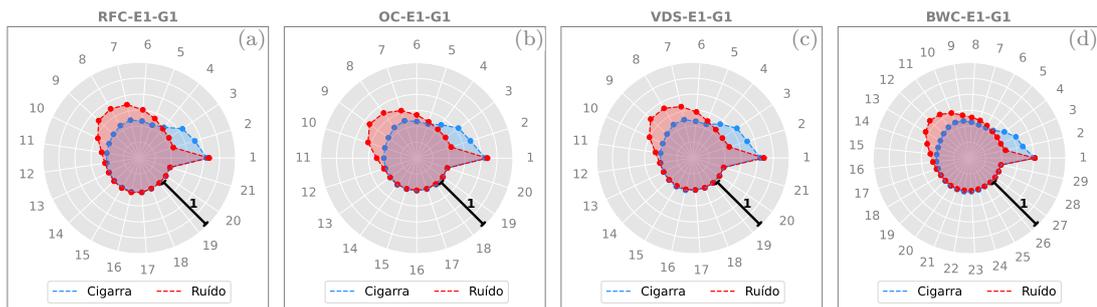
Fonte: Produzido pelo autor.

Figura 31 – Gráficos de radar das *features*, em média, para as classes “cigarra” e “ruído” das configurações SD-E1-G1, SSC-E1-G1, TTC-E1-G1 e EDT-E1-G1.



Fonte: Produzido pelo autor.

Figura 32 – Gráficos de radar das *features*, em média, para as classes “cigarra” e “ruído” das configurações RFC-E1-G1, OC-E1-G1, VDS-E1-G1 e BWC-E1-G1.



Fonte: Produzido pelo autor.

Tal observação sugere que, independentemente das particularidades de cada sinal, a tendência geral em relação à distribuição de energia entre as IMFs é mantida, em média, para as classes “cigarra” e “ruído”. Esta uniformidade, identificada em todas as configurações exploradas neste estudo, realça a relevância e eficiência dessas características para a classificação dos sinais.

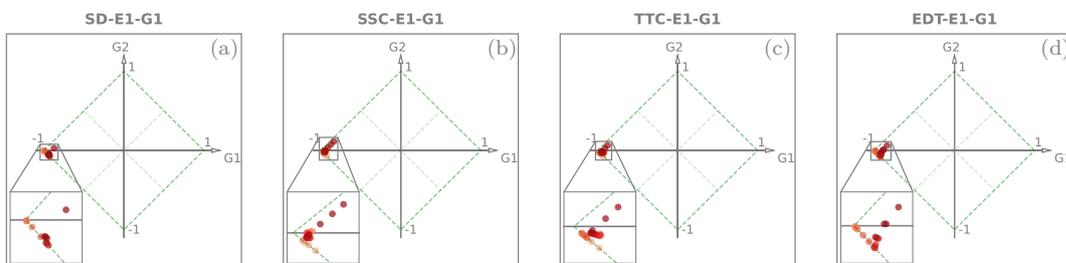
E1-G1: Resultados do Módulo MPFE

Como elucidado anteriormente, através do módulo MPFE, é possível analisar qualidade e a influência das *features* sobre o problema de classificação. Neste ensaio, foram testadas variações no número de *features* em cada configuração estabelecida. Mais especificamente, foram consideradas as k primeiras *features*, com k variando entre 2 e M . O critério para análise é a menor distância entre o ponto P , previamente determinado, e VO. Esta abordagem tem o objetivo de determinar se a utilização de vetores com um número reduzido de *features* pode simplificar o sistema e viabilizar a adoção de modelos menos complexos. Por exemplo, se for viável empregar vetores com apenas duas *features*, o módulo MEF teria que extrair somente as duas IMFs iniciais, um número consideravelmente inferior aos máximos M registrados neste estudo (conforme Tabela 10), resultando em uma redução do custo computacional do sistema.

Os PPs, conforme discutido na seção 2.3, juntamente com gráficos das medidas de distâncias em relação ao VO, foram utilizados para representar os resultados do módulo. A intenção é comparar essas distâncias a fim de identificar as menores. Seguem nas Figuras 33 e 34 os PPs resultantes.

Figura 33 – PPs para as configurações SD-E1-G1, SSC-E1-G1, TTC-E1-G1 e EDT-E1-G1.

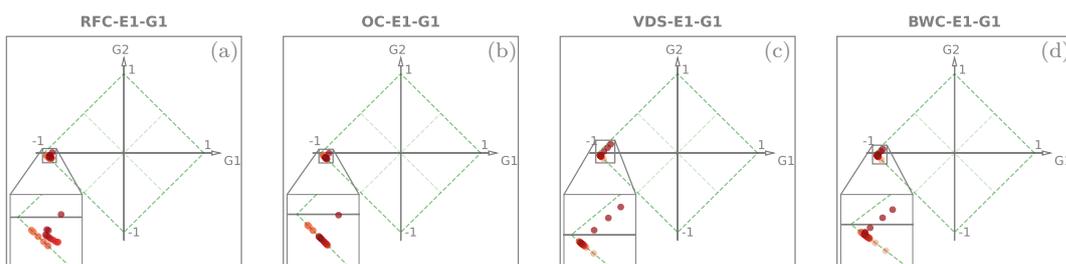
O ponto mais claro, em cada gráfico, indica os vetores com 2 *features*, enquanto o mais escuro representa vetores com o máximo M .



Fonte: Produzido pelo autor.

Figura 34 – PPs para as configurações RFC-E1-G1, OC-E1-G1, VDS-E1-G1 e BWC-E1-G1.

O ponto mais claro, em cada gráfico, indica os vetores com 2 *features*, enquanto o mais escuro representa vetores com o máximo M .

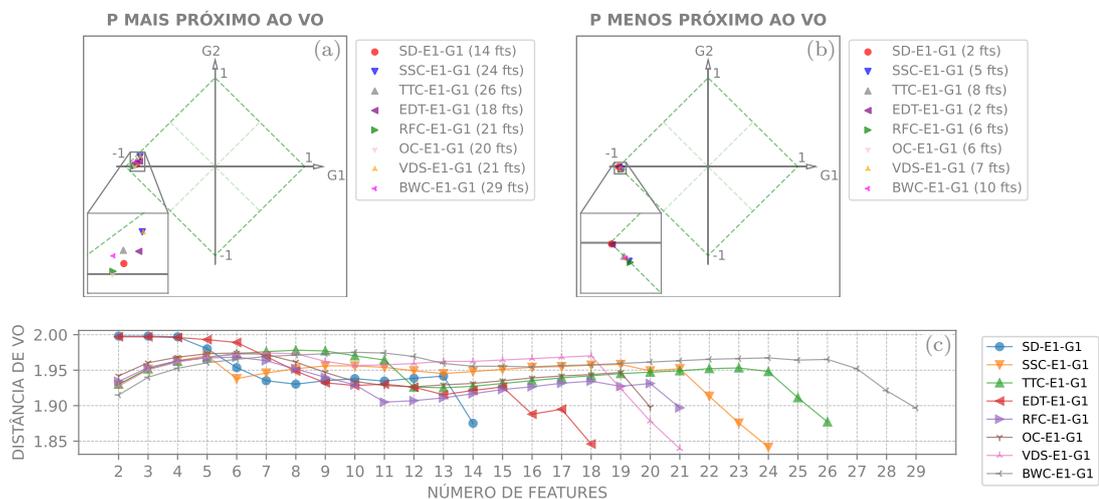


Fonte: Produzido pelo autor.

Nota-se que a variação do critério de parada não influencia significativamente os resultados das análises PFE. Em geral, os pontos obtidos situaram-se mais próximos do vértice $(-1, 0)$, correspondente à falsidade. Isso sugere que, em todos os casos, os vetores de uma mesma classe (intraclasse) são dispersos, enquanto os vetores de classes distintas (interclasse) apresentam uma considerável sobreposição.

As Figuras 35a e 35b destacam, respectivamente, os melhores e os piores resultados para as configurações avaliadas. A Figura 35c, por sua vez, apresenta as distâncias de todos os pontos retratados nas Figuras 33 e 34 ao VO.

Figura 35 – Resumo dos resultados do módulo MPFE. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Constata-se que as configurações SD-E1-G1 e EDT-E1-G1, ao considerar apenas 2, 3 e 4 *features*, obtiveram os piores resultados, com pontos situados aproximadamente à máxima distância do VO. Por outro lado, as configurações EDT-E1-G1, VDS-E1-G1 e SSC-E1-G1, ao considerarem 18, 21 e 24 *features*, respectivamente, alcançaram os melhores desempenhos, com valores próximos a 1.85, conforme ilustrado na Figura 35c. Dentre estas, a configuração EDT-E1-G1 se sobressai por ter conseguido um desempenho similar ao das demais utilizando menos *features* (somente 18). Além disso, esta teve um custo computacional consideravelmente baixo em relação às demais, conforme detalhado na Tabela 12. Também é digno de nota o desempenho da configuração SD-E1-G1, que, ao utilizar 14 *features*, proporcionou maior velocidade de processamento e uma distância aproximada de 1.875.

Evidentemente, para solucionar um problema com tal grau de complexidade, é imprescindível um classificador forte. Esse cenário justifica novamente a escolha pelo classificador SVM. Na próxima subseção são apresentados os testes relacionados ao módulo

MTT.

E1-G1: Resultados do módulo MTT

Finalmente, conforme detalhado anteriormente, o módulo MTT utiliza o classificador SVM, que é treinado e testado para todos os conjuntos de vetores obtidos ao variar a quantidade de *features* em sequência crescente. Os parâmetros designados para o treinamento do classificador estão elencados na [Tabela 6](#). O limiar de treinamento, por sua vez, foi definido por múltiplos de 10 no intervalo de 20 a 80. Se X representa o número total de amostras, a quantidade de amostras destinadas ao treinamento é calculada como $X \cdot P/100$, onde P pertence ao conjunto $\{20, 30, \dots, 80\}$.

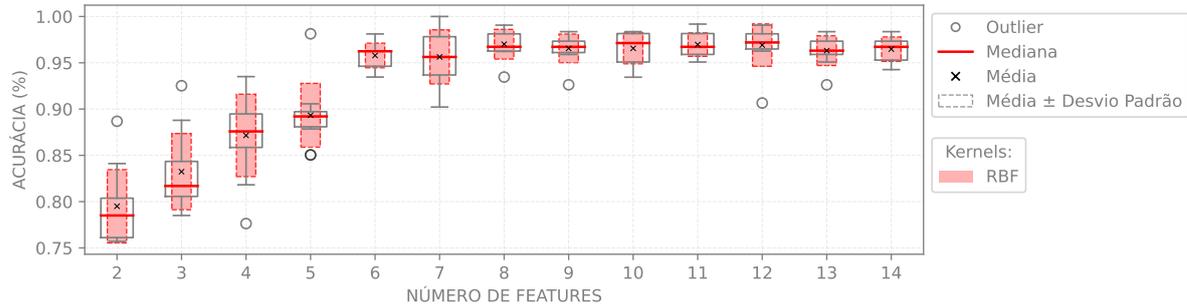
Assim, levando em consideração a validação cruzada empregada com $k = 10$ partições, o fato de que o *kernel* linear não utiliza o parâmetro γ e os máximos de *features* M obtidos em cada configuração ([Tabela 10](#)), realizam-se $7\,700 \cdot (M - 1)$ treinamentos distintos para cada configuração especificada na [Tabela 7](#), perfazendo um total de 1 270 500 treinamentos. Ao final deste processo, os modelos que exibiram maiores médias de acurácias no processo de validação cruzada foram eleitos para os testes definitivos, utilizando o conjunto de dados especificamente reservado para essa finalidade.

A seguir, para validar o sistema denominado “detector de cigarras”, as [Figuras 36 a 43](#) exibem os diagramas de caixa que representam as acurácias obtidas durante a etapa de treinamento com validação cruzada. Nos gráficos, são também representados os intervalos correspondentes à média \pm desvio padrão, bem como os *kernels* correspondentes aos modelos treinados.

Quando se utiliza validação cruzada, conforme discutido na [seção 3.1](#), o modelo é treinado e testado em diferentes subconjuntos dos dados. Esse procedimento contribui para uma avaliação robusta e generalizada do desempenho do modelo. O desvio padrão oriundo dos resultados dessa validação pode indicar a variação de desempenho do modelo entre esses subconjuntos distintos. Evidentemente, ainda que a validação cruzada forneça estimativas sólidas, o desempenho de um modelo em conjuntos de testes, que são independentes dos conjuntos de treinamento, pode ser influenciado por vários fatores. Esses fatores estão relacionados tanto à natureza dos dados quanto às características intrínsecas do modelo. No entanto, a faixa determinada pela média \pm desvio padrão oferece uma boa estimativa da variação esperada nos resultados de testes.

Conforme ilustrado na [Figura 36](#), é notável que o uso do *kernel* RBF se sobressaiu em todos os cenários analisados para SD-E1-G1. Considerando a partir de 6 *features*, constata-se que a acurácia supera o 90%. Este índice escala para acima de 95% quando são incorporadas 11 *features*. Entretanto, é relevante salientar que o ponto ótimo de desempenho, em média, foi alcançado ao considerar 8 *features*. Por outro lado, ao restringir-se a análise

Figura 36 – Resultados dos treinamentos com validação cruzada para a configuração SD-E1-G1. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

a somente 2 *features*, os resultados apresentaram uma performance relativamente baixa, oscilando entre 75% e 90%, com uma média aproximada de 80%.

Na análise apresentada na Figura 37 para a configuração SSC-E1-G1, verifica-se novamente uma predominância do *kernel* RBF nos resultados, exceto quando avaliado com 12 *features*, onde o *kernel* polinomial demonstrou ser mais eficaz. É notável que, ao incorporar mais de 9 *features* na análise, a acurácia, em geral, ultrapassou a marca de 90%, evidenciando uma performance notoriamente superior. O ápice de desempenho foi atingido ao utilizar 18 *features*, alcançando uma acurácia média estimada em 96%. No entanto, ao avaliar a configuração com apenas 2 *features*, notou-se uma dispersão mais significativa nos resultados: foi registrado um *outlier* indicando 75% de acurácia, enquanto os demais valores flutuaram entre 79% e 83.5%, culminando em uma média próxima a 80%. Esta análise reitera a importância de uma seleção criteriosa de *features* para maximizar a eficácia do modelo.

Figura 37 – Resultados dos treinamentos com validação cruzada para a configuração SSC-E1-G1. O número de *features* é dado pela ordem de extração das IMFs.

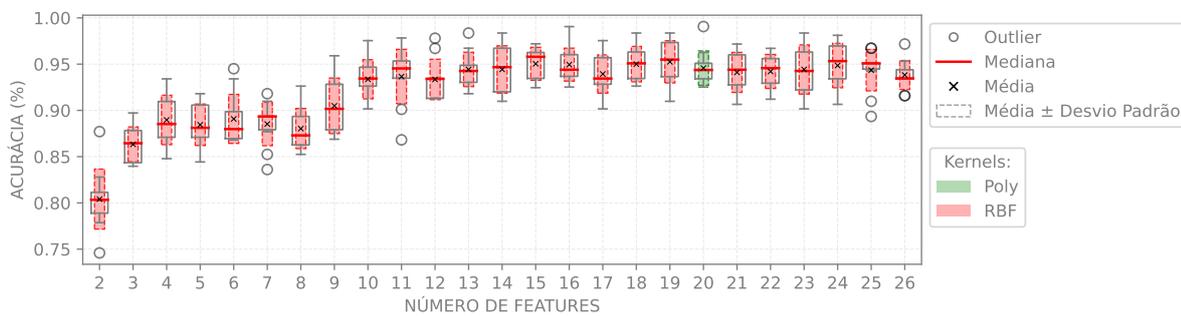


Fonte: Produzido pelo autor.

Na Figura 38 referente à configuração TTC-E1-G1, observa-se mais uma vez a predominância do *kernel* RBF, excetuando-se no caso em que foram consideradas 20 *features*, caso em que o *kernel* polinomial se destacou. Quando avaliados conjuntos com

features superiores a 9, o patamar de 90% de acurácia foi consistentemente superado, de modo geral, evidenciando uma tendência corroborada nas configurações anteriores. Destaca-se, nesta configuração, que ao empregar 19 *features* obteve-se a melhor média, próxima a 95.25%. No cenário mais restrito, utilizando apenas 2 *features*, dois *outliers* foram identificados, com acurácias aproximadas de 75% e 88%, respectivamente. Neste caso, a amplitude dos demais resultados variou entre 77% e 84%, resultando novamente em uma média em torno de 80%. A análise da configuração TTC-E1-G1 ratifica a influência significativa do número de *features* no desempenho do modelo.

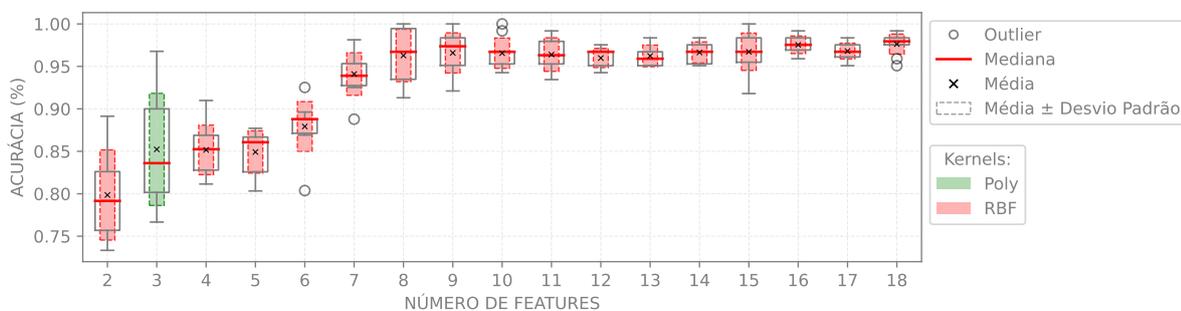
Figura 38 – Resultados dos treinamentos com validação cruzada para a configuração TTC-E1-G1. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Do mesmo modo que nas configurações anteriores, percebe-se uma tendência marcante do *kernel* RBF para a configuração EDT-E1-G1, com exceção da análise com 3 *features*, onde o *kernel* polinomial se revelou mais propício, conforme Figura 39. Quando são empregadas 7 ou mais *features*, o desempenho do modelo obteve acurácias superiores a 90%. Nesta configuração, a acurácia média mais elevada foi obtida no caso em que foram consideradas 18 *features*, estimada em 97.75%. Em contrapartida, ao limitar a análise a apenas 2 *features*, os resultados ficaram entre 74% e 89.7%, com média próxima dos 80%.

Figura 39 – Resultados dos treinamentos com validação cruzada para a configuração EDT-E1-G1. O número de *features* é dado pela ordem de extração das IMFs.

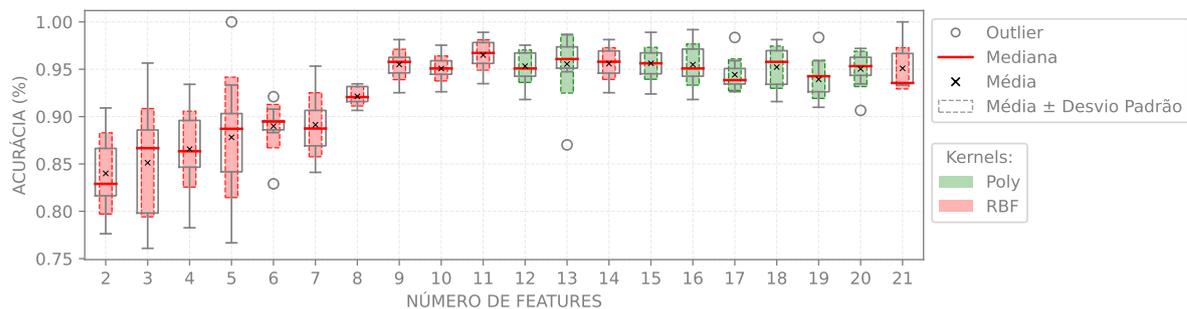


Fonte: Produzido pelo autor.

Para a configuração RFC-E1-G1, em contraste com as configurações anteriormente analisadas, embora o *kernel* RBF tenha apresentado os melhores resultados em 12 de 20

casos (60%), o *kernel* polinomial foi predominante em 8 dos 20 casos (40%), conforme ilustrado na [Figura 40](#). Ao considerar a partir de 8 *features*, verifica-se que as acurácias excedem os 90%. Esse índice eleva-se para mais de 93.5% quando são avaliados vetores com 11 *features*, alcançando o melhor desempenho médio de 96.25%. Por outro lado, ao limitar a análise a apenas 2 *features*, observa-se uma performance significativamente inferior, com resultados variando entre 77.5% e 91%, e uma média de aproximadamente 83.7%.

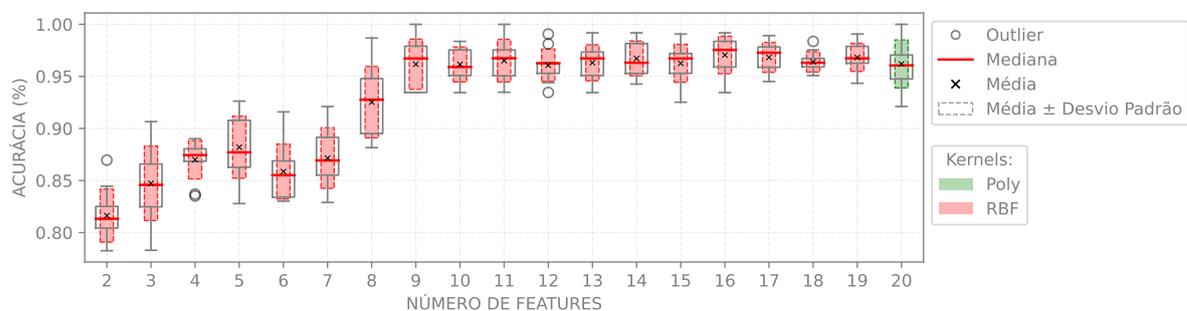
Figura 40 – Resultados dos treinamentos com validação cruzada para a configuração RFC-E1-G1. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Nas distribuições representadas na [Figura 41](#) referente à configuração OC-E1-G1, observa-se que o *kernel* RBF predominou nos resultados. No entanto, ao avaliar o conjunto de vetores com 20 *features*, o *kernel* polinomial demonstrou superioridade. Nota-se que, para vetores de 9 ou mais *features*, a acurácia ultrapassou o limiar de 92%. O desempenho máximo foi alcançado ao avaliar-se um conjunto com vetores de 16 *features*, registrando uma acurácia média estimada em 97%. Contudo, ao considerar a configuração com apenas 2 *features*, detectou-se um *outlier* correspondente a 87% de acurácia, enquanto os outros resultados oscilaram entre 78% e 84,5%, sendo a média aproximadamente 81,5%.

Figura 41 – Resultados dos treinamentos com validação cruzada para a configuração OC-E1-G1. O número de *features* é dado pela ordem de extração das IMFs.

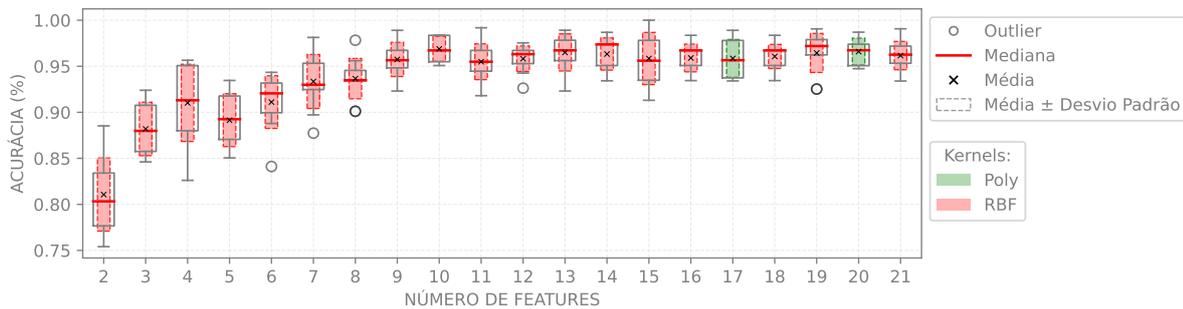


Fonte: Produzido pelo autor.

Como observado em todas as configurações previamente analisadas, a [Figura 42](#) relativa à configuração VDS-E1-G1 reitera a predominância do *kernel* RBF. No entanto,

essa tendência é interrompida quando são consideradas 17 e 20 *features*, situações nas quais o *kernel* polinomial sobressaiu-se. Para os casos que englobam mais que 7 *features*, a linha dos 90% foi consistentemente ultrapassada, comportamento semelhante ao observado em configurações anteriores. Neste contexto, é relevante destacar que a melhor média, aproximando-se de 97%, foi alcançada ao se considerar vetores de 10 *features*. Em um cenário mais restritivo, com apenas 2 *features*, as acurácias flutuaram entre 75,2% e 88,5%, culminando em uma média estimada em cerca de 81%.

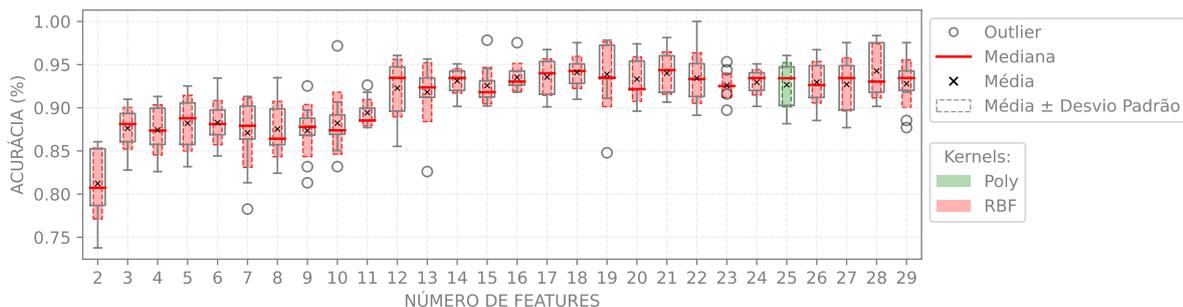
Figura 42 – Resultados dos treinamentos com validação cruzada para a configuração VDS-E1-G1. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Por fim, os resultados referentes à configuração BWC-E1-G1 estão detalhados na [Figura 43](#). Nota-se que, em termos gerais, a performance desta configuração foi inferior quando comparada às demais, as quais frequentemente exibiram médias acima de 95% em diversos casos avaliados. Esta marca não foi atingida em nenhum cenário para a configuração BWC-E1-G1, sendo o melhor desempenho registrado para o conjunto com vetores de 28 *features*, com uma acurácia média estimada em 94.1%. Em contraponto, ao restringir a análise para apenas 2 *features*, a faixa de resultados oscilou entre 74% e 86%, com uma média aproximada de 81%. Conforme observado nas configurações anteriores, há uma tendência marcada em favor do *kernel* RBF. Contudo, ao analisar conjuntos com 25 *features*, o *kernel* polinomial demonstrou ser mais eficiente.

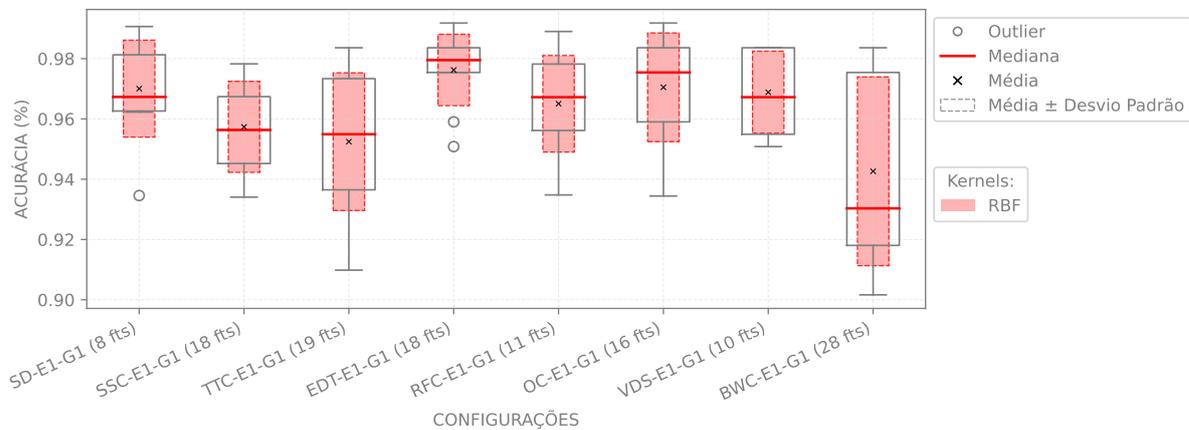
Figura 43 – Resultados dos treinamentos com validação cruzada para a configuração BWC-E1-G1. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Após a análise de cada configuração em função da variação do número de *features*, os modelos que apresentaram maiores médias foram agrupados e seguem ilustrados na Figura 44. Observa-se que, de modo geral, a configuração EDT-E1-G1, considerando 18 *features*, destaca-se pelo seu desempenho superior em termos de acurácia. Esta configuração exibiu o menor intervalo de distribuição e desvio padrão, além de apresentar 50% dos resultados com acurácia superior a 98% (mediana igual a 98%). Sua média também superou as das demais configurações. Em contraposição, a configuração BWC-E1-G1 manifestou o maior intervalo de distribuição e desvio padrão, com 50% dos seus resultados abaixo de 93% (mediana igual a 93%). Contudo, sua média aproximou-se de 94.1%.

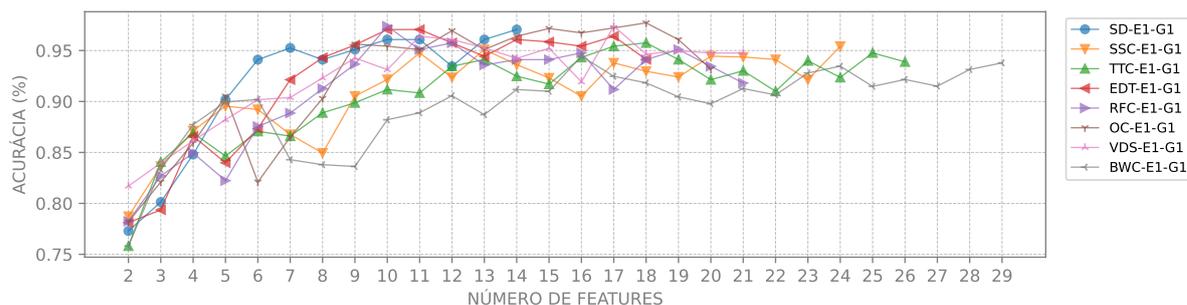
Figura 44 – Resultados dos treinamentos utilizando validação cruzada para os modelos com maiores médias em todas as configurações de E1-G1. O número de *features* corresponde à ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Determinados os melhores modelos em todos os cenários avaliados, estes foram submetidos aos conjuntos reservados exclusivamente para os testes, garantindo sua independência em relação aos conjuntos utilizados no treinamento. A Figura 45 ilustra os resultados para todos os modelos avaliados.

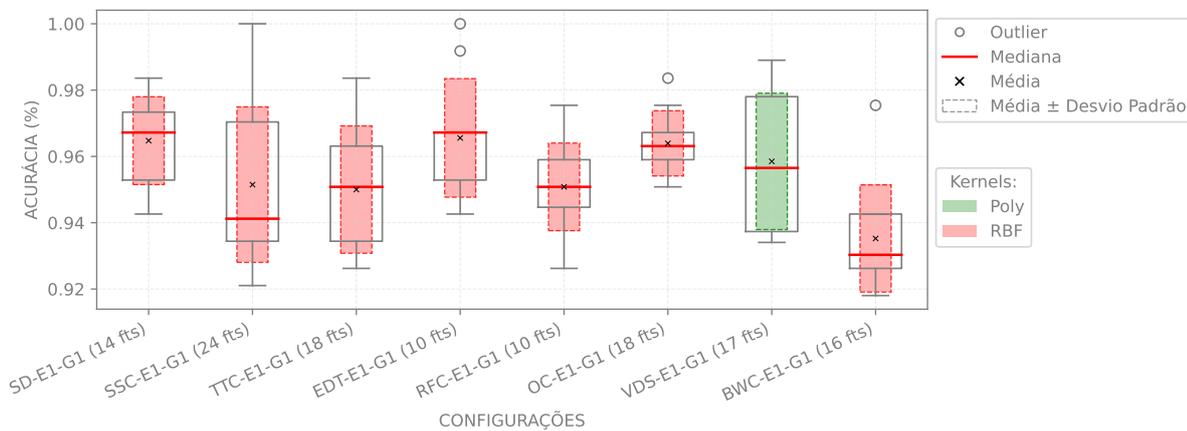
Figura 45 – Resultados dos testes dos melhores modelos em todos os cenários avaliados. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Observa-se que, à exceção da configuração BWC-E1-G1, todos os conjuntos de vetores com 9 ou mais *features* atingiram acurácias iguais ou superiores a 90%. Quando analisado o critério do menor número de *features*, o destaque foi para VDS-E1-G1 (2 fts) com 82%. Em relação aos melhores desempenhos gerais, as seguintes se sobressaíram: SD-E1-G1 (14 fts) com 97.05%, SSC-E1-G1 (24 fts) com 95.41%, TTC-E1-G1 (18 fts) com 95.75%, EDT-E1-G1 (10 fts) com 97.05%, RFC-E1-G1 (10 fts) com 97.38%, OC-E1-G1 (18 fts) com 97.71%, VDS-E1-G1 (17 fts) com 97.38% e BWC-E1-G1 (16 fts) com 94.44%. Os resultados dos treinamentos, com validação cruzada, correspondentes aos respectivos testes seguem ilustrados na [Figura 46](#).

Figura 46 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas. O número de *features* corresponde à sequência de extração das IMFs.



Fonte: Produzido pelo autor.

Outro fato notável é que, com exceção do modelo correspondente à configuração RFC-E1-G1, todos os resultados dos testes se enquadram dentro da faixa média \pm desvio padrão. No caso de RFC-E1-G1, o resultado ficou acima da faixa. Esse comportamento indica que os intervalos definidos conseguem representar adequadamente as variações de desempenho dos modelos, evidenciando que, de maneira geral, os modelos possuem uma performance relativamente consistente.

Para complementar a análise e melhor visualizar a capacidade de classificação dos modelos, as MCs representam um recurso gráfico amplamente empregado na literatura para examinar os resultados alcançados por classificadores (LUQUE et al., 2022; GE et al., 2022; ÜRETEN; MARAŞ, 2022). Estas fornecem uma perspectiva detalhada do desempenho de cada modelo ao comparar os valores previstos com os valores reais, servindo também como fundamento para várias métricas comuns para avaliação de desempenho, tais como: precisão, *recall*, *F1-score*, entre outras. Tal abordagem é pertinente no contexto desta pesquisa, visto que a acurácia por si só não fornece uma imagem completa do desempenho

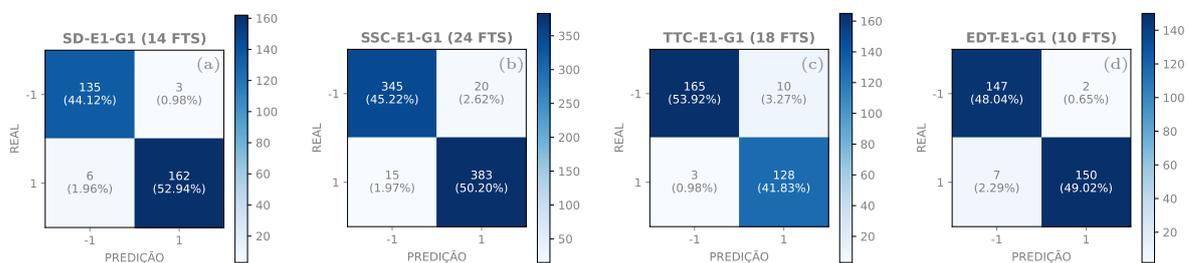
dos modelos.

Uma MC é composta por uma tabela na qual as linhas indicam as classes verdadeiras e as colunas denotam as preditas, ou vice-versa. Dessa forma, considerando um classificador binário, quatro possíveis resultados podem surgir ao examinar uma instância específica (FAWCETT, 2006):

- Se a instância é negativa e é classificada como negativa, ela é contada como um Verdadeiro Negativo (VN);
- Se a instância é negativa e é classificada como positiva, ela é contada como um Falso Positivo (FP);
- Se a instância é positiva e é classificada como positiva, ela é contada como um Verdadeiro Positivo (VP);
- Se a instância é positiva e é classificada como negativa, ela é contada como um Falso Negativo (FN).

Nas Figuras 47 e 48, são apresentadas as MCs referentes aos resultados dos modelos que exibiram melhores desempenhos nos testes. Nesses gráficos, a tonalidade mais escura indica o máximo alcançado entre as quatro categorias possíveis na matriz, enquanto a cor branca representa a ausência de ocorrências. Portanto, idealmente, espera-se que a diagonal principal da MC seja predominantemente escura (indicando acertos) e que a diagonal secundária seja predominantemente branca (indicando ausência de erros de classificação). Esta análise sugere um desempenho satisfatório para os casos aqui abordados.

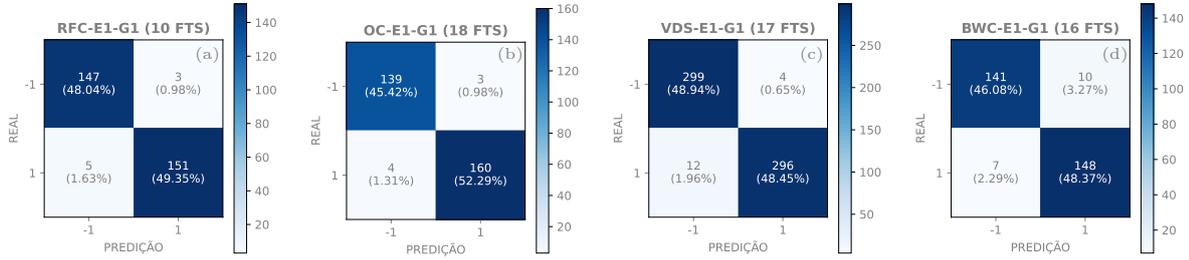
Figura 47 – MCs para as configurações SD-E1-G1, SSC-E1-G1, TTC-E1-G1 e EDT-E1-G1. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.



Fonte: Produzido pelo autor.

No contexto desta pesquisa, tanto os VPs (detecção correta de cigarras) quanto os VNs (detecção correta da ausência de cigarras) são obviamente de suma importância, pois determinam a acurácia, definida pela Equação (4.1). Contudo, a análise dos FPs (identificação errônea da presença de cigarras) e dos FNs (falha na detecção das cigarras quando presentes) é crucial. Note que o custo associado a FPs é elevado, dado que

Figura 48 – MCs para as configurações RFC-E1-G1, OC-E1-G1, VDS-E1-G1 e BWC-E1-G1. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.



Fonte: Produzido pelo autor.

a aplicação de agrotóxicos na lavoura é onerosa e pode trazer impactos prejudiciais ao meio ambiente, como discutido no [Capítulo 2](#). Desta forma, é importante ter uma alta precisão, definida pela [Equação \(4.2\)](#). Por outro lado, o custo de FNs também é consideravelmente alto, uma vez que a presença não detectada de cigarras pode acarretar em perdas significativas na produção. Portanto, é imprescindível garantir também um alto *recall*, definido pela [Equação \(4.3\)](#).

$$Ac = \frac{VP + VN}{VP + VN + FP + FN} \quad (4.1)$$

$$Prec = \frac{VP}{VP + FP} \quad (4.2)$$

$$Rec = \frac{VP}{VP + FN} \quad (4.3)$$

O *F1-score* é a média harmônica entre precisão e *recall*, resultando na [Equação \(4.4\)](#). Como a média harmônica atribui maior peso a valores baixos ([NARAYANAN, 2015](#)), isso implica que, para que o *F1-score* seja alto, tanto a precisão quanto o *recall* devem ser altos. Nesse sentido, o *F1-score* se apresenta como uma métrica valiosa para a avaliação final dos modelos, pois quantifica o equilíbrio entre *recall* e precisão, auxiliando na ponderação entre a detecção eficaz de cigarras e a minimização de FPs. Os hiperparâmetros determinados para os modelos de melhor desempenho nos testes, bem como a acurácia, precisão, *recall* e *F1-score*, são detalhados na [Tabela 14](#).

$$F_1 = 2 \cdot \frac{Prec \cdot Rec}{Prec + Rec} \quad (4.4)$$

Finalmente, o índice *Area Under the Curve* (AUC), definido pela área sob a curva ROC (determinada pela razão entre os VPs e os FPs), atesta a qualidade dos resultados obtidos. Uma classificação ideal é representada pelo ponto (0, 1), portanto, um valor de

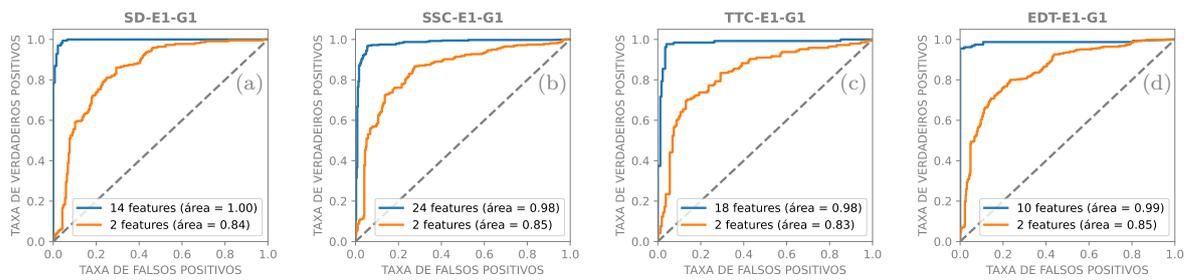
Tabela 14 – Melhores resultados em E1-G1.

Configuração	Num. features	Amostras treino (%)	C	γ	Kernel	Acurácia	Precisão	Recall	F1-score
SD-E1-G1	14	80	1000	10	RBF	0.97058	0.98181	0.96428	0.97297
SSC-E1-G1	24	50	1000	1	RBF	0.95412	0.95037	0.96231	0.95630
TTC-E1-G1	18	80	1000	10	RBF	0.95751	0.92753	0.97709	0.95167
EDT-E1-G1	10	80	100	10	RBF	0.97058	0.98684	0.95541	0.97087
RFC-E1-G1	10	80	100	10	RBF	0.97385	0.98051	0.96794	0.97419
OC-E1-G1	18	80	100	10	RBF	0.97712	0.98159	0.97560	0.97859
VDS-E1-G1	17	60	100	1000	RBF	0.97381	0.98666	0.96103	0.97368
BWC-E1-G1	16	80	1000	1	RBF	0.94444	0.93670	0.95483	0.94568

Fonte: Elaborada pelo autor.

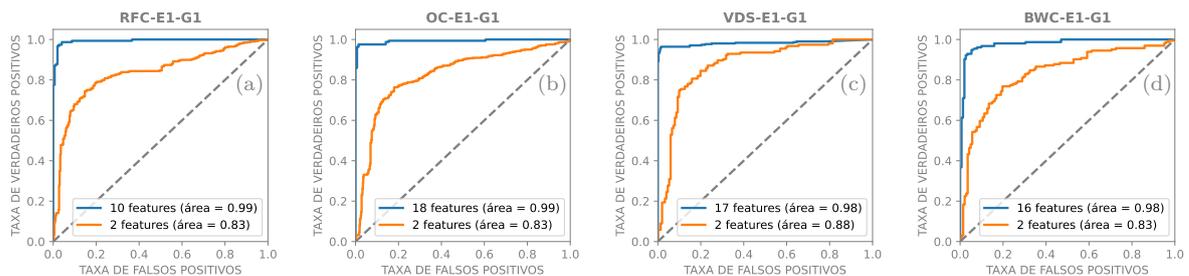
AUC próximo de 1 sugere um desempenho excelente de classificação (FAWCETT, 2006). As curvas ROC, apresentadas nas Figuras 49 e 50 ilustram os desempenhos dos melhores modelos (azul) e dos piores (laranja).

Figura 49 – Curvas ROC para as configurações SD-E1-G1, SSC-E1-G1, TTC-E1-G1 e EDT-E1-G1.



Fonte: Produzido pelo autor.

Figura 50 – Curvas ROC para as configurações RFC-E1-G1, OC-E1-G1, VDS-E1-G1 e BWC-E1-G1.



Fonte: Produzido pelo autor.

Os modelos de melhor desempenho apresentam um AUC mínimo de 0.98, alcançando 1 em certos casos. Em contraste, os resultados menos promissores, todos associados ao número mínimo de *features* para os conjuntos de vetores considerados, possuem AUC variando entre 0.83 e 0.88. Isso indica que, para tais casos, existe a necessidade de explorar-se métodos mais eficazes para a extração de *features*, visando aprimorar a solução do problema em estudo.

Com base nas análises e considerando os resultados detalhados nas Tabelas 12 e 14, identificam-se duas configurações notavelmente promissoras para o sistema proposto:

SD-E1-G1 e EDT-E1-G1. Ambas se destacam por combinar um custo computacional mais eficiente, em comparação com as demais configurações, e demonstrar uma performance elevada na classificação. Portanto, confirmou-se a hipótese da viabilidade do sistema proposto, que demonstrou robustez e precisão nos testes conduzidos.

Um experimento semelhante ao apresentado nesta subseção foi publicado no formato de artigo científico, sob o título “*Empirical Mode Decomposition Applied to Acoustic Detection of a Cicadid Pest*” (SOUZA et al., 2022). No entanto, é importante destacar que os sinais utilizados nesse estudo diferem dos selecionados para esta tese, assim como a metodologia empregada para a determinação dos melhores modelos. Ainda assim, ambos os trabalhos convergem em termos de resultados.

Nas subseções subsequentes, esforços visando o aprimoramento sob o ponto de vista do custo computacional serão empenhados, assim como serão conduzidas investigações adicionais para melhorar o desempenho dos classificadores.

4.2.1.2 Experimento E2

Após os resultados promissores observados na subseção anterior, a hipótese, nesta subseção, é que frações menores dos sinais podem oferecer desempenhos equiparáveis aos obtidos para sinais de 10 segundos. Dessa forma, o experimento E2 foi conduzido utilizando frações reduzidas dos sinais, derivadas de sua forma original, que foram catalogados com uma taxa de amostragem de 44.1 kHz e 16 bits de quantização. As frações consideradas para cada sinal foram: 5, 2 e 1 segundos. Para o processamento pela EMD, os 8 critérios de parada foram novamente adotados. O número máximo de iterações por IMF foi delimitado em 700. Os vetores de *features* foram normalizados com a técnica MN. Todos os parâmetros específicos associados a cada critério de parada permaneceram inalterados em relação aos estabelecidos na subseção anterior. As configurações utilizadas neste ensaio estão detalhadas na [Tabela 15](#).

E2-G1: Resultados do Módulo MEF

Conforme esperado, constata-se que os sinais com frações temporais reduzidas conduzem a um menor número de iterações no processo de decomposição pela EMD, como pode ser observado na [Tabela 16](#), que apresenta a média de iterações para as decomposições dos sinais de 1 segundo. Tal observação pode ser atribuída ao processo iterativo SP, intrínseco à EMD, que visa identificar e separar as escalas distintas de tempo (ou frequências) presentes ao sinal original. Ao reduzir a duração do sinal, naturalmente menos dessas escalas se manifestam, resultando, portanto, na extração de um número menor de IMFs, conforme [Tabela 17](#). Esse comportamento reforça a capacidade adaptativa da EMD na análise de sinais não lineares e não estacionários (WU; HUANG, 2005;

Tabela 15 – Configurações para o experimento E2 do grupo G1.

Rótulos	Amostragem (kHz)	Tempo (s)	Configurações da EMD		Norma	It. Max.
			Critério de parada	Parâmetros		
SD-E2-G1-1	44.1	5	SD	$\varepsilon = 0.1$	MN	700
SSC-E2-G1-1			SSC	$S = 3$		
TTC-E2-G1-1			TTC	$\alpha = 0.05, \theta_1 = 0.05, \theta_2 = 0.5$		
EDT-E2-G1-1			EDT	$\varepsilon = 0.001$		
RFC-E2-G1-1			RFC	$R = 50$		
OC-E2-G1-1			OC	$\varepsilon = 0.05$		
VDS-E2-G1-1			VDS	95% de $m(t) < 0.005$		
BWC-E2-G1-1			BWC	mínimo de B_f^2 encontrado		
SD-E2-G1-2	44.1	2	SD	$\varepsilon = 0.1$	MN	700
SSC-E2-G1-2			SSC	$S = 3$		
TTC-E2-G1-2			TTC	$\alpha = 0.05, \theta_1 = 0.05, \theta_2 = 0.5$		
EDT-E2-G1-2			EDT	$\varepsilon = 0.001$		
RFC-E2-G1-2			RFC	$R = 50$		
OC-E2-G1-2			OC	$\varepsilon = 0.05$		
VDS-E2-G1-2			VDS	95% de $m(t) < 0.005$		
BWC-E2-G1-2			BWC	mínimo de B_f^2 encontrado		
SD-E2-G1-3	44.1	1	SD	$\varepsilon = 0.1$	MN	700
SSC-E2-G1-3			SSC	$S = 3$		
TTC-E2-G1-3			TTC	$\alpha = 0.05, \theta_1 = 0.05, \theta_2 = 0.5$		
EDT-E2-G1-3			EDT	$\varepsilon = 0.001$		
RFC-E2-G1-3			RFC	$R = 50$		
OC-E2-G1-3			OC	$\varepsilon = 0.05$		
VDS-E2-G1-3			VDS	95% de $m(t) < 0.005$		
BWC-E2-G1-3			BWC	mínimo de B_f^2 encontrado		

Fonte: Elaborada pelo autor.

BOUDRAA; CEXUS, 2007), promovendo uma decomposição adequada, de acordo com as características intrínsecas do sinal em análise.

Tabela 16 – Número máximo de IMFs e média de iterações do SP, por classe, em cada configuração da terceira rodada de testes de E2-G1. C indica a classe “cigarra” e R a classe “ruído”.

Componentes	SD-E2-G1-3		SSC-E2-G1-3		TTC-E2-G1-3		EDT-E2-G1-3		RFC-E2-G1-3		OC-E2-G1-3		VDS-E2-G1-3		BWC-E2-G1-3	
	C	R	C	R	C	R	C	R	C	R	C	R	C	R	C	R
IMF 1	5	3	301	396	223	333	7	8	97	32	100	134	202	178	582	644
IMF 2	3	3	192	249	173	250	7	11	84	24	75	64	143	32	605	641
IMF 3	3	4	111	143	115	128	10	11	54	23	49	37	61	23	573	581
IMF 4	3	4	52	119	85	125	12	9	38	28	41	33	18	21	518	549
IMF 5	3	4	28	90	47	107	12	9	43	33	32	28	11	21	451	486
IMF 6	3	3	19	41	41	70	12	9	55	48	27	28	10	19	408	440
IMF 7	3	2	16	30	37	80	15	14	65	65	27	27	8	18	362	407
IMF 8	3	2	10	24	38	64	18	18	72	86	26	26	5	13	326	381
IMF 9	3	2	8	14	42	56	18	20	75	92	22	23	3	9	293	357
IMF 10	3	2	7	11	47	48	27	36	83	110	20	21	3	5	264	309
IMF 11	2	2	6	8	61	47	39	32	84	106	18	18	2	4	228	249
IMF 12	-	-	7	7	67	56	39	51	95	103	15	13	2	2	226	223
IMF 13	-	-	5	6	64	44	194	47	108	89	11	11	2	2	226	237
IMF 14	-	-	4	7	69	57	-	-	77	95	9	9	-	-	218	222
IMF 15	-	-	-	5	41	64	-	-	39	30	-	3	-	-	270	273
IMF 16	-	-	-	5	7	88	-	-	-	52	-	-	-	-	243	253
IMF 17	-	-	-	-	-	32	-	-	-	-	-	-	-	-	333	311
IMF 18	-	-	-	-	-	3	-	-	-	-	-	-	-	-	307	275
IMF 19	-	-	-	-	-	-	-	-	-	-	-	-	-	-	33	382
IMF 20	-	-	-	-	-	-	-	-	-	-	-	-	-	-	22	109
IMF 21	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	13

Fonte: Elaborada pelo autor.

Os gráficos relativos às decomposições dos sinais para as configurações do ensaio E2-G1 foram omitidos visando evitar redundâncias e assegurar clareza e objetividade na exposição dos resultados, uma vez que esta abordagem proporciona ilustrações visuais acessíveis do SP de uma perspectiva puramente quantitativa. Como mencionado no experimento anterior, a avaliação da qualidade das decomposições pode ser verificada pelos

Tabela 17 – Quantidade máxima (M) de IMFs por configuração em E2-G1, incluindo o resíduo.

Configuração	E2-G1-1	E2-G1-2	E2-G1-3
SD	13	13	12
SSC	23	20	17
TTC	25	21	19
EDT	17	15	14
RFC	20	19	17
OC	19	17	16
VDS	21	21	14
BWC	27	26	22

Fonte: Elaborada pelo autor.

IOs, conforme Tabela 18. É notório pelos tempos médios das decomposições que sinais com menor duração implicam em um número reduzido de IMFs, otimizando o processo de decomposição e tornando-o computacionalmente mais ágil.

Associado à redução do custo computacional, observa-se uma melhoria nos IOs, em média, entre as IMFs extraídas. Tal progresso pode ser observado ao comparar as Tabelas 12 e 18, que contêm as informações sobre IOs referentes aos sinais de durações de 10, 5, 2 e 1 segundos. Como destacado anteriormente, a ortogonalidade entre as IMFs é uma propriedade desejável, pois sinaliza a eficácia da extração das IMFs, que, por sua vez, correspondem a faixas de frequências presentes no sinal original. Ao decompor sinais com menor duração, as chances de sobreposições de frequências entre IMFs diferentes é reduzida, resultando em um conjunto de IMFs com menor IO. Essa melhoria na ortogonalidade contribui para a precisão e a clareza dos resultados derivados da EMD, reforçando a hipótese de que é possível obter resultados iguais ou melhores que os obtidos para sinais de maior duração.

Assim como no ensaio E1-G1, destaca-se um número considerável de *outliers* com valores superiores a 1. De modo geral, estes números não exibem alterações expressivas em sua quantidade. Observando que as energias mínimas em todas as configurações são maiores que 1, concluí-se, com base nos argumentos apresentados na subseção anterior, que a EMD não foi capaz de decompor alguns sinais de forma eficaz em componentes ortogonais. Desse modo, as IMFs associadas a estas decomposições são categorizadas como de qualidade inferior. Em relação a esse aspecto, é notório que as configurações que envolvem os critérios de parada SD e EDT apresentam uma menor quantidade de *outliers*, além de exibirem menores IOs em média.

Tabela 18 – Detalhes sobre a distribuição dos IOs e o Tempo Médio de Decomposição (TMD), expresso em segundos, para todas as configurações. O termo “Lim. sup.” refere-se a $Q3 + 1.5 \cdot IIQ$, sendo $Q3$ o terceiro quartil e IIQ o intervalo interquartil.

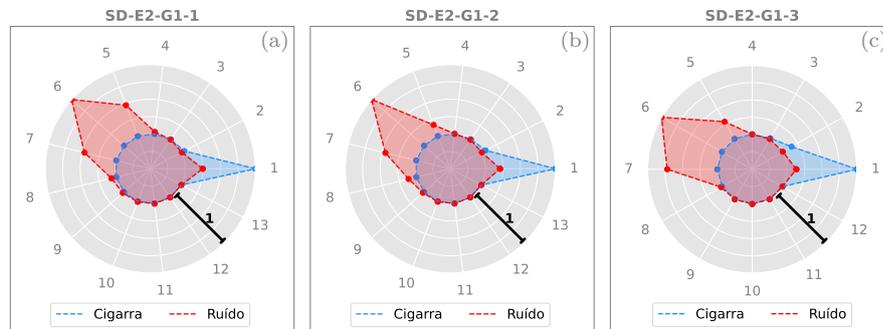
Configuração	min(E)	min(IO)	Lim. sup. (IO)	Média (IO)	Outliers > 1	TMD (s)
SD-E2-G1-1		$6.78 \cdot 10^{-4}$	0.22653	3.71	12	1.55
SSC-E2-G1-1		$1.05 \cdot 10^{-3}$	0.39613	$5.77 \cdot 10^3$	128	173.17
TTC-E2-G1-1		$6.27 \cdot 10^{-4}$	0.56030	$1.05 \cdot 10^3$	145	247.73
EDT-E2-G1-1	$1 + 2.43 \cdot 10^{-3}$	$1.09 \cdot 10^{-3}$	0.25045	$1.37 \cdot 10^1$	21	14.60
RFC-E2-G1-1		$1.30 \cdot 10^{-3}$	0.70128	$2.76 \cdot 10^4$	186	67.01
OC-E2-G1-1		$1.49 \cdot 10^{-3}$	0.31798	$7.87 \cdot 10^2$	49	61.26
VDS-E2-G1-1		$1.26 \cdot 10^{-3}$	0.21229	$8.04 \cdot 10^3$	61	54.08
BWC-E2-G1-1		$4.07 \cdot 10^{-3}$	2.55262	$7.15 \cdot 10^4$	247	1661.01
SD-E2-G1-2		$6.15 \cdot 10^{-4}$	0.24762	$1.64 \cdot 10^{-1}$	19	0.60
SSC-E2-G1-2		$8.77 \cdot 10^{-4}$	0.47946	1.16	129	35.79
TTC-E2-G1-2		$6.02 \cdot 10^{-4}$	0.72030	1.22	164	50.72
EDT-E2-G1-2	$1 + 7.83 \cdot 10^{-4}$	$9.13 \cdot 10^{-4}$	0.31775	$2.98 \cdot 10^{-1}$	32	4.78
RFC-E2-G1-2		$9.98 \cdot 10^{-4}$	1.31520	$7.02 \cdot 10^1$	206	20.66
OC-E2-G1-2		$1.26 \cdot 10^{-3}$	0.48555	$6.21 \cdot 10^{-1}$	94	15.74
VDS-E2-G1-2		$1.06 \cdot 10^{-3}$	0.33277	1.36	77	14.27
BWC-E2-G1-2		$2.42 \cdot 10^{-3}$	3.03920	$2.77 \cdot 10^2$	255	425.75
SD-E2-G1-3		$6.14 \cdot 10^{-4}$	0.28786	$1.66 \cdot 10^{-1}$	22	0.24
SSC-E2-G1-3		$8.93 \cdot 10^{-4}$	0.59880	1.10	151	19.01
TTC-E2-G1-3		$6.29 \cdot 10^{-4}$	0.74933	1.42	195	16.51
EDT-E2-G1-3	$1 + 9.65 \cdot 10^{-5}$	$9.35 \cdot 10^{-4}$	0.36521	$2.57 \cdot 10^{-1}$	46	2.01
RFC-E2-G1-3		$9.72 \cdot 10^{-4}$	2.21994	5.06	248	10.41
OC-E2-G1-3		$1.12 \cdot 10^{-3}$	0.67478	$6.15 \cdot 10^{-1}$	163	7.09
VDS-E2-G1-3		$9.54 \cdot 10^{-4}$	0.43982	$6.89 \cdot 10^{-1}$	105	5.59
BWC-E2-G1-3		$1.62 \cdot 10^{-3}$	3.92923	$1.52 \cdot 10^1$	225	162.73

Fonte: Elaborada pelo autor.

E2-G1: Resultados do Módulo MNF

A partir dos conjuntos de vetores de *features* obtidos, o próximo passo é a aplicação do módulo MNF para normalização. A técnica adotada neste ensaio foi a MN, assim como no ensaio anterior, conforme descrito na Tabela 15. Na Figura 51, são apresentados os gráficos de radar correspondentes aos vetores com frações reduzidas de tempo, derivados dos vetores introduzidos na subseção anterior e ilustrados na Figura 30.

Figura 51 – Exemplos de vetores de *features* formados pelas configurações SD-E2-G1- $\{1,2,3\}$. Estes vetores correspondem aos representados na Figura 30, porém resultantes dos sinais com frações de tempo reduzidas.



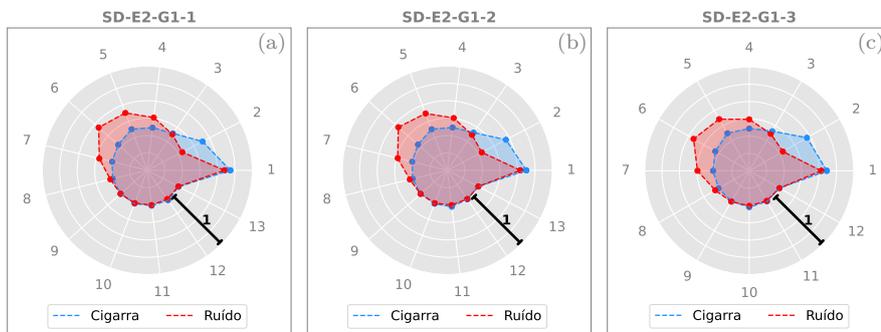
Fonte: Produzido pelo autor.

Os gráficos evidenciam, assim como na subseção anterior, distinções marcantes entre os vetores das classes “cigarra” e “ruído”. Os vetores associados à classe “cigarra” exibem perfis energéticos distintivos, com picos nas IMFs de número 1, apresentando

decréscimo acentuado nas IMFs subsequentes. Em contraste, os vetores relativos à classe “ruído”, demonstram maiores distribuições de energia entre as IMFs 5, 6 e 7, com picos nas sextas IMFs.

Em uma análise geral, observa-se que as classes são, em média, distinguíveis, conforme demonstrado no exemplo da Figura 51. Evidentemente, há variações nas representações das distribuições de energias das diferentes configurações, principalmente devido à quantidade de IMFs. No entanto, em média, as características discutidas em E1-G1 permanecem para todas as configurações. A Figura 52 ilustra as médias dos vetores normalizados para as três configurações associadas ao critério de parada SD.

Figura 52 – Gráficos de radar das *features*, em média, para as classes “cigarra” e “ruído” das configurações SD-E2-G1- $\{1,2,3\}$.



Fonte: Produzido pelo autor.

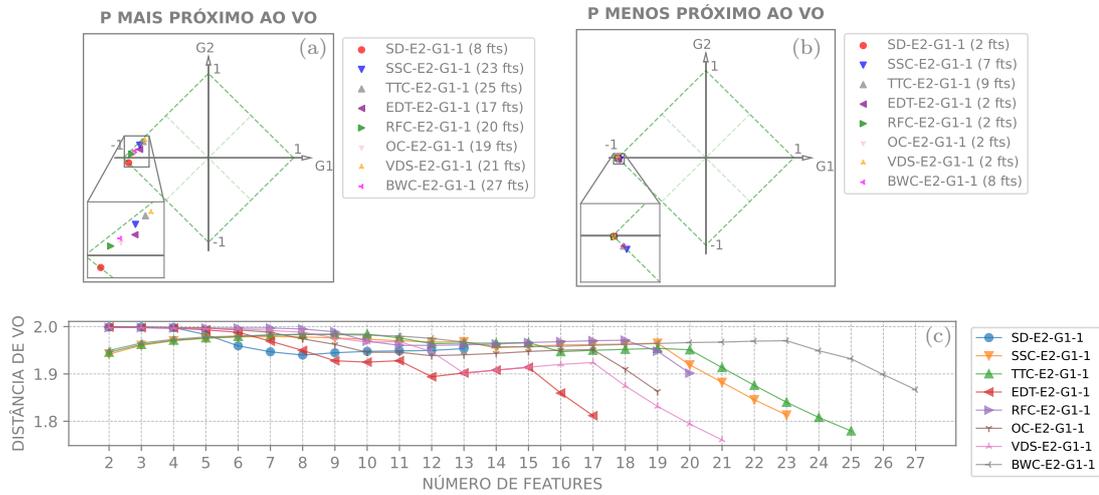
Esta uniformidade, identificada em todas as configurações exploradas, realça a relevância e eficiência dessas características para a classificação dos sinais com frações reduzidas, reforçando a hipótese proposta nesta subseção. Os gráficos pertinentes às representações das distribuições médias das energias no formato radar, correspondentes às demais configurações deste ensaio foram omitidos visando evitar redundâncias e assegurar clareza e objetividade na exposição dos resultados.

E2-G1: Resultados do Módulo MPFE

Prosseguindo com a avaliação dos vetores, as variações determinadas pela alteração no número de *features* foram submetidas ao módulo MPFE. Especificamente, as k primeiras *features* foram consideradas, com k variando entre 2 e M . Vale ressaltar que a métrica adotada para análise baseou-se na menor distância entre o ponto P , determinado pela PFE, e o VO.

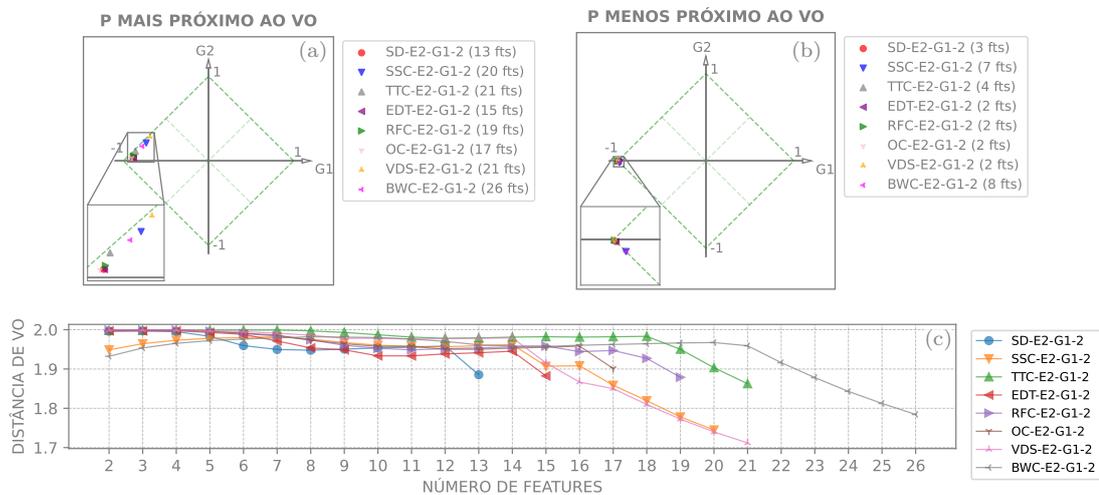
As Figuras 53, 54 e 55 destacam tanto os melhores quanto os piores resultados para as configurações examinadas, bem como todas as distâncias ao VO referentes aos pontos P associados aos conjuntos de vetores em análise.

Figura 53 – Resumo dos resultados do módulo MPFE para E2-G1-1. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

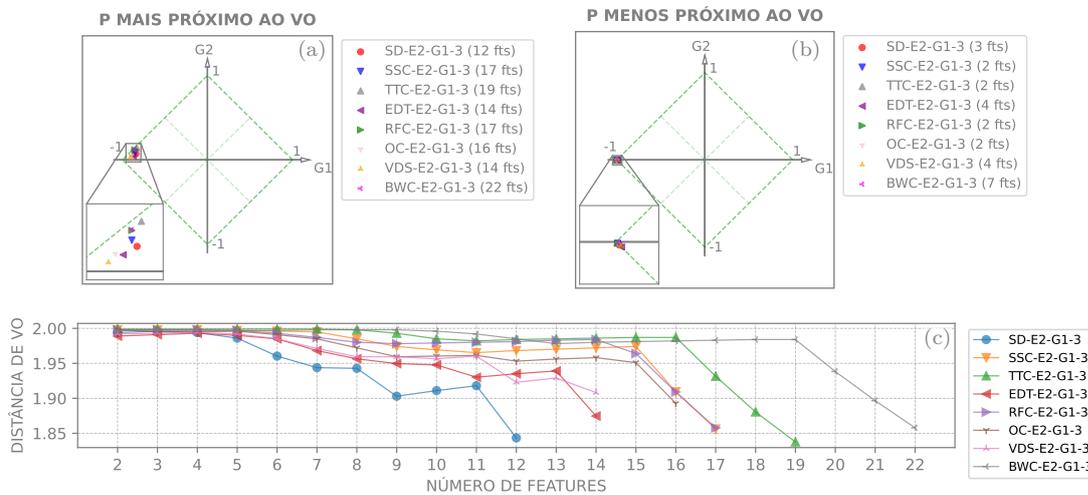
Figura 54 – Resumo dos resultados do módulo MPFE para E2-G1-2. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Observa-se que a duração dos sinais não exerce influência significativa sobre os resultados das análises PFE. No entanto, em determinados casos foram observados valores inferiores aos correspondentes às configurações de E1-G1, tais como: VDS-E2-G1-1 (21 fts) e TTC-E2-G1-1 (25 fts) abaixo de 1.78; e VDS-E2-G1-2 (21 fts) e SSC-E2-G1-2 (20 fts) abaixo de 1.75. Os resultados mais promissores associados aos sinais com apenas 1 segundo de duração (E2-G1-3) exibiram valores próximos a 1.85, de maneira similar ao observado em E1-G1. Em particular, as configurações associadas aos critérios de parada SD e TTC ao considerar 12 e 19 *features*, respectivamente.

Figura 55 – Resumo dos resultados do módulo MPFE para E2-G1-3. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Quanto à disposição dos pontos nos PPs, observa-se, analogamente ao ensaio E1-G1, que os pontos resultantes posicionaram-se mais próximos do vértice $(-1, 0)$, o qual está associado à falsidade. Esta observação indica que, em todas as situações avaliadas, os vetores intraclasse tendem a ser dispersos, ao passo que os vetores interclasse demonstram uma sobreposição significativa. Diante desse cenário, para superar esse desafio, será imprescindível a adoção de um classificador forte, como o SVM.

Conclui-se, a partir da análise PFE, que sinais com menor duração não comprometem o processo de classificação, corroborando positivamente com a hipótese inicialmente levantada sobre a viabilidade do uso destes sinais. Na subseção seguinte, são apresentados os testes relacionados ao módulo MTT.

E2-G1: Resultados do módulo MTT

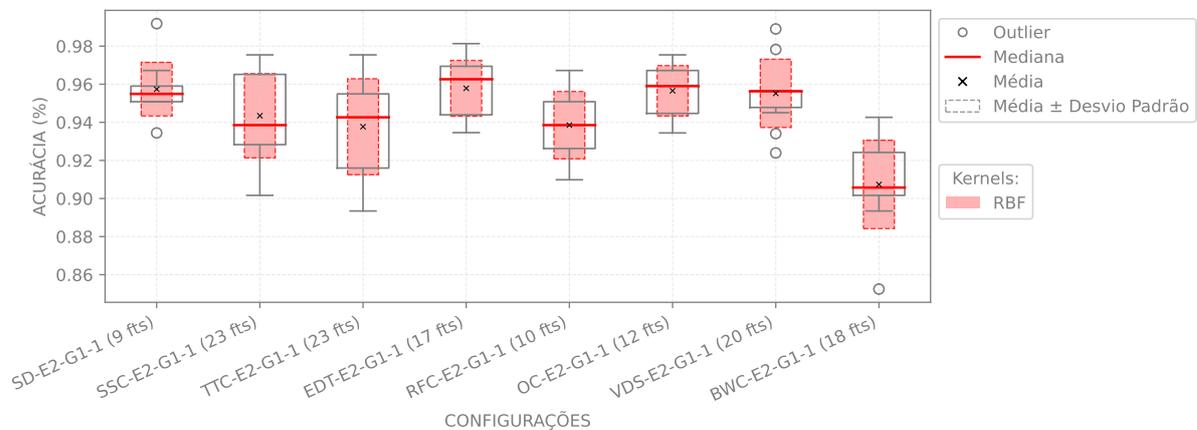
Prosseguindo com a avaliação de desempenho dos modelos SVM, o módulo MTT processa todos os conjuntos de vetores formados ao se variar a quantidade de *features*, em sequência crescente, de forma análoga ao descrito na subseção anterior. Os parâmetros designados para o treinamento do classificador estão elencados na Tabela 6. Assim como em E1-G1, o limiar de treinamento foi definido por múltiplos de 10 no intervalo de 20 a 80.

Dados os máximos de *features* M alcançados, conforme a Tabela 17, e considerando a validação cruzada com $k = 10$ partições e o fato de que o *kernel* linear não utiliza o parâmetro γ , realizaram-se $7\,700 \cdot (M - 1)$ treinamentos distintos para cada configuração especificada na Tabela 15, totalizando 3 264 800 treinamentos. Ao final deste processo, os modelos que exibiram maiores médias de acurácias no processo de validação cruzada foram

eleitos para os testes definitivos, utilizando o conjunto de dados especificamente reservado para essa finalidade.

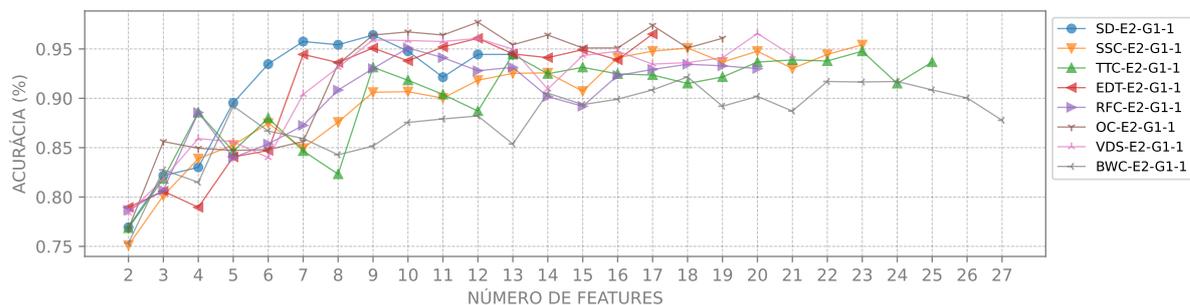
Após a análise de todos os conjuntos de vetores em função da variação do número de *features*, nas Figuras 56, 58 e 60 seguem os resultados dos treinamentos com validação cruzada dos modelos que apresentaram os melhores desempenhos nos testes subsequentes, abrangendo todas as configurações. Adicionalmente, as Figuras 57, 59 e 61 ilustram os resultados dos testes dos melhores modelos em todos os cenários avaliados.

Figura 56 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E2-G1-1. O número de *features* corresponde à sequência de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 57 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E2-G1-1. O número de *features* é dado pela ordem de extração das IMFs.

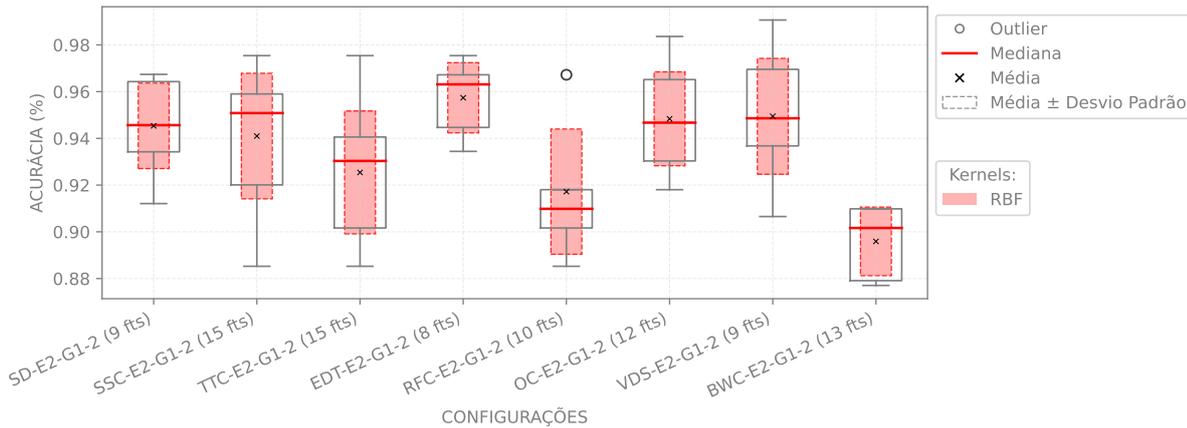


Fonte: Produzido pelo autor.

Para os ensaios E2-G1-1, com exceção da configuração BWC-E2-G1-1, todos os conjuntos de vetores com 9 ou mais *features* atingiram acurácias iguais ou superiores a 90% (Figura 57). O destaque para o menor número de *features* foi EDT-E2-G1-1 (2 fts) com 79%. Quanto aos melhores desempenhos gerais, as seguintes configurações se sobressaíram: SD-E2-G1-1 (9 fts), SSC-E2-G1-1 (23 fts), TTC-E2-G1-1 (23 fts), EDT-E2-G1-1 (17 fts).

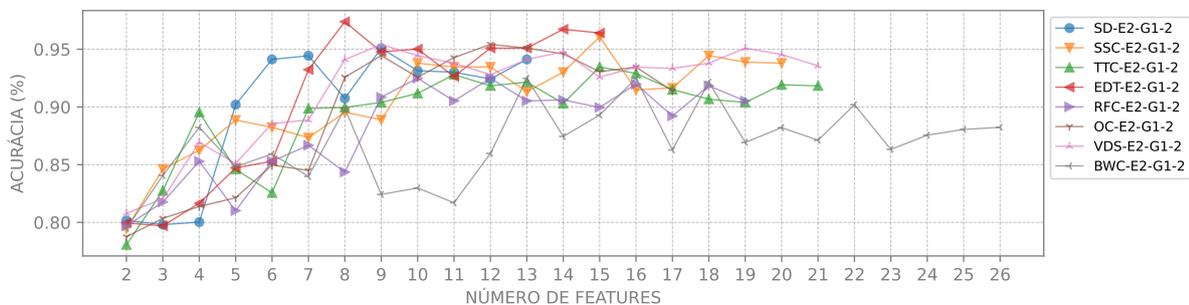
fts), RFC-E2-G1-1 (10 fts), OC-E2-G1-1 (12 fts), VDS-E2-G1-1 (20 fts) e BWC-E2-G1-1 (18 fts). Assim como em E1-G1, os melhores resultados dos testes são superiores a 95%, excetuando-se as configurações referentes aos critérios de parada TTC e BWC.

Figura 58 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E2-G1-2. O número de *features* corresponde à sequência de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 59 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E2-G1-2. O número de *features* é dado pela ordem de extração das IMFs.

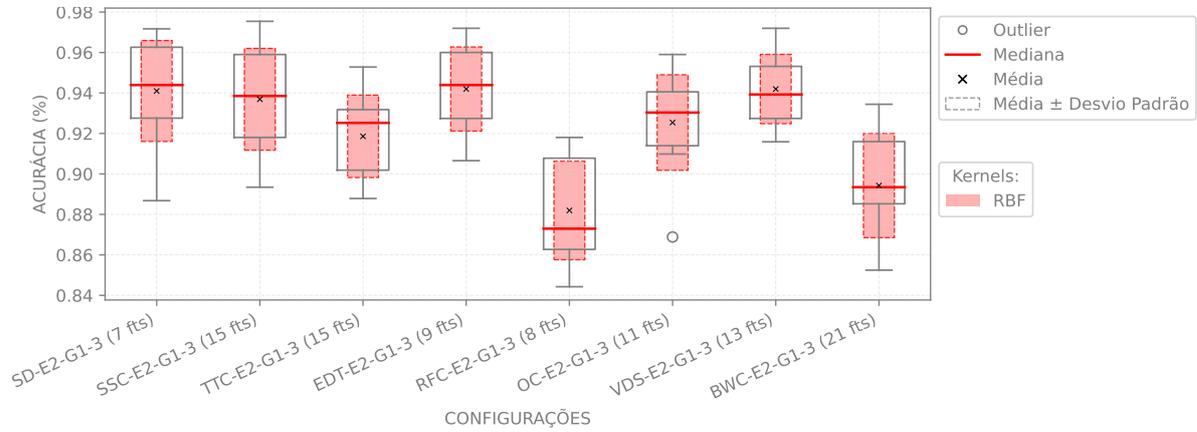


Fonte: Produzido pelo autor.

Nos ensaios E2-G1-2, à exceção das configurações referentes ao critério de parada BWC, todos os conjuntos de vetores com 9 ou mais *features* atingiram acurácias iguais ou superiores a 90% (Figura 59). VDS-E2-G1-2 (2 fts) obteve 81% de acurácia dentre as configurações com menos *features*. Em relação aos melhores desempenhos gerais, SD-E2-G1-2 (9 fts), SSC-E2-G1-2 (15 fts), TTC-E2-G1-2 (15 fts), EDT-E2-G1-2 (8 fts), RFC-E2-G1-2 (10 fts), OC-E2-G1-2 (12 fts), VDS-E2-G1-2 (9 fts) e BWC-E2-G1-2 (13 fts) se destacaram. Comparando os ensaios E2-G1-1 e E2-G1-2, observa-se que o último necessitou de menos *features* para atingir os melhores resultados.

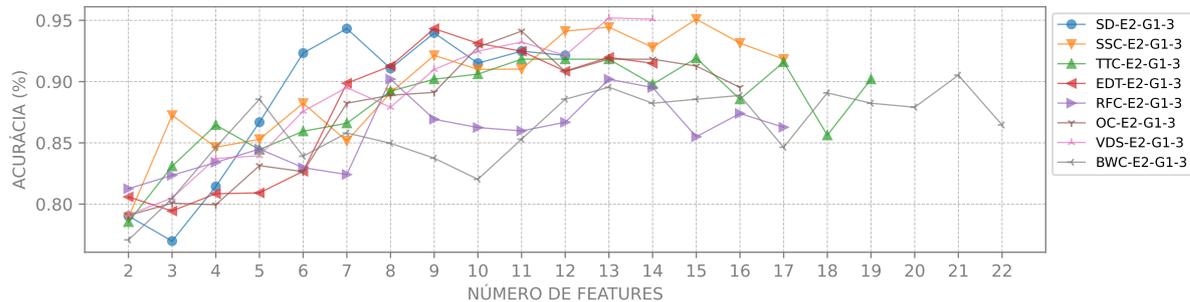
Finalmente, nos testes E2-G1-3, as configurações referentes aos critérios de parada SD, SSC, EDT, OC e VDS resultaram em acurácias próximas ou acima de 90% para

Figura 60 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E2-G1-3. O número de *features* corresponde à sequência de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 61 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E2-G1-3. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

os conjuntos de vetores de 9 ou mais *features* (Figura 61). Considerando apenas duas *features*, RFC-E2-G1-3 destacou-se em relação às demais com aproximadamente 82% de acurácia. Quanto aos melhores desempenhos gerais, sobressaíram-se: SD-E2-G1-3 (7 fts), SSC-E2-G1-3 (15 fts), TTC-E2-G1-3 (15 fts), EDT-E2-G1-3 (9 fts), RFC-E2-G1-3 (8 fts), OC-E2-G1-3 (11 fts), VDS-E2-G1-3 (13 fts) e BWC-E2-G1-3 (21 fts). Comparado aos ensaios anteriores, E2-G1-3 mostrou que menos *features* eram necessárias para atingir os melhores resultados que, com exceção de {TTC, RFC e BWC}-E2-G1-3, ficaram acima de 94%.

No que se refere aos *kernels*, o RBF mostrou-se predominante entre os melhores hiperparâmetros para as configurações avaliadas neste ensaio, prevalecendo em 100% das ocorrências. Outro fato notável é que todos os resultados dos testes se enquadram dentro da faixa média \pm desvio padrão. Este padrão, também observado em E1-G1, sugere que os intervalos estabelecidos representam de forma adequada as variações de desempenho

dos modelos, evidenciando que, de modo geral, os modelos mantêm uma performance consistente mesmo com sinais de duração reduzida.

Os hiperparâmetros determinados para os modelos de melhor desempenho, bem como as métricas acurácia, precisão, *recall*, *F1-score* e AUC, estão detalhados na Tabela 19. Os modelos de melhor desempenho alcançaram um AUC mínimo de 0.95, atingindo 0.99 nos casos SD-E2-G1-1 e EDT-E2-G1-2 com vetores de 9 e 8 *features*, respectivamente. As configurações que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada estão destacadas na Tabela 19. Priorizou-se o *F1-score* máximo, conforme descrito na subseção referente ao ensaio E1-G1.

Tabela 19 – Melhores resultados em E2-G1. As configurações destacadas são as que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada.

Configuração	Num. features	Amostras treino (%)	C	γ	Kernel	Acurácia	Precisão	Recall	F1-score	AUC
SD-E2-G1-1	9	80	100	10	RBF	0.96405	0.97500	0.95706	0.96594	0.99
SSC-E2-G1-1	23	80	100	10	RBF	0.95425	0.96154	0.94937	0.95541	0.98
TTC-E2-G1-1	23	80	1000	1	RBF	0.94771	0.94194	0.95425	0.94805	0.97
EDT-E2-G1-1	17	70	100	10	RBF	0.96507	0.97854	0.95397	0.96610	0.99
RFC-E2-G1-1	10	80	1000	1	RBF	0.95098	0.95395	0.94771	0.95082	0.98
OC-E2-G1-1	12	80	1000	10	RBF	0.97712	0.97143	0.97842	0.97491	0.98
VDS-E2-G1-1	20	60	1000	10	RBF	0.96563	0.96321	0.96644	0.96482	0.98
BWC-E2-G1-1	18	80	1000	1	RBF	0.92157	0.94079	0.90506	0.92258	0.95
SD-E2-G1-2	9	60	1000.0	10.0	RBF	0.95090	0.94720	0.95912	0.95312	0.98
SSC-E2-G1-2	15	80	1000.0	1	RBF	0.96078	0.97386	0.94904	0.96129	0.98
TTC-E2-G1-2	15	80	1000.0	1	RBF	0.93464	0.94118	0.92903	0.93506	0.97
EDT-E2-G1-2	8	80	1000.0	10.0	RBF	0.97386	0.97297	0.97297	0.97297	0.99
RFC-E2-G1-2	10	80	1000.0	1	RBF	0.92484	0.90977	0.91667	0.91321	0.95
OC-E2-G1-2	12	80	1000.0	10.0	RBF	0.95425	0.94375	0.96795	0.95570	0.98
VDS-E2-G1-2	9	70	100.0	10.0	RBF	0.95415	0.94141	0.97571	0.95825	0.99
BWC-E2-G1-2	13	80	1000.0	1	RBF	0.92484	0.93038	0.92453	0.92744	0.97
SD-E2-G1-3	7	70	1000	10	RBF	0.94323	0.92857	0.95413	0.94118	0.97
SSC-E2-G1-3	15	80	1000	1	RBF	0.95098	0.93865	0.96835	0.95327	0.98
TTC-E2-G1-3	15	70	1000	1	RBF	0.91921	0.90171	0.93778	0.91939	0.96
EDT-E2-G1-3	9	70	1000	10	RBF	0.94323	0.96203	0.93061	0.94606	0.98
RFC-E2-G1-3	8	80	100	10	RBF	0.90196	0.89796	0.89796	0.89796	0.96
OC-E2-G1-3	11	80	1000	10	RBF	0.94118	0.92157	0.95918	0.94000	0.98
VDS-E2-G1-3	13	70	1000	1	RBF	0.95197	0.94348	0.96018	0.95175	0.97
BWC-E2-G1-3	21	80	1000	1	RBF	0.90523	0.95000	0.85806	0.90169	0.96

Fonte: Elaborada pelo autor.

Com base nas análises e considerando os resultados detalhados nas Tabelas 18 e 19, conclui-se que é possível reduzir o custo computacional do processo ao se utilizar sinais com menor duração, sem comprometer a performance do sistema. Adicionalmente observou-se uma melhora significativa na ortogonalidade, em média, entre as IMFs. Em algumas configurações avaliadas, houve também uma redução no número de *features* necessárias, o que pode permitir na prática a interrupção do SP da EMD tão logo o número requerido de IMFs seja atingido.

Finalmente, acurácias e *F1-scores* acima de 95%, alcançando até 97% em determinados cenários, são indicativos de que algumas configurações obtiveram desempenho comparável ao do ensaio E1-G1. Estes resultados sugerem que os modelos foram eficientes na classificação das observações, equilibrando de forma apropriada a detecção de cigarras e a minimização de FPs.

Conclui-se pela viabilidade do sistema proposto com uso de sinais de duração

reduzida, demonstrada a robustez e precisão nos testes conduzidos, validando a hipótese levantada nesta subseção.

Nas subseções subsequentes, mais esforços foram empenhados para aprimorar o sistema do ponto de vista computacional, bem como para conduzir investigações adicionais visando melhorar o desempenho dos classificadores.

4.2.1.3 Experimento E3

No ensaio anterior, validou-se a hipótese de que o sistema proposto, ao empregar sinais com durações inferiores que os 10 segundos utilizados em E1-G1, pode alcançar resultados satisfatórios tanto em termos de custo quanto computacional de desempenho. Assim, nesta subseção, o objetivo é minimizar ainda mais o custo computacional associado ao processamento dos sinais. A hipótese agora em foco sugere que a redução da taxa de amostragem não compromete a eficácia dos modelos classificadores. Neste contexto, o experimento E3 foi realizado com sinais reamostrados através do método “*signal.resample*” da biblioteca *Python “scipy”* derivados dos sinais originais, os quais foram capturados a uma taxa de amostragem de 44.1 kHz e 16 bits de quantização. Foram consideradas as taxas de amostragem 22, 13 e 6 kHz, fixando-se a duração de 1 segundo para cada sinal. Para o processamento pela EMD, os 8 critérios de parada foram aplicados, e o número máximo de iterações por IMF foi fixado em 700. Os vetores foram normalizados com a técnica MN. Todos os parâmetros específicos associados a cada critério de parada permanecem inalterados em relação aos estabelecidos nas subseções anteriores. As configurações adotadas neste ensaio estão detalhadas na [Tabela 20](#).

Tabela 20 – Configurações para o experimento E3 do grupo G1.

Rótulos	Amostragem (kHz)	Tempo (s)	Configurações da EMD		Norma	It. Max.
			Critério de parada	Parâmetros		
SD-E3-G1-1	22	1	SD	$\varepsilon = 0.1$	MN	700
SSC-E3-G1-1			SSC	$S = 3$		
TTC-E3-G1-1			TTC	$\alpha = 0.05, \theta_1 = 0.05, \theta_2 = 0.5$		
EDT-E3-G1-1			EDT	$\varepsilon = 0.001$		
RFC-E3-G1-1			RFC	$R = 50$		
OC-E3-G1-1			OC	$\varepsilon = 0.05$		
VDS-E3-G1-1			VDS	95% de $m(t) < 0.005$		
BWC-E3-G1-1			BWC	mínimo de B_f^2 encontrado		
SD-E3-G1-2	13	1	SD	$\varepsilon = 0.1$	MN	700
SSC-E3-G1-2			SSC	$S = 3$		
TTC-E3-G1-2			TTC	$\alpha = 0.05, \theta_1 = 0.05, \theta_2 = 0.5$		
EDT-E3-G1-2			EDT	$\varepsilon = 0.001$		
RFC-E3-G1-2			RFC	$R = 50$		
OC-E3-G1-2			OC	$\varepsilon = 0.05$		
VDS-E3-G1-2			VDS	95% de $m(t) < 0.005$		
BWC-E3-G1-2			BWC	mínimo de B_f^2 encontrado		
SD-E3-G1-3	6	1	SD	$\varepsilon = 0.1$	MN	700
SSC-E3-G1-3			SSC	$S = 3$		
TTC-E3-G1-3			TTC	$\alpha = 0.05, \theta_1 = 0.05, \theta_2 = 0.5$		
EDT-E3-G1-3			EDT	$\varepsilon = 0.001$		
RFC-E3-G1-3			RFC	$R = 50$		
OC-E3-G1-3			OC	$\varepsilon = 0.05$		
VDS-E3-G1-3			VDS	95% de $m(t) < 0.005$		
BWC-E3-G1-3			BWC	mínimo de B_f^2 encontrado		

Fonte: Elaborada pelo autor.

E3-G1: Resultados do Módulo MEF

A redução da taxa de amostragem impacta diretamente na resolução espectral dos sinais (UNSER, 2000) e, no contexto desta pesquisa, influencia o processo de decomposição pela EMD, pois os extremos dos sinais desempenham um papel importante na construção das envoltórias, conforme descrito no Capítulo 2. Ao reduzir a taxa de amostragem, os sinais podem perder componentes de altas frequências ou sofrer *aliasing*, afetando assim o SP e a quantidade de IMFs (RILLING; FLANDRIN, 2006), conforme demonstrado na Tabela 21, que exhibe as médias de iterações para as decomposições dos sinais com taxa de amostragem reduzida para os ensaios E3-G1-3. Nota-se uma redução significativa tanto no número de iterações quanto no número de IMFs ao comparar os resultados desta tabela com os da Tabela 16.

Tabela 21 – Número máximo de IMFs e média de iterações do SP, por classe, em cada configuração da terceira rodada de testes de E3-G1. C indica a classe “cigarra” e R a classe “ruído”.

Componentes	SD-E3-G1-3		SSC-E3-G1-3		TTC-E3-G1-3		EDT-E3-G1-3		RFC-E3-G1-3		OC-E3-G1-3		VDS-E3-G1-3		BWC-E3-G1-3	
	C	R	C	R	C	R	C	R	C	R	C	R	C	R	C	R
IMF 1	2	4	34	50	23	34	10	9	26	17	33	45	32	23	303	170
IMF 2	3	5	23	39	24	34	12	8	29	23	38	33	13	24	440	332
IMF 3	3	4	23	35	24	36	11	8	38	40	26	29	12	30	426	339
IMF 4	3	3	18	27	25	35	10	9	46	61	27	26	11	29	356	337
IMF 5	3	2	13	14	23	25	11	12	59	83	26	26	7	23	292	282
IMF 6	3	2	10	8	21	23	13	14	64	93	26	24	4	15	257	245
IMF 7	3	3	8	7	25	26	14	15	76	95	23	23	3	10	226	224
IMF 8	3	2	8	9	29	40	15	21	76	97	22	18	2	5	197	204
IMF 9	2	2	7	6	44	40	19	26	82	109	20	15	2	3	204	202
IMF 10	-	-	6	4	46	39	21	58	97	83	16	11	2	2	205	222
IMF 11	-	-	10	5	38	28	35	7	90	75	11	11	-	-	228	264
IMF 12	-	-	4	-	45	1	2	-	74	68	6	4	-	-	253	344
IMF 13	-	-	-	-	13	-	-	-	46	-	-	-	-	-	295	256
IMF 14	-	-	-	-	-	-	-	-	-	-	-	-	-	-	335	304
IMF 15	-	-	-	-	-	-	-	-	-	-	-	-	-	-	324	-

Fonte: Elaborada pelo autor.

Este comportamento destaca a relevância da taxa de amostragem na análise dos sinais e evidencia a necessidade de uma escolha adequada da mesma para assegurar uma representação precisa das características intrínsecas dos sinais. Esta seleção está atrelada à teoria de amostragem e deve-se considerar o Teorema de Nyquist (NYQUIST, 1928), que determina que a taxa de amostragem deve ser, no mínimo, o dobro da maior frequência presente no sinal para garantir que este possa ser corretamente reconstruído sem ambiguidade. A frequência dominante, emitida pela *Quesada gigas*, presente nos sinais empregados nos experimentos é de aproximadamente 1 700 Hz. Portanto, as taxas de amostragem propostas para os experimentos desta subseção estão em conformidade com o teorema e não comprometem as frequências de interesse. A Tabela 22 detalha as quantidades máximas, M , de IMFs obtidas por configuração em E3-G1.

Tabela 22 – Quantidade máxima (M) de IMFs por configuração em E3-G1, incluindo o resíduo.

Configuração	E3-G1-1	E3-G1-2	E3-G1-3
SD	11	11	10
SSC	16	14	13
TTC	18	16	14
EDT	14	13	13
RFC	17	15	14
OC	16	14	13
VDS	14	13	12
BWC	20	18	16

Fonte: Elaborada pelo autor.

Em síntese, conforme mencionado, fica evidente que a redução da taxa de amostragem dos sinais resulta na extração de um número menor de IMFs, otimizando o processo de decomposição e tornando-o computacionalmente mais eficiente. Associada à redução do custo computacional, observa-se uma singela melhoria nos IOs, em média, entre as IMFs extraídas. Tal progresso pode ser observado comparando as Tabelas 18 e 23. Essa melhoria na ortogonalidade contribui para a precisão e a clareza dos resultados derivados da EMD, reforçando a hipótese de que é possível obter resultados equiparáveis aos obtidos para sinais com maior taxa de amostragem.

Tabela 23 – Detalhes sobre a distribuição dos IOs e o Tempo Médio de Decomposição (TMD), expresso em segundos, para todas as configurações. O termo “Lim. sup.” refere-se a $Q3 + 1.5 \cdot IIQ$, sendo $Q3$ o terceiro quartil e IIQ o intervalo interquartil.

Configuração	min(E)	min(IO)	Lim. sup. (IO)	Média (IO)	Outliers > 1	TMD (s)
SD-E3-G1-1		$4.03 \cdot 10^{-4}$	0.24879	$1.33 \cdot 10^{-1}$	13	0.18
SSC-E3-G1-1		$7.38 \cdot 10^{-4}$	0.44092	1.02	97	8.12
TTC-E3-G1-1		$4.15 \cdot 10^{-4}$	0.52018	$9.05 \cdot 10^{-1}$	137	10.14
EDT-E3-G1-1		$8.10 \cdot 10^{-4}$	0.31748	$2.96 \cdot 10^{-1}$	35	2.15
RFC-E3-G1-1	$1 + 4.32 \cdot 10^{-8}$	$9.90 \cdot 10^{-4}$	2.08889	4.47	246	10.42
OC-E3-G1-1		$1.15 \cdot 10^{-3}$	0.62227	$4.37 \cdot 10^{-1}$	131	5.32
VDS-E3-G1-1		$8.10 \cdot 10^{-4}$	0.37534	$5.25 \cdot 10^{-1}$	93	4.01
BWC-E3-G1-1		$1.37 \cdot 10^{-3}$	2.57397	$3.93 \cdot 10^1$	246	83.43
SD-E3-G1-2		$3.53 \cdot 10^{-4}$	0.27184	$1.25 \cdot 10^{-1}$	10	0.12
SSC-E3-G1-2		$1.23 \cdot 10^{-3}$	0.42246	1.00	97	3.77
TTC-E3-G1-2		$6.15 \cdot 10^{-4}$	0.56824	$9.77 \cdot 10^{-1}$	158	5.14
EDT-E3-G1-2		$5.87 \cdot 10^{-4}$	0.39390	$2.08 \cdot 10^{-1}$	55	1.38
RFC-E3-G1-2	1	$1.41 \cdot 10^{-3}$	3.03383	4.50	246	7.37
OC-E3-G1-2		$8.93 \cdot 10^{-4}$	0.83202	$5.86 \cdot 10^{-1}$	146	3.53
VDS-E3-G1-2		$8.01 \cdot 10^{-4}$	0.49369	$5.58 \cdot 10^{-1}$	119	1.89
BWC-E3-G1-2		$1.56 \cdot 10^{-3}$	2.53075	5.28	271	51.31
SD-E3-G1-3		$9.80 \cdot 10^{-4}$	0.27703	$1.19 \cdot 10^{-1}$	13	0.15
SSC-E3-G1-3		$1.79 \cdot 10^{-3}$	0.52770	$5.43 \cdot 10^{-1}$	125	1.68
TTC-E3-G1-3		$1.29 \cdot 10^{-3}$	0.73001	$6.50 \cdot 10^{-1}$	164	2.95
EDT-E3-G1-3		$1.78 \cdot 10^{-3}$	0.41156	$2.82 \cdot 10^{-1}$	61	0.74
RFC-E3-G1-3	$1 + 1.94 \cdot 10^{-4}$	$1.61 \cdot 10^{-3}$	3.87982	5.25	229	5.00
OC-E3-G1-3		$2.12 \cdot 10^{-3}$	1.01793	$5.57 \cdot 10^{-1}$	170	1.98
VDS-E3-G1-3		$1.62 \cdot 10^{-3}$	0.72138	2.21	159	0.82
BWC-E3-G1-3		$1.60 \cdot 10^{-3}$	2.42245	$1.49 \cdot 10^1$	249	28.51

Fonte: Elaborada pelo autor.

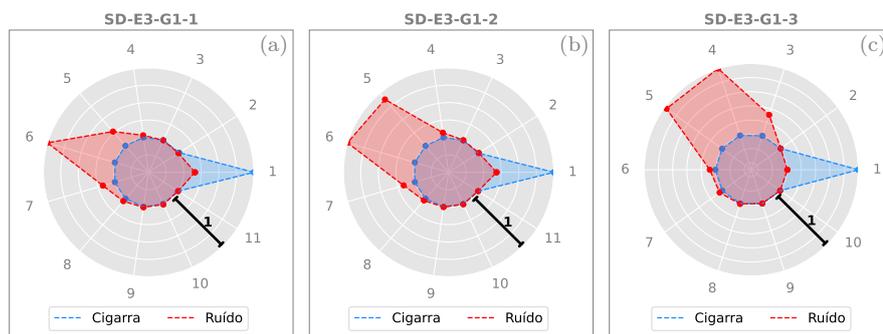
Assim como nos ensaios anteriores, observa-se um número considerável de *outliers* com valores superiores a 1. De modo geral, a quantidade desses números não apresenta alterações expressivas em relação ao ensaio E2-G1. Semelhante ao discutido na subseção re-

ferente ao ensaio E1-G1, e considerando que as energias mínimas em todas as configurações são maiores ou iguais a 1, conclui-se que a EMD não foi eficaz na decomposição de alguns sinais em componentes ortogonais. Portanto, as IMFs associadas a essas decomposições são categorizadas como de qualidade inferior. Em relação a esse aspecto, e coerente com os ensaios anteriores, é notório que as configurações que envolvem os critérios de parada SD e EDT apresentam uma menor quantidade de *outliers*, além de exibirem, em média, IOs mais baixos.

E3-G1: Resultados do Módulo MNF

Seguindo, aplica-se o módulo MNF para normalização dos vetores de *features* obtidos. A técnica adotada neste ensaio foi a MN, assim como no ensaio anterior, conforme descrito na Tabela 20. Na Figura 62, são apresentados os gráficos de radar dos vetores correspondentes aos sinais com taxas de amostragem reduzidas, derivados dos sinais introduzidos na subseção anterior e ilustrados na Figura 51c.

Figura 62 – Exemplos de vetores de *features* formados pelas configurações SD-E3-G1- $\{1,2,3\}$. Estes vetores correspondem aos representados na Figura 51c, porém resultantes dos sinais com taxas de amostragem reduzidas.



Fonte: Produzido pelo autor.

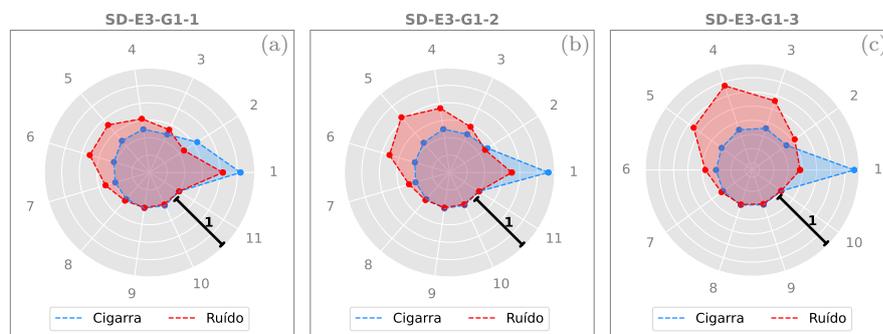
Os gráficos reiteram, assim como nas subseções anteriores, distinções significativas entre os vetores das classes “cigarra” e “ruído”. Os vetores associados à classe “cigarra” continuam a exibir perfis de energia distintivos, com picos nas IMFs de número 1 e decréscimos acentuados nas IMFs subsequentes. Em contraste, os vetores pertencentes à classe “ruído” mostram distribuições de energia mais acentuadas nas IMFs 5 a 7, com picos particularmente notáveis nas IMFs de número 6 para as configurações SD-E3-G1-1 e SD-E3-G1-2. Esta última configuração apresenta também um pico na quinta IMF. Para SD-E3-G1-3, há uma maior concentração de energia nas IMFs 3 a 5, com picos nas IMFs 4 e 5.

É notável que as energias tendem a se acumular em IMFs progressivamente menores à medida que a taxa de amostragem é reduzida. Este fenômeno ocorre porque cada IMF representa uma faixa específica de frequência e, como discutido nos resultados do módulo

anterior deste ensaio, a redução da taxa de amostragem pode levar à perda de componentes de altas frequências ou ao surgimento de *aliasing*, afetando assim o número de IMFs e resultando no comportamento observado.

Em uma análise geral, observa-se que as classes são, em média, distinguíveis, conforme demonstrado no exemplo da Figura 62. Evidentemente, há variações nas representações das distribuições de energias das diferentes configurações, principalmente devido à quantidade de IMFs. No entanto, em média, as características discutidas nos experimentos anteriores permanecem para todas as configurações. A Figura 63 ilustra as médias dos vetores normalizados para as três configurações associadas ao critério de parada SD.

Figura 63 – Gráficos de radar das *features*, em média, para as classes “cigarra” e “ruído” das configurações SD-E3-G1- $\{1,2,3\}$.



Fonte: Produzido pelo autor.

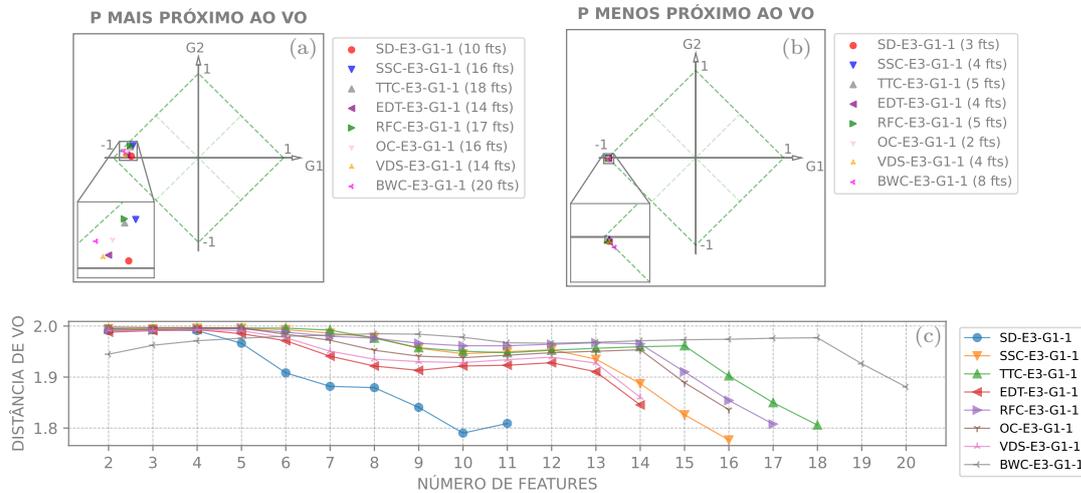
Esta uniformidade, identificada em todas as configurações exploradas, realça a relevância e eficiência dessas características para a classificação dos sinais com taxas de amostragem reduzidas, reforçando a hipótese proposta nesta subseção. Os gráficos pertinentes às representações das distribuições médias das energias no formato radar, correspondentes às demais configurações deste ensaio foram omitidos visando evitar redundâncias e assegurar clareza e objetividade na exposição dos resultados.

E3-G1: Resultados do Módulo MPFE

Prosseguindo com a avaliação dos vetores, as variações induzidas pela alteração no número de *features* foram novamente submetidas ao módulo MPFE. Especificamente, consideraram-se as k primeiras *features*, com k variando entre 2 e M , para todas as configurações. As Figuras 64, 65 e 66 destacam tanto os melhores quanto os piores resultados para as configurações examinadas, bem como todas as distâncias ao VO referentes aos pontos P associados aos conjuntos de vetores em análise.

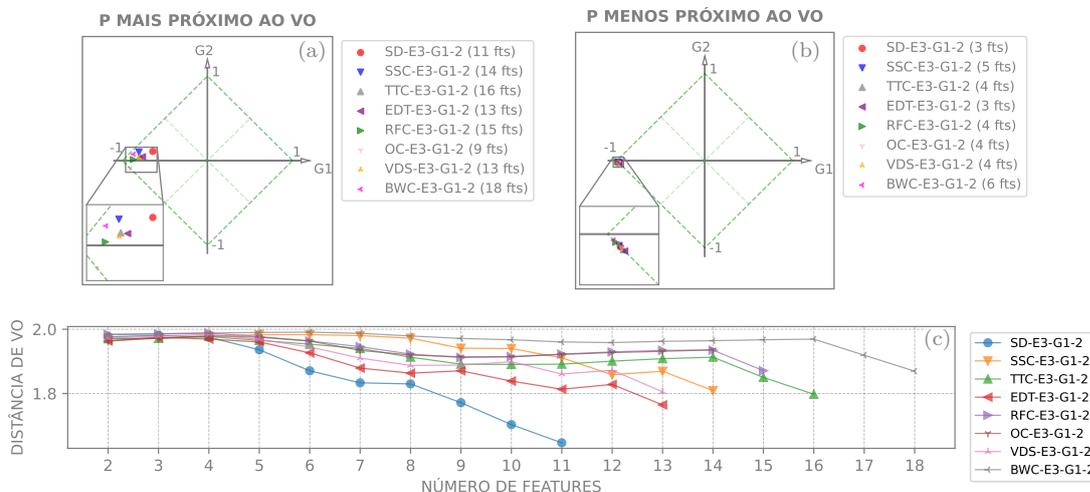
Observa-se que as taxas de amostragem consideradas para os sinais, apesar de diminuírem as distâncias em alguns casos, não exercem influência significativa sobre os

Figura 64 – Resumo dos resultados do módulo MPFE para E3-G1-1. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Figura 65 – Resumo dos resultados do módulo MPFE para E3-G1-2. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



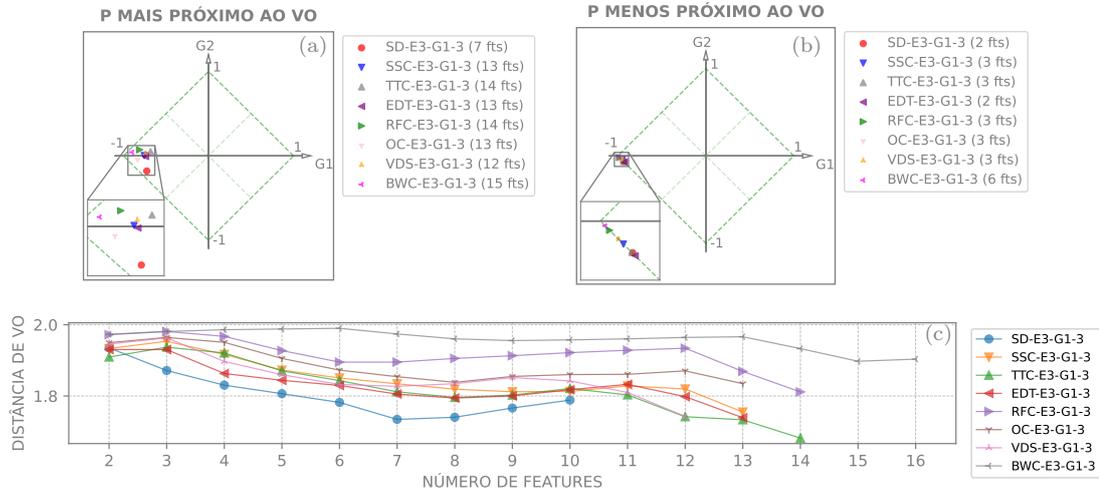
Fonte: Produzido pelo autor.

resultados das análises PFE. Os melhores resultados situaram-se no intervalo de 1.64 à 1.8 ou próximos a este.

Os resultados mais promissores, associados aos sinais com taxa de amostragem de 6 kHz (E3-G1-3), exibiram valores próximos a 1.7, representando uma pequena melhoria em relação ao E2-G1. Em particular, destacaram-se as configurações associadas aos critérios de parada SD, EDT e TTC, ao considerar 7, 13 e 14 *features*, respectivamente.

Quanto à disposição dos pontos nos PPs, observa-se, de maneira análoga aos ensaios

Figura 66 – Resumo dos resultados do módulo MPFE para E3-G1-3. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

anteriores, que os pontos resultantes posicionam-se, agora de maneira mais distribuída, próximos ao vértice $(-1, 0)$, associado à falsidade. Tal observação sugere que, nas situações avaliadas, os vetores intraclasse tendem a ser mais dispersos, enquanto os vetores interclasse sobrepõem-se de forma significativa. Isso justifica, uma vez mais, a escolha por um classificador forte, como o SVM.

A partir da análise PFE, conclui-se que a redução da taxa de amostragem dos sinais não exerce impacto significativo nos resultados, em comparação com os ensaios anteriores. Essa constatação, aliada à comprovação da viabilidade do sistema proposto nos experimentos anteriores para resolução do problema de classificação em questão, corrobora positivamente a hipótese levantada nesta subseção. Na subseção seguinte, são apresentados os testes relacionados ao módulo MTT.

E3-G1: Resultados do módulo MTT

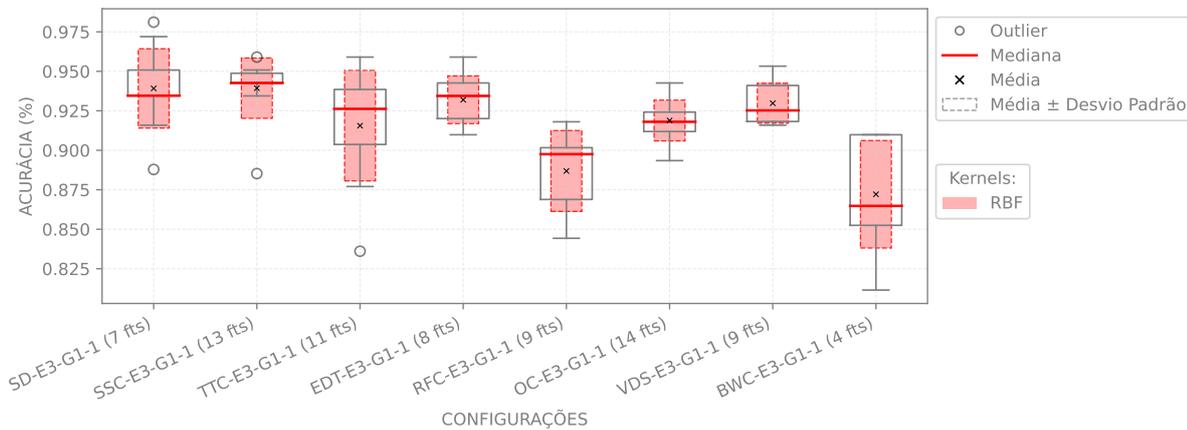
Prosseguindo para a avaliação de desempenho dos modelos SVM, o módulo MTT processa todos os conjuntos de vetores formados ao se variar a quantidade de *features*, em sequência crescente, de forma análoga ao descrito nas subseções anteriores. Os parâmetros designados para o treinamento do classificador estão elencados na Tabela 6. Assim como nos ensaios anteriores, o limiar de treinamento foi definido por múltiplos de 10 no intervalo de 20 a 80.

Dados os máximos, M , de *features* alcançados, conforme a Tabela 22; considerando a validação cruzada com $k = 10$ partições e o fato de que o *kernel* linear não utiliza o parâmetro γ , realizaram-se $7\,700 \cdot (M - 1)$ treinamentos distintos para cada configuração

especificada na Tabela 20, totalizando 2 471 700 treinamentos. Ao final deste processo, os modelos que exibiram maiores médias de acurácias no processo de validação cruzada foram eleitos para os testes definitivos, utilizando o conjunto de dados especificamente reservado para essa finalidade.

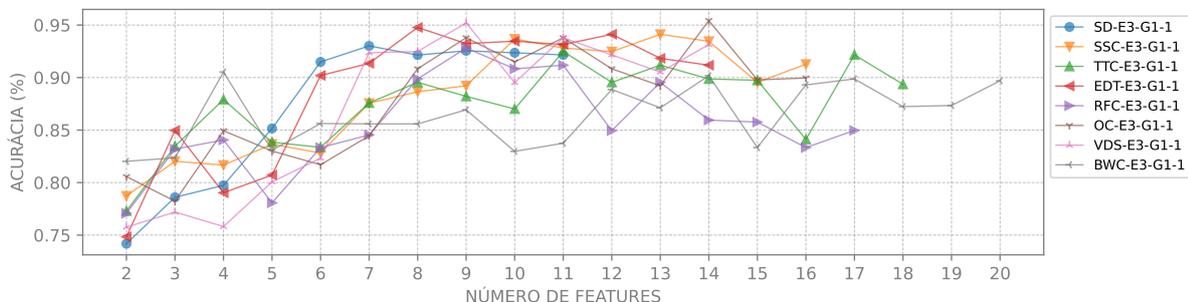
Após a análise de todos os conjuntos de vetores em função da variação do número de *features*, nas Figuras 67, 69 e 71 seguem os resultados dos treinamentos com validação cruzada para os modelos que apresentaram os melhores desempenhos nos testes subsequentes, abrangendo todas as configurações avaliadas. Adicionalmente, as Figuras 68, 70 e 72 ilustram os resultados dos testes dos melhores modelos em todos os cenários avaliados.

Figura 67 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E3-G1-1. O número de *features* corresponde à sequência de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 68 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E3-G1-1. O número de *features* é dado pela ordem de extração das IMFs.

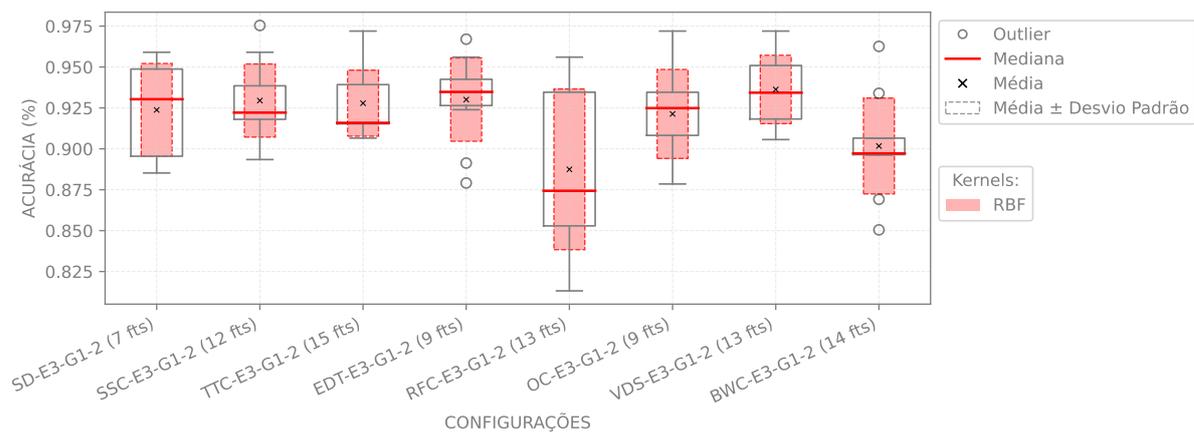


Fonte: Produzido pelo autor.

Para os ensaios E3-G1-1, apesar de todas as configurações apresentarem alguns resultados acima de 90% e um comportamento oscilatório a medida que mais *features* são consideradas, apenas as configurações vinculadas aos critérios de parada SD, EDT, OC

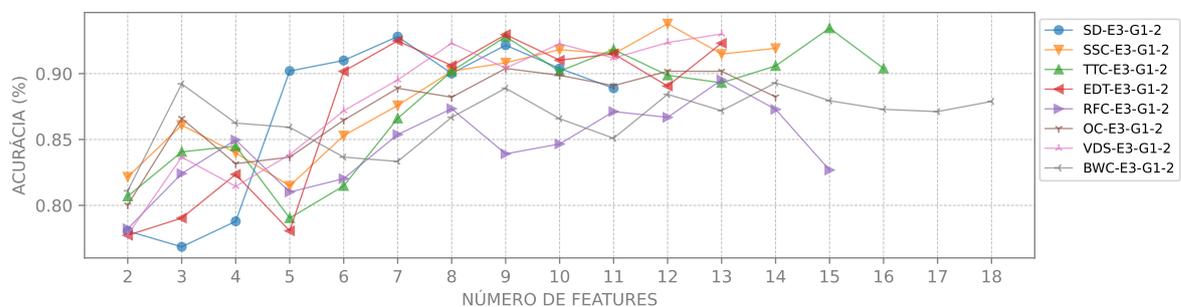
e VDS mantêm-se, de modo geral, acima de 90% ao considerar-se 8 ou mais *features* (Figura 68). Quanto ao menor número de *features*, nota-se que a configuração BWC-E3-G1-1, ao considerar apenas 2, obteve 82.4% de acurácia. Em termos de melhores desempenhos gerais, as seguintes configurações destacaram-se: SD-E3-G1-1 (7 fts), SSC-E3-G1-1 (13 fts), TTC-E3-G1-1 (11 fts), EDT-E3-G1-1 (8 fts), RFC-E3-G1-1 (9 fts), OC-E3-G1-1 (14 fts), VDS-E3-G1-1 (9 fts) e BWC-E3-G1-1 (4 fts). Notavelmente, a última, mesmo considerando apenas as quatro primeiras IMFs, alcançou uma acurácia superior a 90%. Ao contrário dos ensaios anteriores, neste, os melhores resultados com acurácias superiores a 95% foram obtidos em somente 3 das 8 (37.5%) configurações, especificamente: EDT-E3-G1-1 (8 fts), VDS-E3-G1-1 (9 fts) e OC-E3-G1-1 (14 fts).

Figura 69 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E3-G1-2. O número de *features* corresponde à sequência de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 70 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E3-G1-2. O número de *features* é dado pela ordem de extração das IMFs.

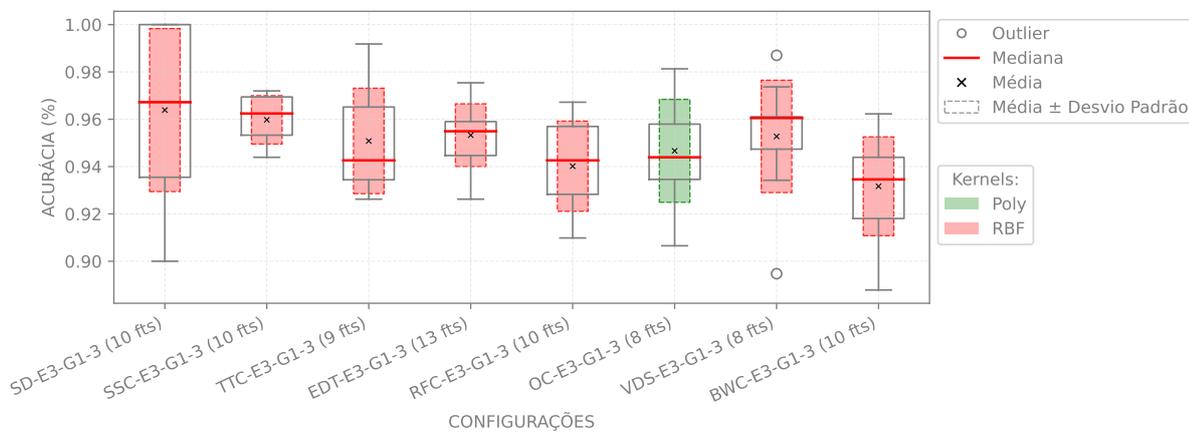


Fonte: Produzido pelo autor.

Nos ensaios E3-G1-2, as mínimas quantidades de *features* que proporcionaram acurácias superiores a 90% foram 5 para o critério de parada SD, 8 para SSC, TCC e VDS, 6 para EDT e 9 para OC. Já os resultados dos critérios RFC e BWC não atingiram

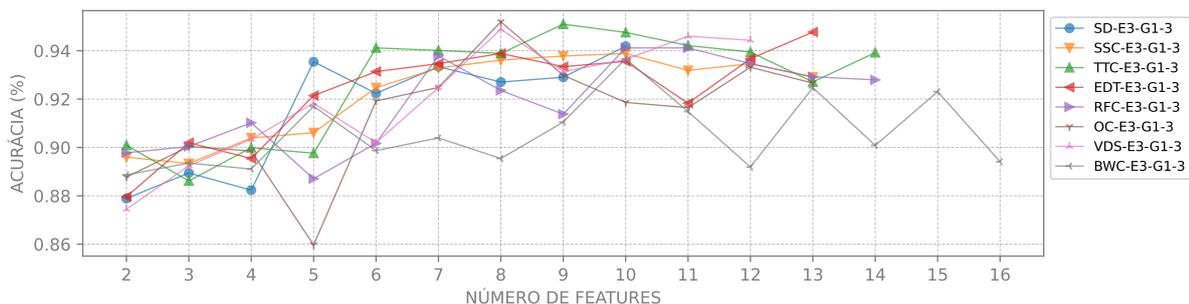
90%, alcançando, no máximo, 89.8% e 89.75%, respectivamente (Figura 59). Com relação ao menor número de *features*, a configuração BWC-E3-G1-2 obteve 82.4% de acurácia ao considerar somente 2. Em termos de melhores desempenhos globais, as configurações SD-E3-G1-2 (7 fts), SSC-E3-G1-2 (12 fts), TTC-E3-G1-2 (15 fts), EDT-E3-G1-2 (9 fts), RFC-E3-G1-2 (13 fts), OC-E3-G1-2 (9 fts), VDS-E3-G1-2 (13 fts) e BWC-E3-G1-2 (14 fts) se sobressaíram. Ressalta-se que, neste ensaio, nenhuma das configurações atingiu acurácias superiores a 95%.

Figura 71 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E3-G1-3. O número de *features* corresponde à sequência de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 72 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E3-G1-3. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Finalmente, nos testes E3-G1-3, excetuando-se algumas situações para o critério de parada BWC, todas as configurações alcançaram acurácias superiores a 90% quando foram considerados conjuntos de vetores de 6 ou mais *features* (Figura 61). Ao considerar somente duas *features*, este ensaio foi o que demonstrou os melhores resultados até o momento, com índices variando entre 87.2% a 90.05%. O critério TTC obteve destaque nesse cenário. Quanto aos melhores desempenhos gerais, as configurações que mais se sobressaíram foram:

SD-E3-G1-3 (10 fts), SSC-E3-G1-3 (10 fts), TTC-E3-G1-3 (9 fts), EDT-E3-G1-3 (13 fts), RFC-E3-G1-3 (10 fts), OC-E3-G1-3 (8 fts), VDS-E3-G1-3 (8 fts) e BWC-E3-G1-3 (10 fts). Em comparação com os ensaios E3-G1-1 e E3-G1-2, que registraram acurácias mínimas de 76% e 74.2%, respectivamente, o experimento E3-G1-3 apresentou desempenho superior, com acurácia mínima de 86% (critério de parada OC com 5 fts).

No que se refere aos *kernels*, o RBF mostrou-se predominante entre os melhores hiperparâmetros para as configurações avaliadas neste ensaio, representando 95.83% das ocorrências. Por outro lado, o *kernel* polinomial prevaleceu em apenas uma instância, correspondendo a 4.17% das ocorrências de destaque.

Outro fato notável é que, com algumas exceções, os resultados dos testes se enquadram dentro da faixa média \pm desvio padrão. Este padrão, também observado nos experimentos E1 e E2 deste grupo, sugere que os intervalos estabelecidos representam de forma adequada as variações de desempenho dos modelos, evidenciando que, de modo geral, os modelos mantêm uma performance consistente mesmo com sinais com taxas de amostragem reduzidas.

Os hiperparâmetros determinados para os modelos de melhor desempenho, bem como as métricas acurácia, precisão, *recall*, *F1-score* e AUC, estão detalhados na Tabela 24. Os modelos de melhor desempenho alcançaram um AUC mínimo de 0.92, atingindo 0.99 no caso TTC-E3-G1-3 com vetores de 9 *features*. As configurações que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada estão destacadas na Tabela 24. Priorizou-se novamente o *F1-score* máximo, conforme descrito na subseção referente ao ensaio E1-G1.

Tabela 24 – Melhores resultados em E3-G1. As configurações destacadas são as que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada. O termo “Poly” refere-se ao *kernel* Polinomial.

Configuração	Num. features	Amostras treino (%)	C	γ	Kernel	Acurácia	Precisão	Recall	F1-score	AUC
SD-E3-G1-1	7	70	1000	10	RBF	0.93013	0.92511	0.93333	0.92920	0.97
SSC-E3-G1-1	13	80	1000	1	RBF	0.94118	0.93548	0.94771	0.94156	0.96
TTC-E3-G1-1	11	80	100	10	RBF	0.92484	0.94000	0.90968	0.92459	0.96
EDT-E3-G1-1	8	80	1000	10	RBF	0.94771	0.94904	0.94904	0.94904	0.98
RFC-E3-G1-1	9	80	1000	10	RBF	0.92810	0.91875	0.94231	0.93038	0.97
OC-E3-G1-1	14	80	100	10	RBF	0.95425	0.97516	0.94012	0.95732	0.97
VDS-E3-G1-1	9	70	1000	10	RBF	0.95197	0.96444	0.93939	0.95175	0.98
BWC-E3-G1-1	4	80	1000	1000	RBF	0.90523	0.89412	0.93252	0.91291	0.92
SD-E3-G1-2	7	80	100	10	RBF	0.92810	0.92683	0.93827	0.93252	0.95
SSC-E3-G1-2	12	80	100	1	RBF	0.93791	0.93168	0.94937	0.94044	0.98
TTC-E3-G1-2	15	70	1000	1	RBF	0.93450	0.96018	0.91176	0.93534	0.95
EDT-E3-G1-2	9	60	1000	10	RBF	0.92962	0.91786	0.92780	0.92280	0.96
RFC-E3-G1-2	13	60	1000	1	RBF	0.89525	0.90459	0.87372	0.88889	0.92
OC-E3-G1-2	9	70	1000	1	RBF	0.90393	0.88571	0.93133	0.90795	0.93
VDS-E3-G1-2	13	70	100	1	RBF	0.93013	0.91416	0.94667	0.93013	0.97
BWC-E3-G1-2	14	70	1000	1	RBF	0.89301	0.91810	0.87654	0.89684	0.93
SD-E3-G1-3	10	20	1000	0.1	RBF	0.94185	0.91837	0.96854	0.94279	0.98
SSC-E3-G1-3	10	70	1000	0.1	RBF	0.93886	0.94118	0.93274	0.93694	0.97
TTC-E3-G1-3	9	80	100	0.1	RBF	0.95098	0.96454	0.93151	0.94774	0.99
EDT-E3-G1-3	13	80	100	1	RBF	0.94771	0.95833	0.93243	0.94521	0.98
RFC-E3-G1-3	10	80	100	1	RBF	0.94118	0.95105	0.92517	0.93793	0.97
OC-E3-G1-3	8	70	0.01	10	Poly	0.95197	0.98058	0.91818	0.94836	0.98
VDS-E3-G1-3	8	50	100	1	RBF	0.94889	0.96477	0.93194	0.94807	0.98
BWC-E3-G1-3	10	70	100	1	RBF	0.93668	0.93450	0.93860	0.93654	0.96

Fonte: Elaborada pelo autor.

Com base nas análises e considerando os resultados detalhados nas Tabelas 23 e 24, conclui-se que é possível reduzir o custo computacional do processo ao se utilizar sinais com taxas de amostragem reduzidas, sem comprometer a performance do sistema. Adicionalmente notou-se uma melhoria, ainda que discreta, na ortogonalidade em média entre as IMFs. Em algumas das configurações avaliadas, observou-se também uma diminuição no número de *features* necessárias. Isso sugere que, na prática, a interrupção do SP da EMD pode ocorrer assim que o número desejado de IMFs for alcançado, resultando em uma redução adicional no custo computacional.

Finalmente, a obtenção de acurácias e *F1-scores* superiores a 95% em determinados cenários indica que algumas configurações alcançaram desempenhos comparáveis aos observados em ensaios anteriores. Tais resultados sugerem que determinados modelos se mostraram eficazes na classificação das observações, equilibrando adequadamente a detecção de cigarras com a minimização de FPs.

Conclui-se que o sistema proposto é viável mesmo quando empregados sinais com taxas de amostragem reduzidas. A robustez e precisão demonstradas nos testes realizados validam a hipótese previamente apresentada nesta subseção.

Nas duas últimas subseções relacionadas aos experimentos do grupo G1, especificamente E4 e E5, são propostas novas abordagens com o intuito de otimizar o desempenho do sistema e reduzir o custo computacional. Em E4, as configurações da EMD são relaxadas, visando a redução das iterações do SP, o que contribui para a melhoria na qualidade das decomposições (IOs) e conseqüente economia de recursos computacionais. Já em E5, o foco é avaliar os desempenhos dos modelos ao empregar diferentes técnicas de normalização dos vetores.

4.2.1.4 Experimento E4

No ensaio anterior, comprovou-se a hipótese de que o sistema proposto, ao utilizar sinais com taxas de amostragem reduzidas, é capaz de alcançar resultados satisfatórios. Ao analisar os resultados dos experimentos já conduzidos, observa-se que vários dos critérios de parada utilizados são relativamente rigorosos, dada a quantidade de iterações necessárias para a extração de cada IMF. Nesta subseção, busca-se otimizar ainda mais a economia de recursos computacionais associados ao processamento dos sinais.

Para tal, é crucial compreender a relação dos parâmetros da EMD com as iterações e IMFs resultantes. No contexto atual da EMD, as IMFs extraídas pelo algoritmo são apenas aproximações, já que o método é totalmente empírico e sua fundamentação matemática ainda não está consolidada (SOUZA; ESCOLA; BRITO, 2022). Em teoria, um elevado número de iterações do SP geraria uma IMF em conformidade com a definição, contudo, esta função pode não ter significado físico relevante (WANG et al., 2010). É consenso na

literatura disponível que um número excessivo de iterações é desaconselhado (HUANG et al., 2003; WU; HUANG; CHEN, 2009; WANG et al., 2010), uma vez que pode comprometer o processo de decomposição ao uniformizar as amplitudes das IMFs (RILLING; FLANDRIN; GONÇALVES, 2003), levar à perda da ortogonalidade entre as IMFs (STEVENSON; MESBAH; BOASHASH, 2005) (propriedade fundamental que indica a qualidade da decomposição) e produzir mais IMFs do que o previsto. Sobre esta última questão, a variação dos parâmetros da EMD pode gerar uma infinidade de conjuntos distintos de IMFs (HUANG; WU, 2008). Portanto, a determinação do número ideal de iterações no SP é extremamente importante, conforme enfatizado por Zhao et al. (2016).

Nesta subsecção, a hipótese é que a flexibilização dos parâmetros dos critérios de parada possa resultar em desempenhos similares ou até superiores aos obtidos nos experimentos anteriores, mas com a vantagem da redução do custo computacional. Nesse cenário, o experimento E4 foi realizado com a adoção de outras duas combinações de parâmetros para cada critério de parada, com exceção dos critérios SSC e BWC. O critério BWC, conforme implementado nesta pesquisa, não possui parâmetros, portando não foi considerado neste ensaio. Por outro lado, o critério SSC só pode assumir mais uma configuração mais flexível, sendo $S = 2$. Vale ressaltar que, nos ensaios anteriores, empregou-se $S = 3$, onde S indica o número de proto-IMFs consecutivas que devem apresentar o mesmo número de zeros e extremos para interrupção do SP. As configurações adotadas neste ensaio estão detalhadas na Tabela 25. Os sinais utilizados são variantes dos originais, obtidos em E3-G1-3, com taxa de amostragem de 6 kHz, 16 bits de quantização e duração de 1 segundo. Para o processamento pela EMD, o número máximo de iterações por IMF foi estipulado em 700. Os vetores de *features* foram normalizados com a técnica MN.

Tabela 25 – Configurações para o experimento E4 do grupo G1.

Rótulos	Amostragem (kHz)	Tempo (s)	Configurações da EMD		Norma	It. Max.
			Critério de parada	Parâmetros		
SD-E4-G1-1	6	1	SD	$\varepsilon = 0.2$	MN	700
SSC-E4-G1-1			SSC	$S = 2$		
TTC-E4-G1-1			TTC	$\alpha = 0.05, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E4-G1-1			EDT	$\varepsilon = 0.01$		
RFC-E4-G1-1			RFC	$R = 40$		
OC-E4-G1-1			OC	$\varepsilon = 0.1$		
VDS-E4-G1-1			VDS	95% de $m(t) < 0.01$		
SD-E4-G1-2	6	1	SD	$\varepsilon = 0.3$	MN	700
TTC-E4-G1-2			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E4-G1-2			EDT	$\varepsilon = 0.1$		
RFC-E4-G1-2			RFC	$R = 30$		
OC-E4-G1-2			OC	$\varepsilon = 0.2$		
VDS-E4-G1-2			VDS	95% de $m(t) < 0.05$		

Fonte: Elaborada pelo autor.

E4-G1: Resultados do Módulo MEF

Conforme esperado, constata-se que as decomposições dos sinais, empregando parâmetros mais flexíveis, resultam em um número reduzido de iterações no SP, como pode ser observado na [Tabela 26](#), a qual apresenta a média de iterações para as decomposições de E4-G1-2, com exceção a SSC-E4-G1-1 que não possui correspondente no segundo conjunto de configurações deste ensaio. Tal observação pode ser atribuída à natureza menos rigorosa dos parâmetros adotados, pois parâmetros mais flexíveis tendem a permitir uma convergência acelerada, gerando resíduos ou IMFs que, sob critérios mais estritos, poderiam demandar mais iterações. No entanto, é fundamental ponderar a relação entre precisão da decomposição e eficiência computacional. Esta relação pode ser avaliada através dos IOs, os quais serão abordados nesta subseção. Junto ao número reduzido de iterações, observa-se que menos IMFs também são extraídas na maioria dos casos, conforme [Tabela 27](#).

Tabela 26 – Número máximo de IMFs e média de iterações do SP, por classe, em cada configuração dos testes de E4-G1-2. C indica a classe “cigarra” e R a classe “ruído”.

Componentes	SD-E4-G1-2		SSC-E4-G1-1		TTC-E4-G1-2		EDT-E4-G1-2		RFC-E4-G1-2		OC-E4-G1-2		VDS-E4-G1-2	
	C	R	C	R	C	R	C	R	C	R	C	R	C	R
IMF 1	2	3	23	34	23	34	6	5	4	5	10	16	5	6
IMF 2	2	3	18	30	24	34	8	6	6	7	10	13	4	8
IMF 3	2	3	16	27	22	34	8	7	8	9	9	12	3	8
IMF 4	2	2	12	18	20	30	8	8	8	10	9	10	3	5
IMF 5	2	2	10	9	18	17	8	10	7	9	9	8	2	3
IMF 6	2	2	6	8	14	19	9	10	7	8	8	8	2	2
IMF 7	2	2	6	5	15	16	9	11	7	9	7	6	2	2
IMF 8	2	2	6	4	17	19	9	12	7	7	6	6	2	2
IMF 9	2	2	6	5	25	22	10	11	7	6	6	5	2	1
IMF 10	-	-	7	5	20	17	10	9	5	4	5	4	-	-
IMF 11	-	-	2	2	16	44	10	-	4	-	6	-	-	-
IMF 12	-	-	-	-	43	-	-	-	-	-	-	-	-	-
IMF 13	-	-	-	-	2	-	-	-	-	-	-	-	-	-

Fonte: Elaborada pelo autor.

Tabela 27 – Quantidade máxima (M) de IMFs por configuração em E4-G1, incluindo o resíduo.

Configuração	E4-G1-1	E4-G1-2
SD	10	10
SSC	12	-
TTC	14	14
EDT	12	12
RFC	13	12
OC	12	12
VDS	11	10
BWC	-	-

Fonte: Elaborada pelo autor.

Associado à redução no número de iterações e custo computacional, observa-se uma melhoria nos IOs, em média, entre as IMFs extraídas. Tal progresso pode ser observado

nas Tabelas 23 e 28. Essa melhoria na ortogonalidade contribui para a precisão e a clareza dos resultados derivados da EMD, reforçando a hipótese de que é possível obter resultados iguais ou melhores que os obtidos nos ensaios anteriores.

Tabela 28 – Detalhes sobre a distribuição dos IOs e o Tempo Médio de Decomposição (TMD), expresso em segundos, para todas as configurações. O termo “Lim. sup.” refere-se a $Q3 + 1.5 \cdot IIQ$, sendo $Q3$ o terceiro quartil e IIQ o intervalo interquartil.

Configuração	min(E)	min(IO)	Lim. sup. (IO)	Média (IO)	Outliers > 1	TMD (s)
SD-E4-G1-1		$9.79 \cdot 10^{-4}$	0.27293	$1.07 \cdot 10^{-1}$	14	0.11
SSC-E4-G1-1		$1.41 \cdot 10^{-3}$	0.42678	$4.09 \cdot 10^{-1}$	88	1.13
TTC-E4-G1-1		$1.11 \cdot 10^{-3}$	0.60413	$5.34 \cdot 10^{-1}$	140	2.06
EDT-E4-G1-1	$1 + 1.94 \cdot 10^{-4}$	$1.49 \cdot 10^{-3}$	0.41567	$2.83 \cdot 10^{-1}$	68	0.65
RFC-E4-G1-1		$1.28 \cdot 10^{-3}$	0.83153	2.23	218	1.30
OC-E4-G1-1		$1.71 \cdot 10^{-3}$	0.61137	$3.55 \cdot 10^{-1}$	91	0.89
VDS-E4-G1-1		$1.38 \cdot 10^{-3}$	0.49254	$3.92 \cdot 10^{-1}$	90	0.49
SD-E4-G1-2		$9.79 \cdot 10^{-4}$	0.27099	$9.60 \cdot 10^{-2}$	6	0.09
TTC-E4-G1-2		$1.10 \cdot 10^{-3}$	0.54522	$4.74 \cdot 10^{-1}$	116	1.46
EDT-E4-G1-2		$1.46 \cdot 10^{-3}$	0.39636	$2.64 \cdot 10^{-1}$	66	0.46
RFC-E4-G1-2	$1 + 1.94 \cdot 10^{-4}$	$1.26 \cdot 10^{-3}$	0.44103	$3.95 \cdot 10^{-1}$	73	0.39
OC-E4-G1-2		$1.47 \cdot 10^{-3}$	0.44749	$2.25 \cdot 10^{-1}$	57	0.50
VDS-E4-G1-2		$1.20 \cdot 10^{-3}$	0.29833	$1.82 \cdot 10^{-1}$	33	0.16

Fonte: Elaborada pelo autor.

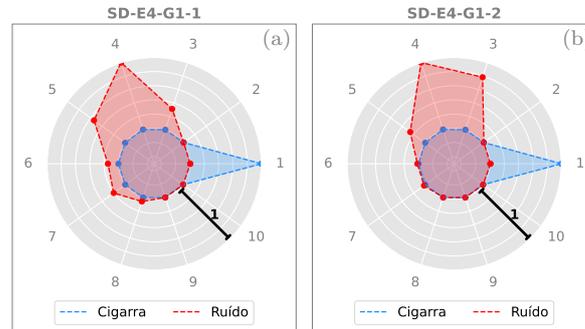
Assim como nos ensaios anteriores, observa-se um número expressivo de *outliers* com valores superiores a 1. Entretanto, este número é notavelmente inferior ao observado no ensaio E3-G1, indicando um avanço em relação à qualidade das decomposições. Em relação a esses *outliers*, e de maneira consistente com os experimentos precedentes, verifica-se que as energias mínimas em todas as configurações ultrapassam o valor de 1. Portanto, deduz-se que a EMD não se mostrou plenamente eficaz na decomposição de determinados sinais em componentes ortogonais, ainda que em uma escala reduzida. Dessa forma, as IMFs decorrentes dessas decomposições são categorizadas como de qualidade inferior. Em relação a esse aspecto, e coerente com os ensaios anteriores, é notório que as configurações que adotam o critério de parada SD registra um menor contingente de *outliers* e apresenta, em média, IOs mais favoráveis. Observa-se uma melhoria similar nas configurações que empregam o critério VDS.

E4-G1: Resultados do Módulo MNF

Seguindo, aplica-se o módulo MNF para normalização dos vetores de *features* obtidos. A técnica adotada neste ensaio novamente foi a MN, conforme descrito na Tabela 25. Na Figura 73, são apresentados os gráficos de radar correspondentes aos sinais decompostos com parâmetros mais flexíveis, derivados dos vetores introduzidos na subseção anterior e ilustrados na Figura 62c.

Os gráficos reiteram, assim como nas subseções anteriores, que apesar das energias se distribuírem em IMFs diferentes em comparação a SD-E3-G1-3, as distinções significativas entre os vetores das classes “cigarra” e “ruído” permanecem. Os vetores associados à classe

Figura 73 – Exemplos de vetores de *features* formados pelas configurações SD-E4-G1- $\{1,2\}$. Estes vetores correspondem aos representados na Figura 62c, porém, correspondem aos sinais decompostos com parâmetros mais flexíveis.

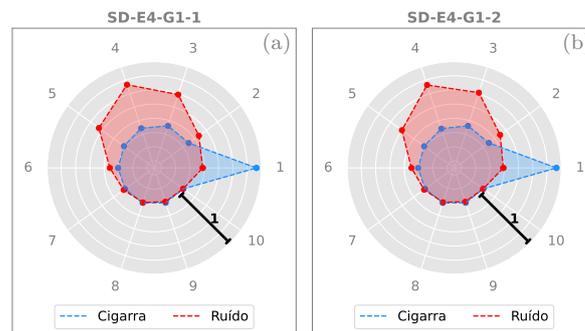


Fonte: Produzido pelo autor.

“cigarra” continuam a exibir perfis de energia distintos, com picos nas IMFs de número 1 e decrescimentos acentuados nas IMFs subsequentes. Em contraste, os vetores pertencentes à classe “ruído” mostram distribuições de energia mais acentuadas nas IMFs 3 a 5, com picos particularmente notáveis nas IMFs de número 4. Adicionalmente, em SD-E4-G1-2 observa-se também um pico na terceira IMF.

Em uma análise geral, nota-se que as classes são, em média, distinguíveis, conforme demonstrado no exemplo da Figura 73. Evidentemente, há variações nas representações das distribuições de energias das diferentes configurações, principalmente devido à quantidade de IMFs. No entanto, em média, as características discutidas nos experimentos anteriores permanecem para todas as configurações. A Figura 74 ilustra as médias dos vetores normalizados para as duas configurações associadas ao critério de parada SD.

Figura 74 – Gráficos de radar das *features*, em média, para as classes “cigarra” e “ruído” das configurações SD-E4-G1- $\{1,2\}$.



Fonte: Produzido pelo autor.

Assim como nos experimentos anteriores, esta uniformidade identificada em todas as configurações exploradas, realça a relevância e eficiência dessas características para a classificação dos sinais, reforçando a hipótese proposta nesta subseção. Assim como nos ensaios anteriores, os gráficos pertinentes às representações das distribuições médias das energias no formato radar, correspondentes às demais configurações deste ensaio foram

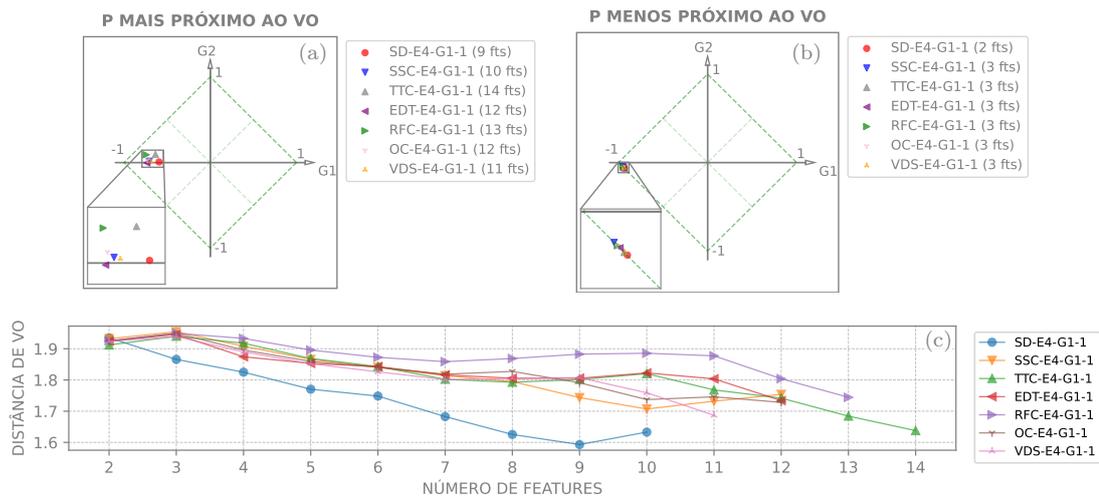
omitidos visando evitar redundâncias e assegurar clareza e objetividade na exposição dos resultados.

E4-G1: Resultados do Módulo MPFE

Dando continuidade à avaliação dos vetores, novamente todos os conjuntos de vetores gerados pela variação do número de *features* foram submetidos ao módulo MPFE. Especificamente, consideraram-se as k primeiras *features*, com k variando entre 2 e M , para todas as configurações.

As Figuras 75 e 76 destacam tanto os melhores quanto os piores resultados para as configurações examinadas, bem como todas as distâncias ao VO referentes aos pontos P associados aos conjuntos de vetores em análise.

Figura 75 – Resumo dos resultados do módulo MPFE para E4-G1-1. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exhibe as distâncias em relação ao VO.



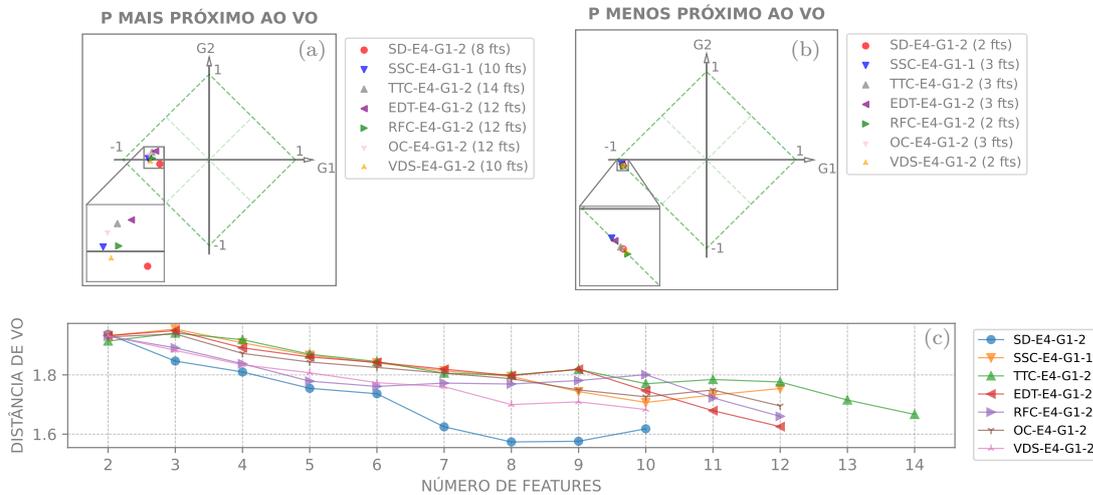
Fonte: Produzido pelo autor.

Observa-se que as variações dos parâmetros da EMD consideradas, apesar de diminuírem as distâncias em alguns casos, novamente não exercem influência significativa sobre os resultados das análises PFE. Os melhores resultados situaram-se entre 1.6 e 1.75.

Os resultados mais promissores, oriundos das decomposições decorrentes de E4-G1-2, apresentaram valores próximos a 1.6, o que significa uma redução de aproximadamente um décimo em relação aos melhores resultados de E3-G1-3. Em particular, novamente, as configurações associadas aos critérios de parada SD e EDT, ao considerarem 8 e 12 *features*, respectivamente, destacam-se.

Assim como nos ensaios anteriores, nota-se que os pontos nos PPs, embora mais próximos de VO e mais distribuídos, ainda se situam predominantemente próximos ao

Figura 76 – Resumo dos resultados do módulo MPFE para E4-G1-2. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

vértice $(-1, 0)$, referente à falsidade. Esta constatação sugere que, nas condições avaliadas, os vetores intraclasse mostram-se mais dispersos, ao passo que os vetores interclasse exibem uma considerável sobreposição. Esta característica reforça, novamente, a escolha por um classificador forte, como o SVM.

Conforme a análise PFE indica, a variação dos parâmetros, embora diminua as distâncias dos pontos ao VO, não produz um impacto significativo nos resultados quando comparada aos ensaios anteriores. Essa constatação, aliada à comprovação da viabilidade do sistema proposto nos experimentos anteriores para resolução do problema de classificação em questão, corrobora positivamente a hipótese levantada nesta subseção. Na subseção seguinte, são apresentados os testes relacionados ao módulo MTT.

E4-G1: Resultados do módulo MTT

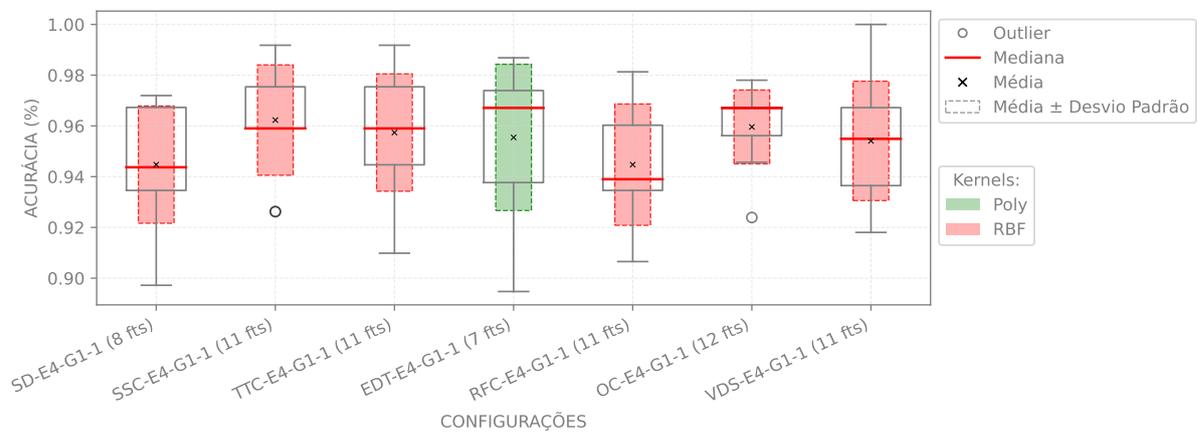
Prosseguindo com a avaliação de desempenho dos modelos SVM, o módulo MTT processa todos os conjuntos de vetores formados ao se variar a quantidade de *features*, em sequência crescente, de forma análoga ao descrito na subseção anterior. Os parâmetros designados para o treinamento do classificador estão elencados na Tabela 6. Assim como nos experimentos anteriores, o limiar de treinamento foi definido por múltiplos de 10 no intervalo de 20 a 80.

Dados os máximos de *features* M alcançados, conforme a Tabela 27, e considerando a validação cruzada com $k = 10$ partições e o fato de que o *kernel* linear não utiliza o parâmetro γ , foram realizadas $7\,700 \cdot (M - 1)$ treinamentos distintos para cada configuração especificada na Tabela 25, totalizando 1 085 700 treinamentos. Ao final deste processo, os

modelos que exibiram maiores médias de acurácias no processo de validação cruzada foram eleitos para os testes definitivos, utilizando o conjunto de dados especificamente reservado para essa finalidade.

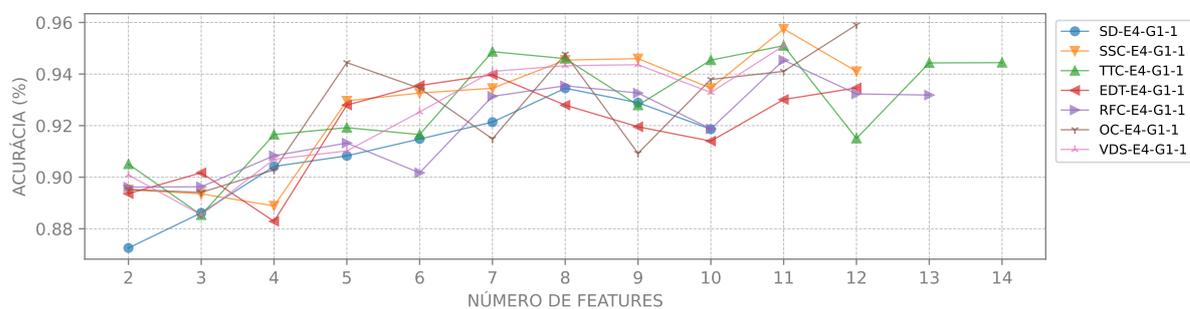
Após a análise de todos os conjuntos de vetores em função da variação do número de *features*, nas Figuras 77 e 79 seguem os resultados dos treinamentos utilizando validação cruzada para os modelos que apresentaram os melhores desempenhos nos testes subsequentes, abrangendo todas as configurações avaliadas. Adicionalmente, as Figuras 78 e 80 ilustram os resultados dos testes dos melhores modelos em todos os cenários avaliados.

Figura 77 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E4-G1-1. O número de *features* corresponde à ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 78 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E4-G1-1. O número de *features* é dado pela ordem de extração das IMFs.

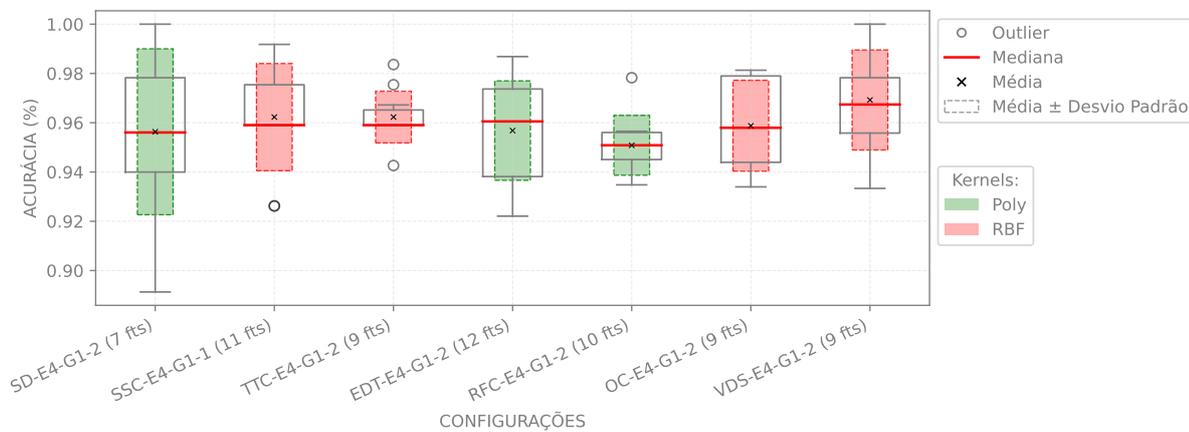


Fonte: Produzido pelo autor.

Para os ensaios E4-G1-1, assim como nos anteriores, nota-se um comportamento oscilatório à medida que mais *features* são consideradas. Com exceção das configurações SSC-E4-G1-1 (4 fts) e EDT-E4-G1-1 (4 fts), todas as demais apresentaram resultados acima de 90% ao considerar 4 ou mais *features*, como evidenciado na Figura 78. Em relação

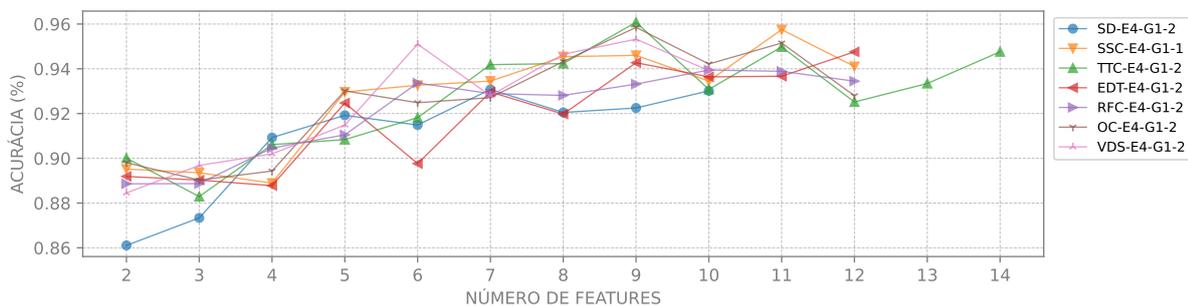
ao menor número de *features* consideradas, as configurações TTC-E4-G1-1 e VDS-E4-G1-1 se destacaram, alcançando acurácias de 90.5% e 90.1%, respectivamente, com apenas 2 *features*. No que se refere aos melhores desempenhos globais, as configurações que se sobressaíram foram: SD-E4-G1-1 (8 fts), SSC-E4-G1-1 (11 fts), TTC-E4-G1-1 (11 fts), EDT-E4-G1-1 (7 fts), RFC-E4-G1-1 (11 fts), OC-E4-G1-1 (12 fts) e VDS-E4-G1-1 (11 fts). Comparado ao ensaio E3-G1-3, houve um avanço notável: enquanto o melhor desempenho anterior foi abaixo ou aproximadamente 95%, no ensaio E4-G1-1, atingiu-se cerca de 96% em casos como TTC-E4-G1-1 (9 fts), OC-E4-G1-1 (9 fts) e SSC-E4-G1-1 (11 fts).

Figura 79 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E4-G1-2. O número de *features* corresponde à ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 80 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E4-G1-2. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Nos ensaios E4-G1-2, as mínimas quantidades de *features* que proporcionaram acurácias superiores ou iguais a 90% foram 2 para o critério de parada TTC; 4 para SD, RFC e VDS; 5 para OC e EDT, conforme ilustra a Figura 80. Com relação ao menor número de *features*, a configuração TTC-E4-G1-2, obteve 90% de acurácia ao considerar somente 2, como mencionado. Em termos de melhores desempenhos globais, as configurações

SD-E4-G1-2 (7 fts), TTC-E4-G1-2 (9 fts), EDT-E4-G1-2 (12 fts), RFC-E4-G1-2 (10 fts), OC-E4-G1-2 (9 fts) e VDS-E4-G1-2 (9 fts) se sobressaíram. Ressalta-se que, neste ensaio, assim como em E4-G1-1, foram alcançadas acurácias correspondentes ou próximas a 96% pelas configurações TTC-E4-G1-2 (9 fts), OC-E4-G1-2 (9 fts) e SSC-E4-G1-2 (11 fts).

No que se refere aos *kernels*, o RBF mostrou-se predominante entre os melhores hiperparâmetros para as configurações avaliadas neste ensaio, com uma ocorrência de 69.23%, seguido pelo *kernel* polinomial, com 30.77%.

Outro fato notável é que os resultados dos testes se enquadram dentro da faixa média \pm desvio padrão. Este padrão, também observado nos experimentos anteriores, sugere que os intervalos estabelecidos representam de forma adequada as variações de desempenho dos modelos, evidenciando que os modelos mantêm uma performance consistente mesmo aplicada a EMD com parâmetros mais flexíveis.

Os hiperparâmetros determinados para os modelos de melhor desempenho, bem como as métricas acurácia, precisão, *recall*, *F1-score* e AUC, estão detalhados na Tabela 29. Os modelos de melhor desempenho alcançaram um AUC mínimo de 0.96, atingindo 0.99 no caso VDS-E4-G1-1 com vetores de 11 *features*. As configurações que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada estão destacadas na Tabela 29. Priorizou-se novamente o *F1-score* máximo, conforme descrito na subseção referente ao ensaio E1-G1.

Tabela 29 – Melhores resultados em E4-G1. As configurações destacadas são as que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada. O termo “Poly” refere-se ao *kernel* Polinomial.

Configuração	Num. features	Amostras treino (%)	C	γ	Kernel	Acurácia	Precisão	Recall	F1-score	AUC
SD-E4-G1-1	8	70	100.0	1	RBF	0.93450	0.97788	0.89837	0.93644	0.98
SSC-E4-G1-1	11	80	1000	0.1	RBF	0.95752	0.97315	0.94156	0.95710	0.98
TTC-E4-G1-1	11	80	1000.0	0.1	RBF	0.95098	0.94521	0.95172	0.94845	0.99
EDT-E4-G1-1	7	50	0.01	10.0	Poly	0.93971	0.95531	0.91935	0.93699	0.98
RFC-E4-G1-1	11	70	1000.0	0.1	RBF	0.94541	0.95434	0.93304	0.94357	0.98
OC-E4-G1-1	12	60	100.0	1	RBF	0.95908	0.96886	0.94595	0.95726	0.98
VDS-E4-G1-1	11	80	1000.0	0.1	RBF	0.95098	0.95833	0.93878	0.94845	0.99
SD-E4-G1-2	7	30	1000	1	Poly	0.93078	0.89825	0.96970	0.93260	0.96
TTC-E4-G1-2	9	80	1000	0.1	RBF	0.96078	0.96689	0.95425	0.96053	0.98
EDT-E4-G1-2	12	50	100	1	Poly	0.94758	0.94344	0.95325	0.94832	0.97
RFC-E4-G1-2	10	60	0.01	10	Poly	0.93944	0.93610	0.94516	0.94061	0.97
OC-E4-G1-2	9	70	100	1	RBF	0.95852	0.97403	0.94538	0.95949	0.98
VDS-E4-G1-2	9	30	1000	0.1	RBF	0.95323	0.94737	0.95817	0.95274	0.97

Fonte: Elaborada pelo autor.

Com base nas análises e tendo em vista os resultados apresentados nas Tabelas 28 e 29, conclui-se que a adoção de parâmetros mais flexíveis para a EMD possibilita uma redução no custo computacional do processo sem comprometer a performance do sistema. De fato, em certos casos, foi possível observar uma melhora no desempenho. Além disso, notou-se uma acentuada melhoria na ortogonalidade entre as IMFs, atribuída em grande parte à notável redução no número de *outliers*. Isso sugere que as componentes extraídas são de maior qualidade, o que, por sua vez, levou a melhores resultados tanto em relação à PFE quanto ao desempenho dos modelos classificadores SVM.

Finalmente, a obtenção de acurácias e *F1-scores* que se aproximaram ou superaram os 96% em alguns cenários indica que certas configurações exibiram desempenhos equiparáveis aos de ensaios anteriores. Isso sugere que alguns modelos se mostraram eficazes na classificação das observações, conseguindo um bom equilíbrio entre a detecção precisa de cigarras e a minimização de FPs.

Conclui-se que o sistema proposto é viável mesmo quando empregados parâmetros mais flexíveis para a EMD. A robustez e precisão demonstradas nos testes realizados validam a hipótese previamente apresentada nesta subseção.

Na próxima subseção, que é a última deste grupo de experimentos, serão concentrados esforços para aperfeiçoar o sistema. O objetivo é melhorar o desempenho dos classificadores ao variar as técnicas de normalização dos vetores no módulo MNF.

4.2.1.5 Experimento E5

Nos experimentos apresentados anteriormente neste grupo, evidenciou-se a robustez e precisão do sistema proposto, validando as hipóteses de que é possível reduzir a duração e taxa de amostragem dos sinais e empregar parâmetros mais flexíveis para a EMD sem comprometer o desempenho do sistema proposto. No entanto, a combinação de todos estes esforços não resultou em acurácias superiores a 96.07% no ensaio E4-G1. Assim, nesta subseção, o objetivo é melhorar o desempenho do sistema.

A hipótese agora em foco sugere que diferentes técnicas de normalização para os vetores de *features* possam acentuar a eficácia dos modelos classificadores. Neste contexto, o experimento E5 foi realizado com sinais derivados dos sinais originais, os quais foram capturados a uma taxa de amostragem de 44.1 kHz e 16 bits de quantização. Foram consideradas duração e taxa de amostragem de 1 segundo e 6 kHz, respectivamente, para cada sinal. No tratamento via EMD, aplicaram-se os 8 critérios de parada e estipulou-se um máximo de 700 iterações por IMF. Os vetores de *features* passaram por um processo de normalização utilizando as técnicas MMN e LS, descritas na [seção 2.5](#). Para a técnica MMN, realizou-se o reescalonamento das *features* para o intervalo $[0, 1]$, definindo $a = 0$ e $b = 1$. Por outro lado, para a técnica LS, exploraram-se cinco variações do coeficiente v , sendo $v \in \{0.01, 0.1, 1, 10, 100\}$. Os parâmetros específicos, associados a cada critério de parada, seguem os mais flexíveis adotados no ensaio E4-G1. A única exceção é para o critério BWC, cuja configuração é derivada de E3-G1-3. As configurações detalhadas deste experimento estão disponíveis na [Tabela 30](#).

Tabela 30 – Configurações para o experimento E5 do grupo G1.

Rótulos	Amostragem (kHz)	Tempo (s)	Configurações da EMD		Norma	It. Max.
			Critério de parada	Parâmetros		
SD-E5-G1-1	6	1	SD	$\varepsilon = 0.3$	MMN	700
SSC-E5-G1-1			SSC	$S = 2$		
TTC-E5-G1-1			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E5-G1-1			EDT	$\varepsilon = 0.1$		
RFC-E5-G1-1			RFC	$R = 30$		
OC-E5-G1-1			OC	$\varepsilon = 0.2$		
VDS-E5-G1-1			VDS	95% de $m(t) < 0.05$		
BWC-E5-G1-1			BWC	mínimo de B_f^2 encontrado		
SD-E5-G1-2	6	1	SD	$\varepsilon = 0.3$	LS(0.01)	700
SSC-E5-G1-2			SSC	$S = 2$		
TTC-E5-G1-2			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E5-G1-2			EDT	$\varepsilon = 0.1$		
RFC-E5-G1-2			RFC	$R = 30$		
OC-E5-G1-2			OC	$\varepsilon = 0.2$		
VDS-E5-G1-2			VDS	95% de $m(t) < 0.05$		
BWC-E5-G1-2			BWC	mínimo de B_f^2 encontrado		
SD-E5-G1-3	6	1	SD	$\varepsilon = 0.3$	LS(0.1)	700
SSC-E5-G1-3			SSC	$S = 2$		
TTC-E5-G1-3			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E5-G1-3			EDT	$\varepsilon = 0.1$		
RFC-E5-G1-3			RFC	$R = 30$		
OC-E5-G1-3			OC	$\varepsilon = 0.2$		
VDS-E5-G1-3			VDS	95% de $m(t) < 0.05$		
BWC-E5-G1-3			BWC	mínimo de B_f^2 encontrado		
SD-E5-G1-4	6	1	SD	$\varepsilon = 0.3$	LS(1)	700
SSC-E5-G1-4			SSC	$S = 2$		
TTC-E5-G1-4			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E5-G1-4			EDT	$\varepsilon = 0.1$		
RFC-E5-G1-4			RFC	$R = 30$		
OC-E5-G1-4			OC	$\varepsilon = 0.2$		
VDS-E5-G1-4			VDS	95% de $m(t) < 0.05$		
BWC-E5-G1-4			BWC	mínimo de B_f^2 encontrado		
SD-E5-G1-5	6	1	SD	$\varepsilon = 0.3$	LS(10)	700
SSC-E5-G1-5			SSC	$S = 2$		
TTC-E5-G1-5			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E5-G1-5			EDT	$\varepsilon = 0.1$		
RFC-E5-G1-5			RFC	$R = 30$		
OC-E5-G1-5			OC	$\varepsilon = 0.2$		
VDS-E5-G1-5			VDS	95% de $m(t) < 0.05$		
BWC-E5-G1-5			BWC	mínimo de B_f^2 encontrado		
SD-E5-G1-6	6	1	SD	$\varepsilon = 0.3$	LS(100)	700
SSC-E5-G1-6			SSC	$S = 2$		
TTC-E5-G1-6			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E5-G1-6			EDT	$\varepsilon = 0.1$		
RFC-E5-G1-6			RFC	$R = 30$		
OC-E5-G1-6			OC	$\varepsilon = 0.2$		
VDS-E5-G1-6			VDS	95% de $m(t) < 0.05$		
BWC-E5-G1-6			BWC	mínimo de B_f^2 encontrado		

Fonte: Elaborada pelo autor.

E5-G1: Resultados do Módulo MEF

Para o experimento E5-G1, os resultados obtidos no módulo MEF são idênticos aos de E4-G1-1 para o critério SSC, E3-G1-3 para BWC e E4-G1-2 para os demais critérios. Isso ocorre porque a normalização das *features*, que é o diferencial deste experimento, é realizada no módulo MNF e não tem influência direta nas decomposições. A [Tabela 31](#) apresenta os números máximos de IMFs alcançados por cada configuração.

Tabela 31 – Quantidade máxima de IMFs por configuração em E5-G1, incluindo o resíduo.

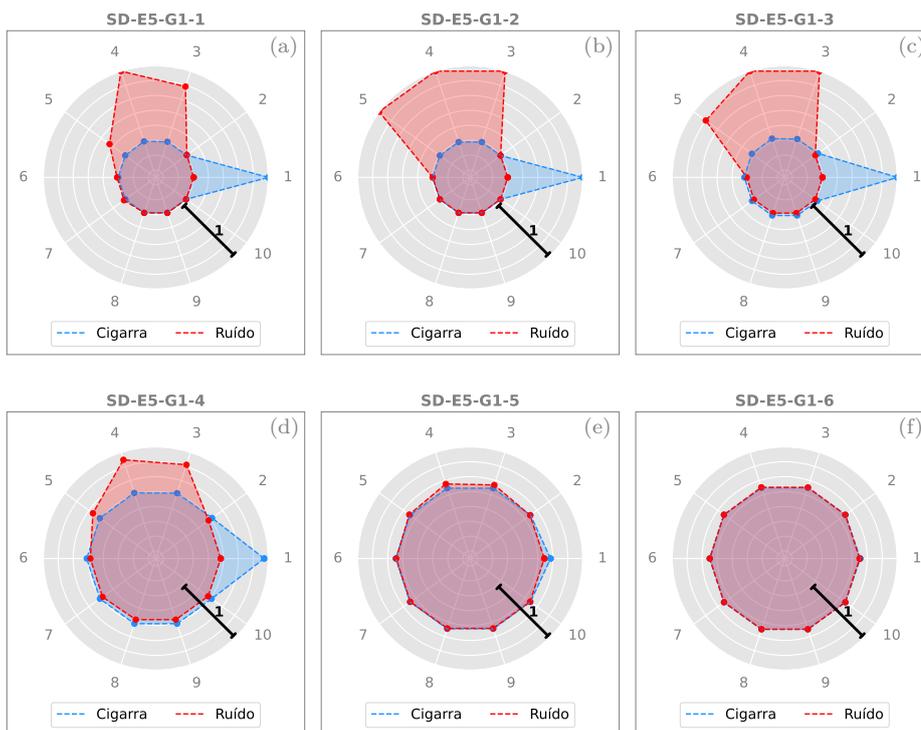
	SD-E5-G1	SSC-E5-G1	TTC-E5-G1	EDT-E5-G1	RFC-E5-G1	OC-E5-G1	VDS-E5-G1	BWC-E5-G1
M	10	12	14	12	12	12	10	16

Fonte: Elaborada pelo autor.

E5-G1: Resultados do Módulo MNF

Seguindo, aplica-se o módulo MNF para normalização dos vetores de *features* obtidos. As técnicas adotadas neste ensaio foram MMN e LS, conforme descrito na Tabela 30. Na Figura 81, são apresentados os gráficos de radar correspondentes aos vetores derivados dos introduzidos na subseção anterior e ilustrados na Figura 73b, aqui normalizados de forma distinta.

Figura 81 – Exemplos de vetores de *features* formados pelas configurações SD-E5-G1-1 à SD-E5-G1-6. Estes vetores correspondem aos representados na Figura 73b, porém, correspondem aos vetores normalizados por diferentes técnicas.



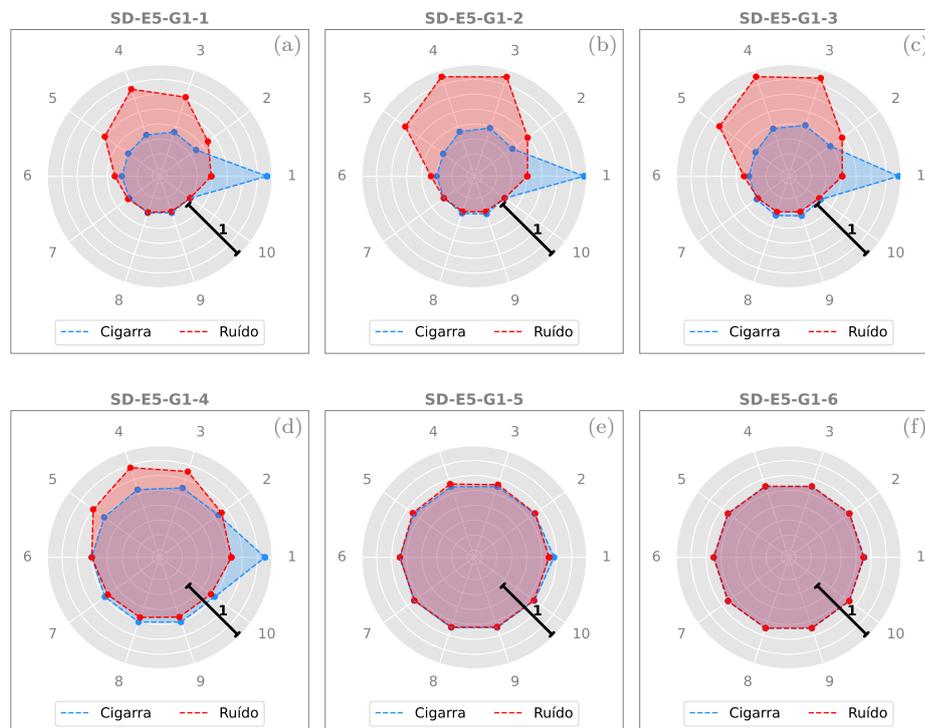
Fonte: Produzido pelo autor.

Observa-se que, para os sinais selecionados como exemplos, os vetores resultantes para SD-E5-G1-1 e SD-E4-G1-2 são idênticos. Isso sugere que as técnicas de normalização MN e MMN produzem os mesmos vetores nesse contexto. A técnica MN reescala cada *feature* para o intervalo $[-1, 1]$ pela divisão do vetor pelo valor absoluto máximo de suas *features*. No entanto, visto que as *features* foram definidas por energias das IMFs (que são positivas), quando normalizadas, elas pertencem ao intervalo $[0, 1]$. Se um vetor não atinge o número máximo M de *features*, ele é preenchido com zeros por definição. Nesse

caso específico, os resultados obtidos usando MN e MMN são equivalentes. Por outro lado, quando um vetor alcança o número máximo de *features*, e não há necessidade de preenchimento com zeros, o vetor normalizado pela técnica MN, a menos que uma de suas IMFs tenha energia nula, não apresentará *features* nulas. Nesse cenário, esta característica é contrastante com sua contraparte normalizada por MMN, que ajustará a *feature* com o valor mínimo para zero, resultando em pelo menos uma *feature* nula no vetor.

Os outros exemplos, ilustrados nas Figuras 81b à 81f, derivam da normalização pela técnica LS, que é uma transformação não-linear. Estes apresentam as diferenças mais acentuadas quando comparados a SD-E4-G1-2. Fica evidente que, nos casos E5-G1-2 e E5-G1-3, as energias mais elevadas tendem a se aproximar do valor 1. Por outro lado, E5-G1-4, E5-G1-5 e E5-G1-6 tendem a comprimir as energias em direção à energia média. Esta compressão torna-se gradativamente mais intensa de E5-G1-4 para E5-G1-6. Essa disposição também pode ser observada em média, conforme ilustrado na Figura 82, que representa as médias dos vetores normalizados para as configurações associadas ao critério de parada SD.

Figura 82 – Gráficos de radar das *features*, em média, para as classes “cigarra” e “ruído” das configurações SD-E5-G1-1 à SD-E5-G1-6.



Fonte: Produzido pelo autor.

Os gráficos, consistentes com as subseções anteriores, reforçam as diferenças notáveis entre os vetores das classes “cigarra” e “ruído”. Contudo, uma exceção é notada em E5-G1-6, onde as distinções entre os vetores tornam-se visualmente imperceptíveis, visto que se aproximam significativamente da média. Nesse caso, o desempenho do SVM pode

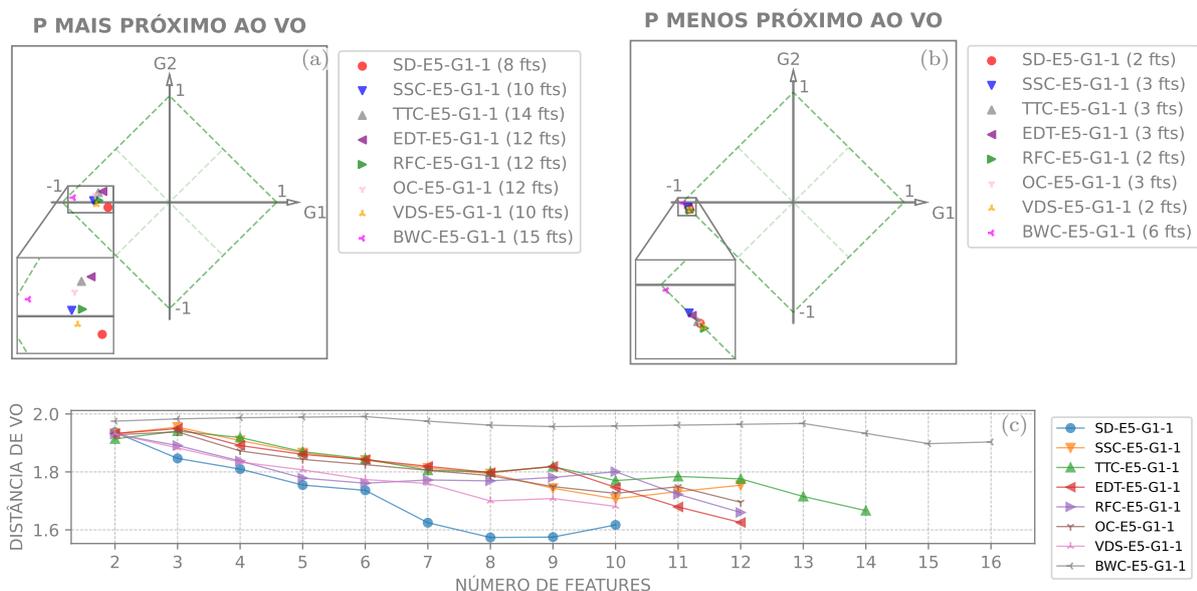
ser comprometido. O modelo pode ter dificuldades em definir um hiperplano de decisão ótimo, levando a uma acurácia reduzida e aumentando o risco de *overfitting*. Apesar dessas considerações, não se pode descartar completamente a capacidade do modelo de apresentar um desempenho satisfatório, que depende da natureza específica dos dados e da implementação do algoritmo SVM.

Esse padrão de distribuição das *features* reescaladas e transformadas, foi identificado em todas as configurações exploradas e realça a relevância e eficiência dessas características para a classificação dos sinais através de diferentes técnicas de normalização, reforçando a hipótese proposta nesta subseção. Os gráficos pertinentes às representações das distribuições médias das energias no formato radar, correspondentes às demais configurações deste ensaio, foram omitidos visando evitar redundâncias e assegurar clareza e objetividade na exposição dos resultados.

E5-G1: Resultados do Módulo MPFE

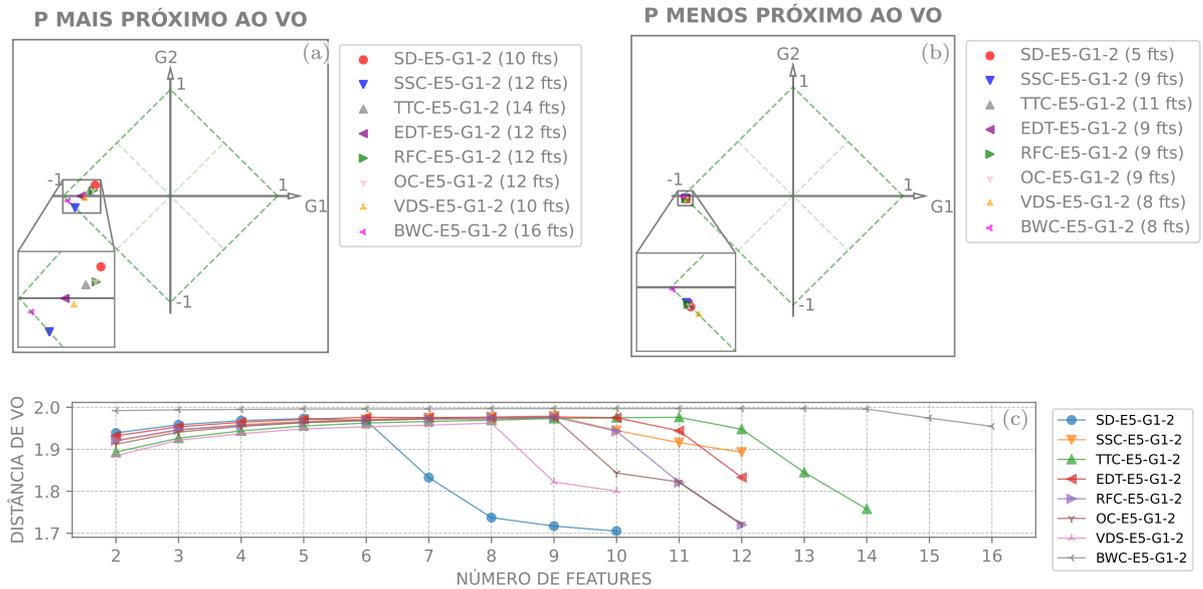
Dando continuidade à avaliação dos vetores, novamente todos os conjuntos gerados pela variação do número de *features* foram submetidos ao módulo MPFE. Especificamente, consideraram-se as k primeiras *features*, com k variando entre 2 e M , para todas as configurações. As Figuras 83 à 88 destacam tanto os melhores quanto os piores resultados para as configurações examinadas, bem como todas as distâncias ao VO referentes aos pontos P associados aos conjuntos de vetores em análise.

Figura 83 – Resumo dos resultados do módulo MPFE para E5-G1-1. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exhibe as distâncias em relação ao VO.



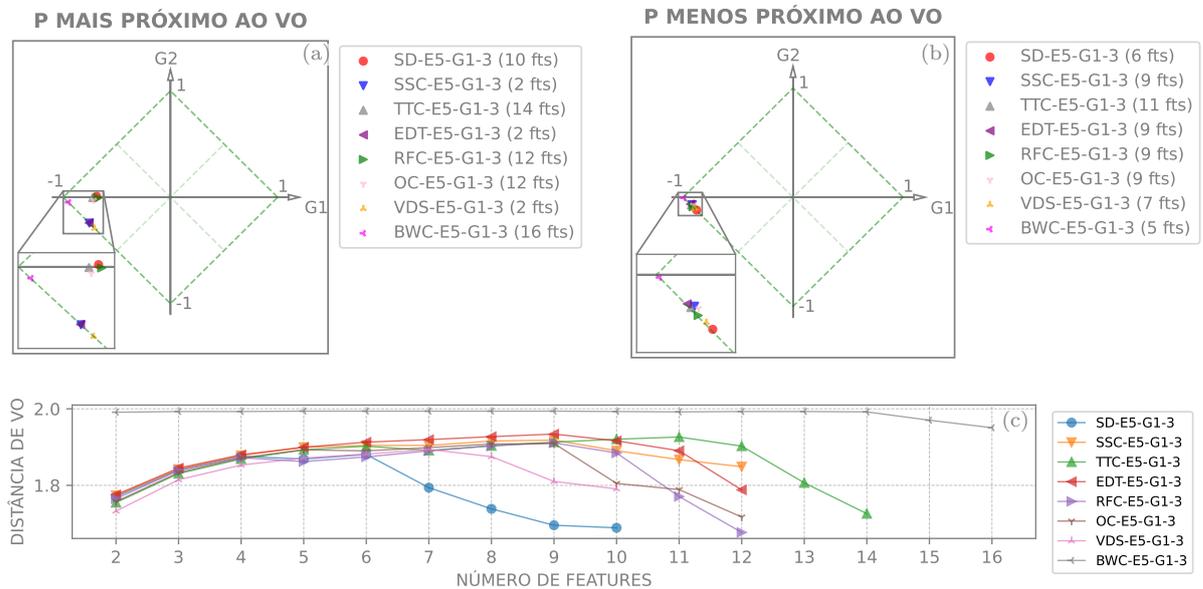
Fonte: Produzido pelo autor.

Figura 84 – Resumo dos resultados do módulo MPFE para E5-G1-2. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Figura 85 – Resumo dos resultados do módulo MPFE para E5-G1-3. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



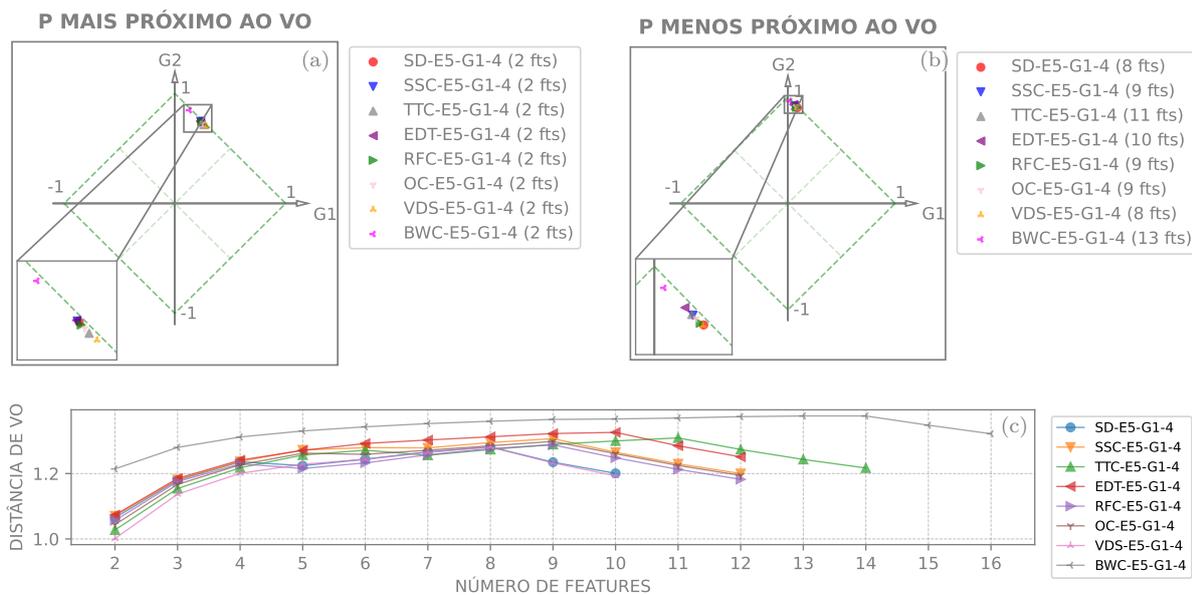
Fonte: Produzido pelo autor.

Observa-se que as configurações E5-G1-1, E5-G1-2 e E5-G1-3 não exercem uma influência significativa sobre os resultados das análises PFE, conforme ilustrados nas Figuras 83 à 85. As distâncias resultantes encontram-se nas faixas semelhantes às observadas em

ensaios anteriores. Especificamente, os melhores resultados correspondem a E5-G1-1 e situaram-se em torno de 1.6, um valor comparável aos melhores resultados dos ensaios anteriores, como os correspondentes às configurações SD-E4-G1-2 e EDT-E4-G1-2. Com base na análise das diferenças entre as técnicas MN e MMN na normalização dos vetores, apresentadas nos resultados do módulo MNF, infere-se que a maioria dos vetores precisou ser complementada com zeros, dado que os resultados mostraram diferenças mínimas.

Assim como nos ensaios anteriores, nota-se que os pontos nos PPs, embora mais distribuídos, ainda se situam predominantemente próximos ao vértice $(-1, 0)$, referente à falsidade. Esta constatação sugere que, nas condições avaliadas, os vetores intraclasse continuam dispersos e os interclasse exibem uma considerável sobreposição. Esta característica reforça, novamente, a escolha por um classificador forte, como o SVM.

Figura 86 – Resumo dos resultados do módulo MPFE para E5-G1-4. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.

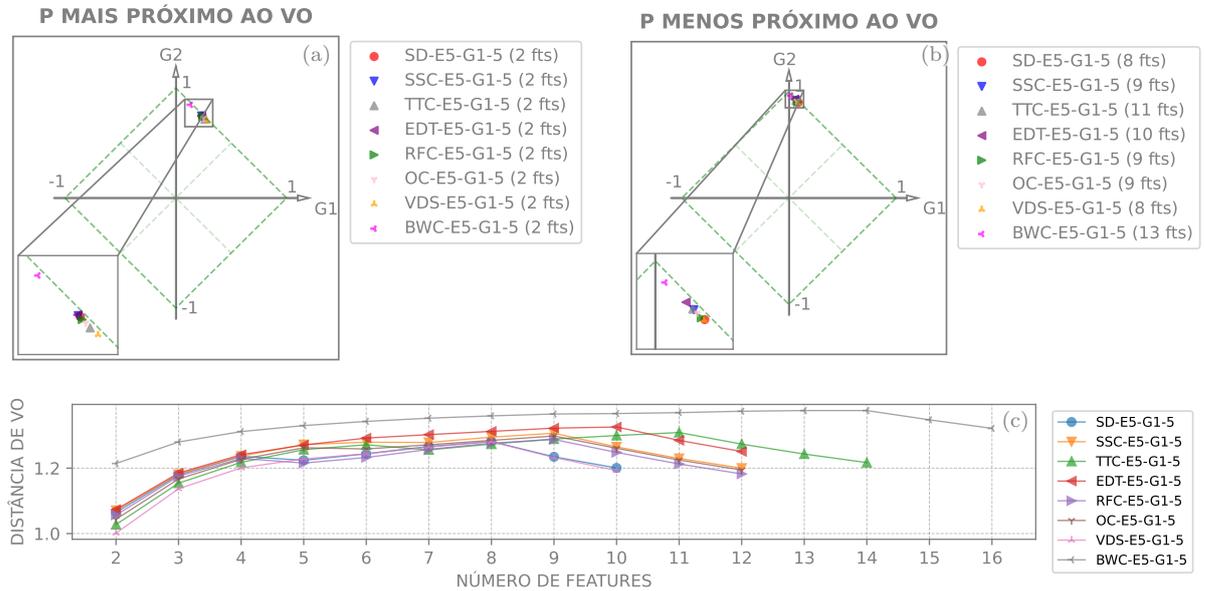


Fonte: Produzido pelo autor.

Em contrapartida, as configurações E5-G1-4, E5-G1-5 e E5-G1-6 sobressaíram-se devido à substancial influência que exerceram sobre as distâncias dos pontos P ao VO. Nas configurações anteriores, as distâncias eram ampliadas quando consideradas menos *features*. No entanto, para as configurações E5-G1-4, E5-G1-5 e E5-G1-6, observa-se um comportamento oposto: as distâncias menores associam-se ao uso de um menor número de *features*. Os desempenhos mais notáveis aproximam-se de 1 para as três configurações, atingindo exatamente esse valor para as configurações correspondentes ao critério de parada VDS nos três cenários.

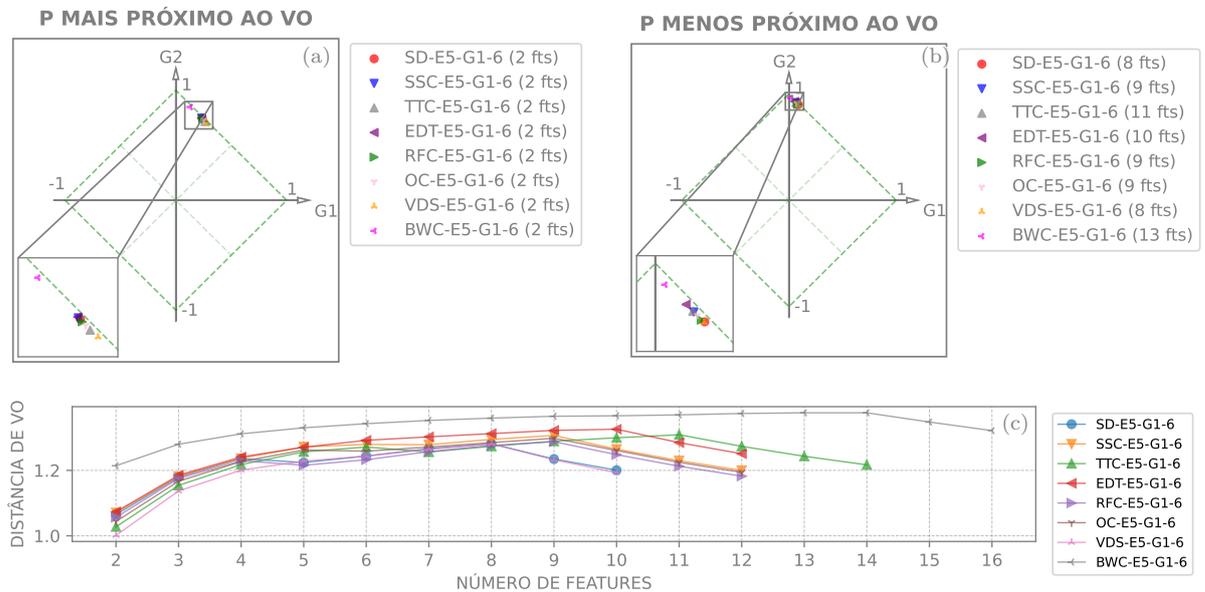
Em contraste com os ensaios anteriores, observa-se que os pontos nos PPs, ainda

Figura 87 – Resumo dos resultados do módulo MPFE para E5-G1-5. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Figura 88 – Resumo dos resultados do módulo MPFE para E5-G1-6. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

que estejam mais próximos de VO, agora se posicionam majoritariamente nas proximidades do vértice (0, 1), que é referente à ambiguidade. Tal constatação indica que, nas condições avaliadas, existe uma notável similaridade entre os vetores intraclasse e interclasse, como

pontuado na análise dos resultados do módulo MNF. Este aspecto reitera a pertinência de se optar por um classificador forte.

Conforme a análise PFE indica, as técnicas de normalização exercem um impacto significativo nos resultados em relação aos ensaios anteriores. Esta constatação corrobora positivamente com a hipótese levantada nesta subseção.

E5-G1: Resultados do módulo MTT

Prosseguindo com a avaliação de desempenho dos modelos SVM, o módulo MTT processa todos os conjuntos de vetores formados ao se variar a quantidade de *features*, em sequência crescente. Os parâmetros designados para o treinamento do classificador estão elencados na [Tabela 6](#). Assim como nos experimentos anteriores, o limiar de treinamento foi definido por múltiplos de 10 no intervalo de 20 a 80.

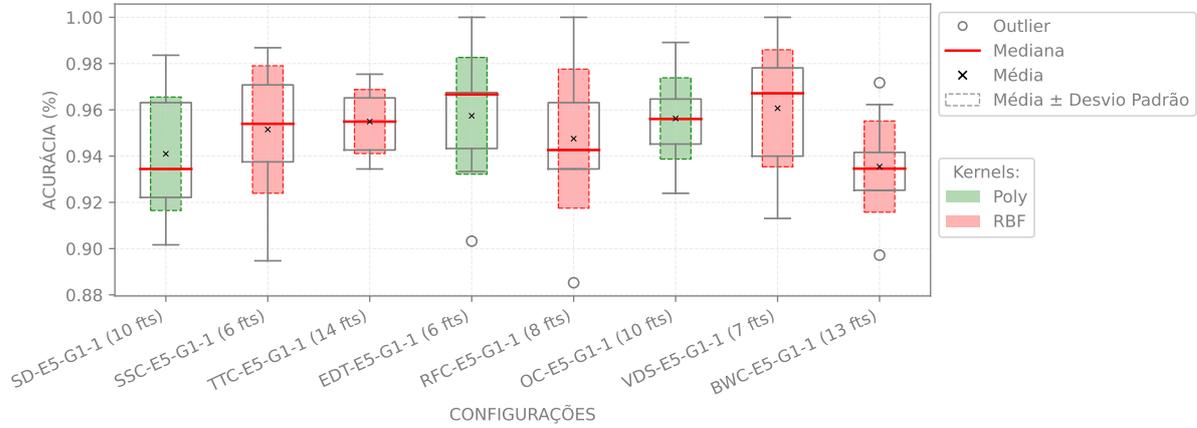
Dados os máximos de *features* M alcançados, conforme a [Tabela 31](#), considerando a validação cruzada com $k = 10$ partições e o fato de que o *kernel* linear não utiliza o parâmetro γ , foram realizadas $7\,700 \cdot (M - 1)$ treinamentos distintos para cada configuração especificada na [Tabela 30](#), totalizando 693 000 treinamentos. Ao final deste processo, os modelos que exibiram maiores médias de acurácias no processo de validação cruzada foram eleitos para os testes definitivos, utilizando o conjunto de dados especificamente reservado para essa finalidade.

Após o processamento de todos os conjuntos de vetores, considerando a variação do número de *features*, os resultados obtidos nos treinamentos com validação cruzada para os modelos que exibiram maior eficácia nos testes subsequentes, abrangendo todas as configurações, foram ilustrados nas Figuras [89](#) à [94](#).

Nos resultados correspondentes às configurações avaliadas neste experimento, observa-se que os treinamentos referentes aos modelos de melhor desempenho nos testes exibiram acurácias superiores a 90% e médias acima de 92%. Apenas as configurações SD-E5-G1-2 (5 fts), BWC-E5-G1-2 (12 fts) e OC-E5-G1-2 (12 fts) constituem exceções. Os dois primeiros modelos apresentaram acurácias mínimas de 87%, enquanto o último registrou um *outlier* de 86.7%. As faixas definidas pelas médias \pm desvios padrão também permaneceram acima de 90%, com exceção de SD-E5-G1-2 (5 fts) e BWC-E5-G1-2 (12 fts).

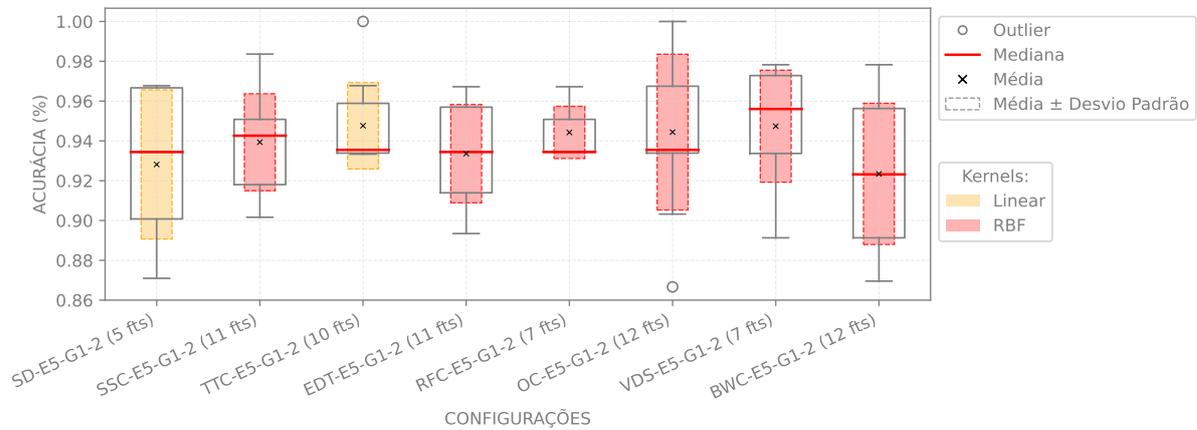
No que se refere aos *kernels*, o RBF mostrou-se predominante entre os melhores hiperparâmetros, com uma ocorrência de 81.25%, seguido pelo *kernel* polinomial, com 14.58%. Um aspecto notável neste experimento é que o *kernel* linear destacou-se em dois dos quarenta e oito melhores resultados (SD e TTC de E5-G1-2), correspondendo a 4.17% do total.

Figura 89 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-1. O número de *features* corresponde à ordem de extração das IMFs.



Fonte: Produzido pelo autor.

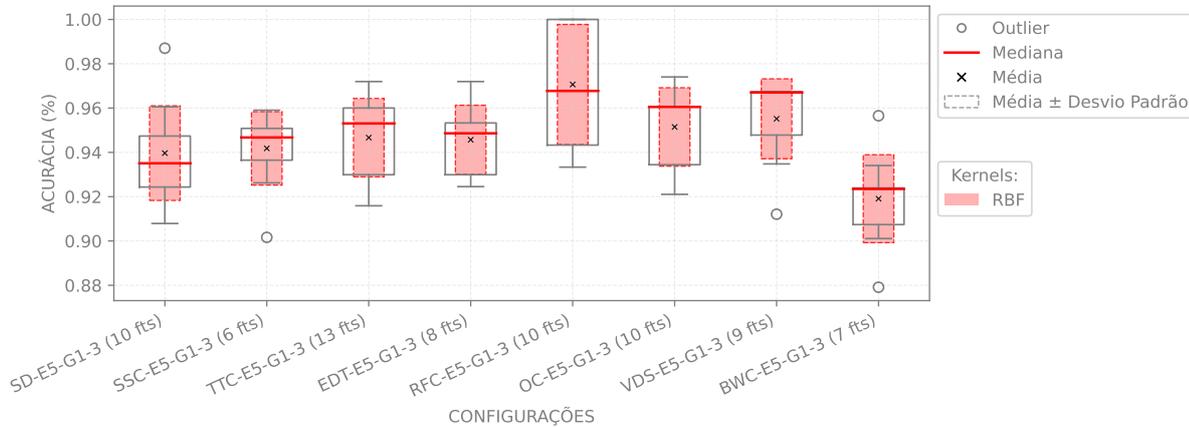
Figura 90 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-2. O número de *features* corresponde à ordem de extração das IMFs.



Fonte: Produzido pelo autor.

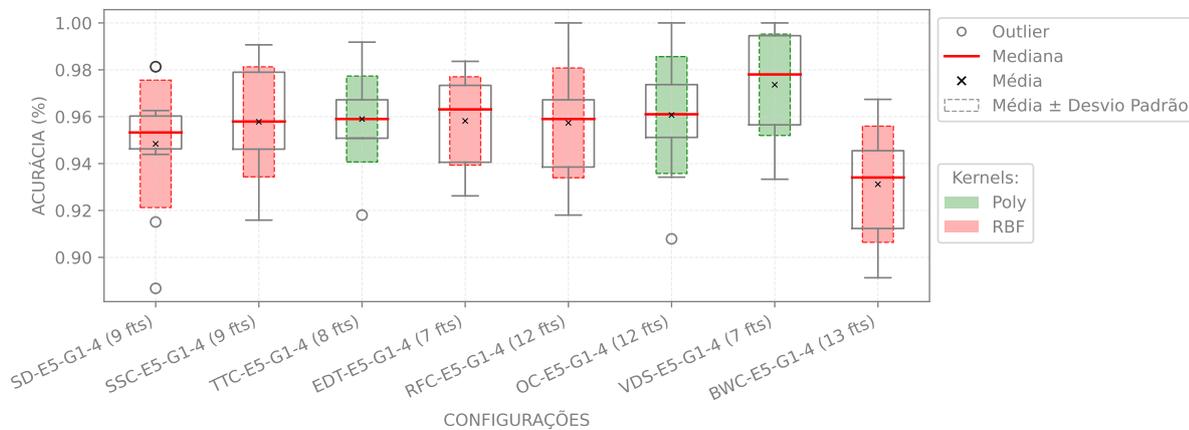
O surgimento do *kernel* linear como destaque nos resultados constitui um achado notável e incita uma análise mais aprofundada. Em geral, o *kernel* linear é empregado em cenários nos quais a relação entre os dados é percebida como relativamente simples ou quando a quantidade de *features* (dimensão) é substancialmente alta em comparação ao número de amostras (MURTY; RAGHAVA, 2016). Isto porque ele é fundamentalmente apto a determinar hiperplanos lineares no espaço de características. O fato de ele ter se mostrado eficaz em duas das quarenta e oito melhores configurações indica que, nessas configurações em particular, os dados podem possuir uma natureza linearmente separável ou que sua relação não exige uma transformação não linear sofisticada. Isso pode ser

Figura 91 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-3. O número de *features* corresponde à ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 92 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-4. O número de *features* corresponde à ordem de extração das IMFs.

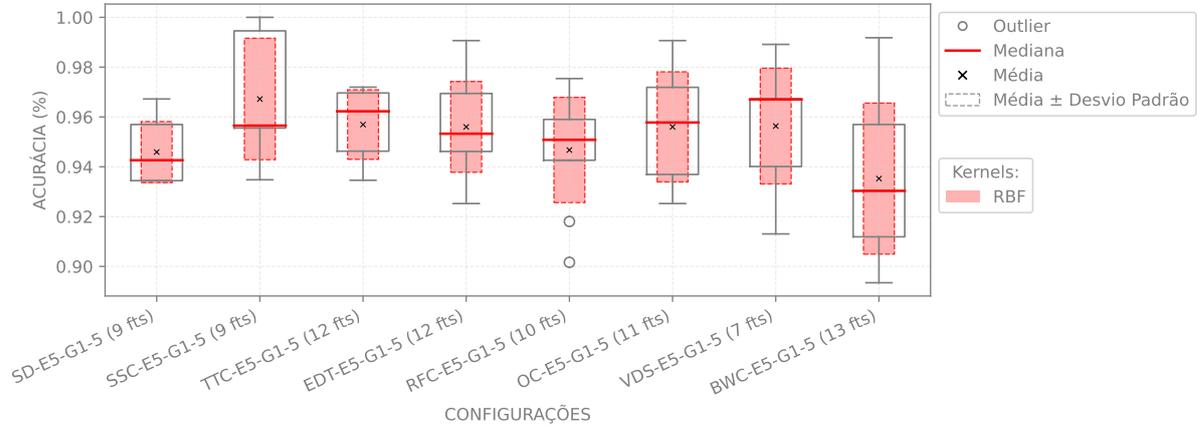


Fonte: Produzido pelo autor.

compreendido como uma evidência de que, em determinadas circunstâncias, a inter-relação entre as *features* e as classes pode ser particularmente simples. Vale ressaltar que a eficiência computacional do *kernel* linear costuma ser superior à de *kernels* não lineares, como o RBF ou polinomial. Assim, sua efetividade em situações específicas pode otimizar a implementação do modelo, agilizando a análise e reduzindo o custo computacional.

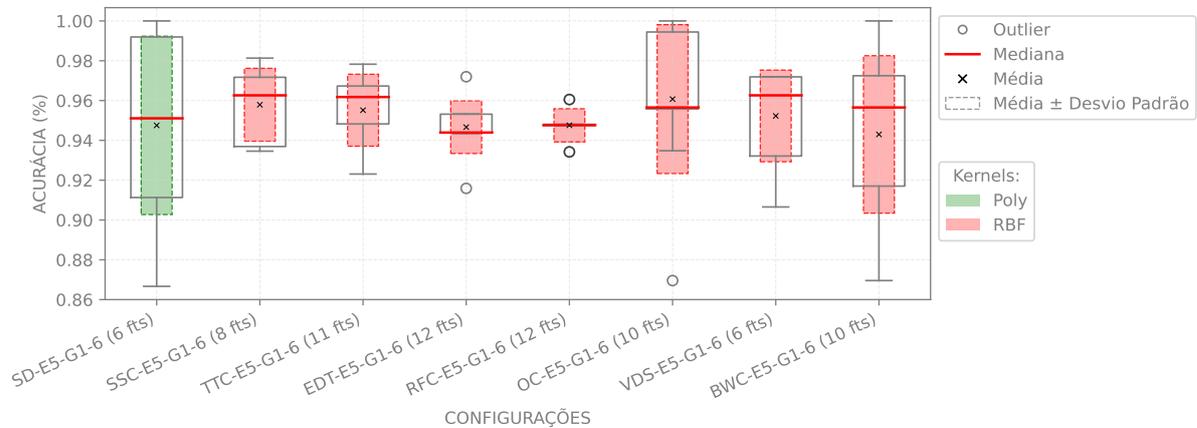
Quanto às distribuições das acurácias, os diagramas de caixa exibem comportamentos diversos. Algumas configurações apresentam simetria no intervalo interquartil em relação à mediana, com a média igual ou próxima à mediana. Em termos práticos, essa simetria indica que a variabilidade dos dados é consistente em ambos os lados da média e

Figura 93 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-5. O número de *features* corresponde à ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 94 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E5-G1-6. O número de *features* corresponde à ordem de extração das IMFs.



Fonte: Produzido pelo autor.

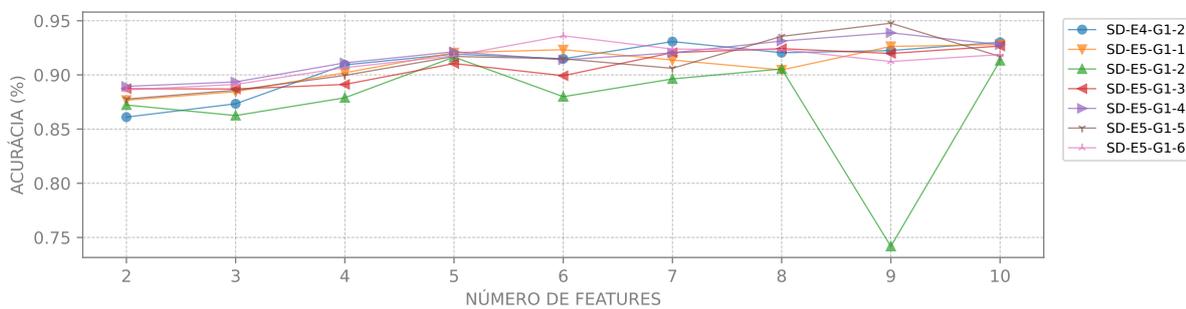
que a média é uma representação robusta do centro dos dados. Uma distribuição simétrica é muitas vezes considerada ideal em contextos científicos e estatísticos, como a distribuição normal por exemplo, pois indica que as condições que levam a valores acima e abaixo da média ocorrem em taxas aproximadamente iguais (DEKKING et al., 2006).

Por outro lado, algumas configurações exibem distribuições com intervalos maiores, enquanto outras em intervalos mais restritos. Intervalos maiores indicam que há uma variação maior nos resultados para essas configurações. Esta variabilidade pode ser devido a instabilidade decorrente da configuração ou outros fatores não controlados. Em contraste, intervalos mais estreitos sugerem que a configuração é mais estável e previsível. No contexto

desta pesquisa, uma variabilidade menor é preferível, pois sugere que o modelo é robusto e confiável nas condições dadas.

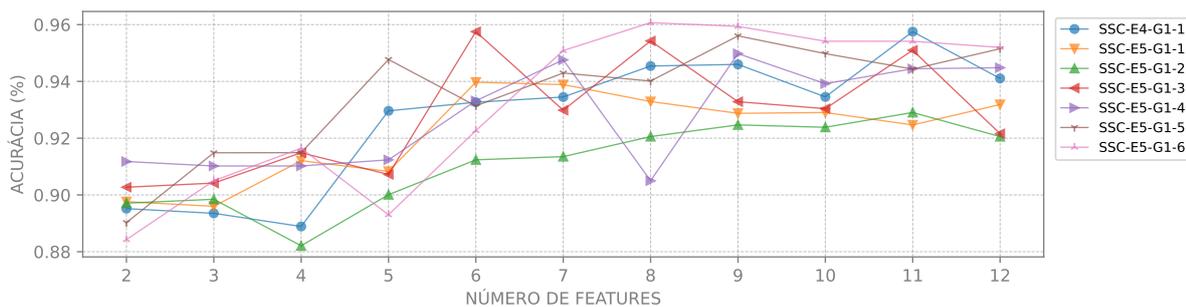
Quanto à avaliação dos modelos, as Figuras 95 à 102 ilustram os resultados dos testes dos melhores modelos em todos os cenários avaliados, agrupados por critério de parada. Para fins de comparação e avaliação da influência das técnicas de normalização, os resultados de E4-G1-1 para o critério SSC, E3-G1-3 para BWC e E4-G1-2 para os demais critérios foram também apresentados conjuntamente.

Figura 95 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada SD. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

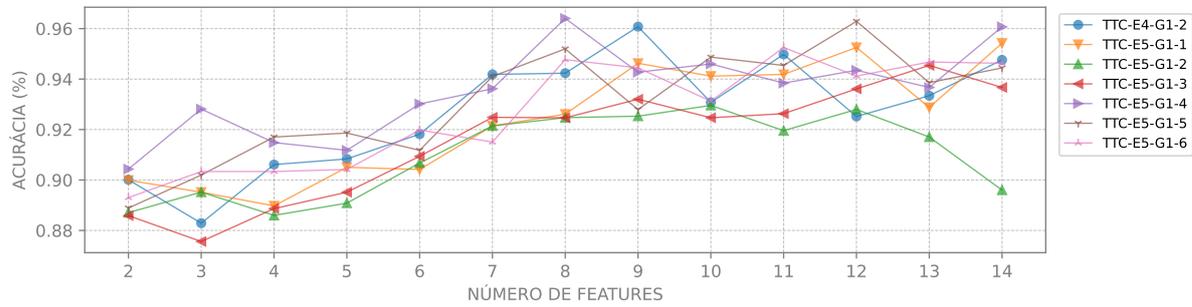
Figura 96 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada SSC. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

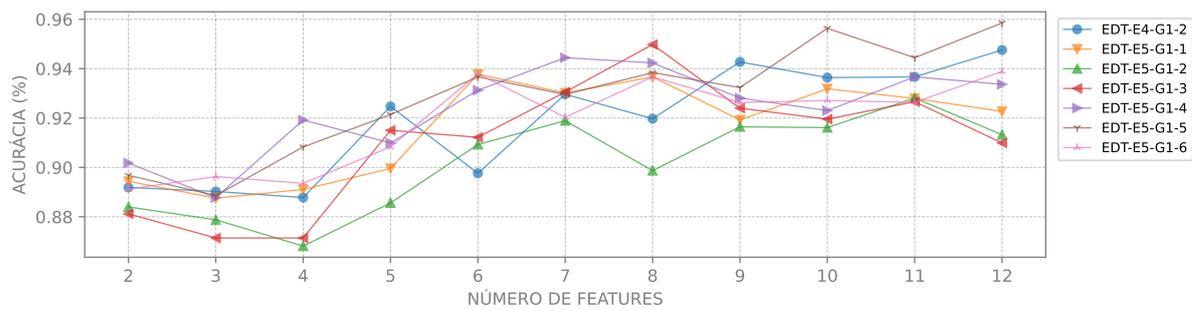
Nas Figuras apresentadas, constata-se uma oscilação marcante nos resultados a partir das técnicas de normalização utilizadas, que exerceram influências variadas, tanto de maneira benéfica quanto adversa. Em certas situações, como no caso de RFC-E5-G1-5 (10 fts), a normalização potencializou a estrutura inerente dos dados, propiciando uma classificação mais acertada. No entanto, em outros contextos, como observado em SD-E5-G1-2 (9 fts), as conexões essenciais entre as *features* foram possivelmente obscurecidas, levando a performances abaixo do esperado. Essa variação de resultados reforça a premissa

Figura 97 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada TTC. O número de *features* é dado pela ordem de extração das IMFs.



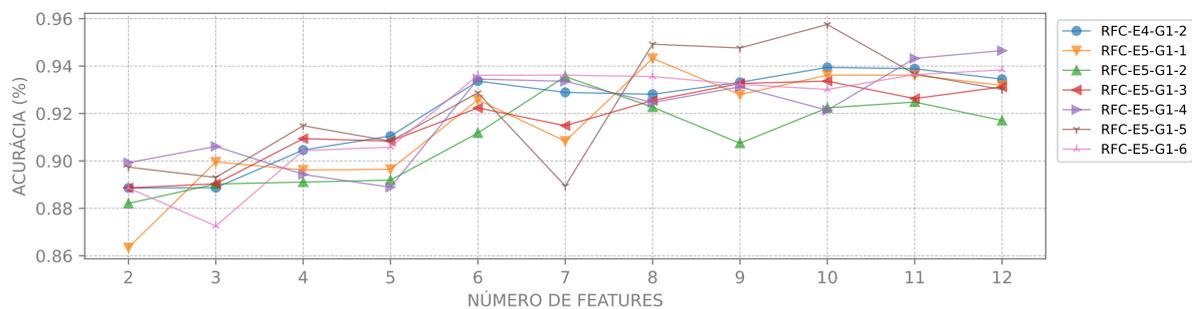
Fonte: Produzido pelo autor.

Figura 98 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada EDT. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 99 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada RFC. O número de *features* é dado pela ordem de extração das IMFs.

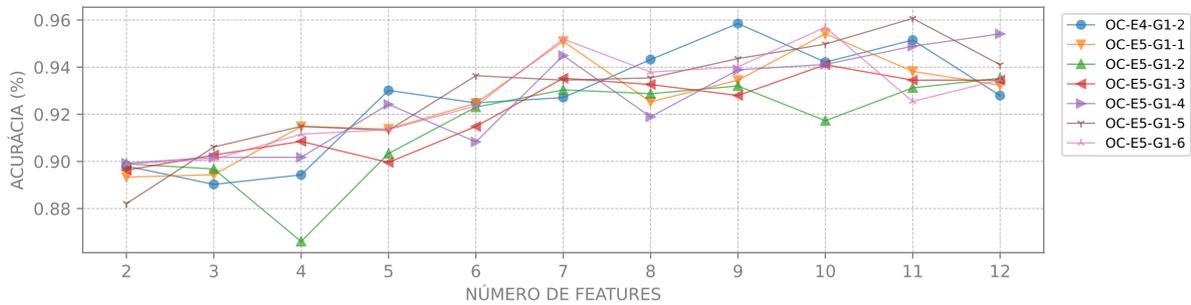


Fonte: Produzido pelo autor.

de que a escolha criteriosa da técnica de normalização é vital para maximizar a performance do modelo classificador, corroborando com Singh e Singh (2020, 2022).

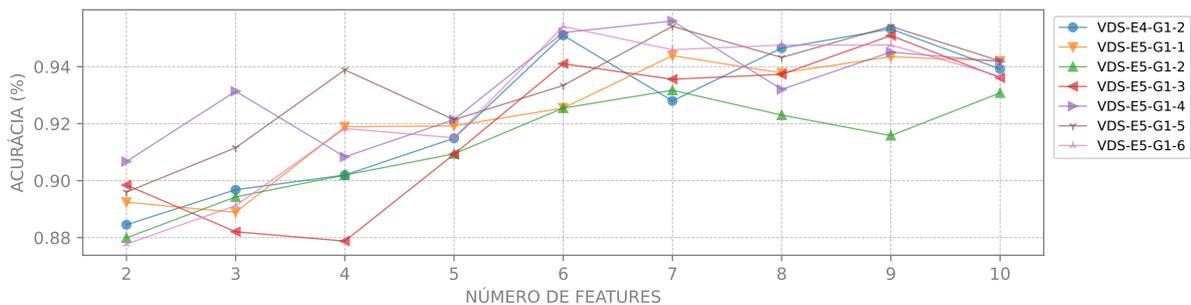
Observou-se que determinadas técnicas de normalização resultaram em desempenhos equivalentes ou superiores quando associadas a um número distinto de *features*, seja

Figura 100 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada OC. O número de *features* é dado pela ordem de extração das IMFs.



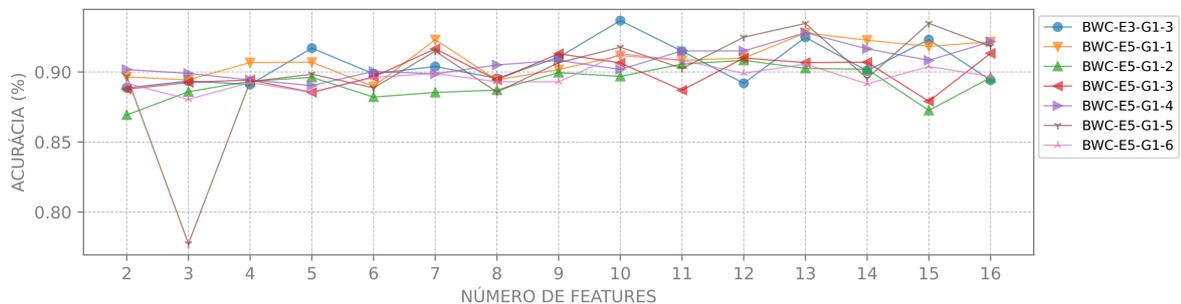
Fonte: Produzido pelo autor.

Figura 101 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada VDS. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 102 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E5-G1 para o critério de parada BWC. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

em quantidades maiores ou menores. Esse fenômeno sugere que a eficácia de uma técnica de normalização pode estar relacionada à dimensionalidade dos dados. Este aspecto destaca a relevância de uma avaliação metódica da interação entre a técnica de normalização empregada e a dimensionalidade do conjunto de dados no processo de otimização dos modelos.

Estudos nessa direção foram realizados com a utilização da PFE para redimensionar os vetores, conservando apenas as *features* de maior relevância, e seus respectivos resultados estão detalhados nos experimentos dos grupos G2 e G3.

Os hiperparâmetros determinados para os modelos de melhor desempenho, bem como as métricas acurácia, precisão, *recall*, *F1-score* e AUC, estão detalhados na Tabela 32. Os modelos alcançaram um AUC mínimo de 0.91, no caso SD-E5-G1-2 (5 fts), atingindo 0.99 em vários outros. As configurações que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada estão destacadas na Tabela 32. Priorizou-se novamente o *F1-score* máximo, conforme descrito anteriormente.

Tabela 32 – Melhores resultados em E5-G1. As configurações destacadas são as que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada. O termo “Poly” refere-se ao *kernel* Polinomial.

Configuração	Num. features	Amostras treino (%)	C	γ	Kernel	Acurácia	Precisão	Recall	F1-score	AUC
SD-E5-G1-1	10	40	100.0	1	Poly	0.92795	0.94570	0.90870	0.92683	0.98
SSC-E5-G1-1	6	50	100.0	10.0	RBF	0.93971	0.96237	0.91795	0.93963	0.97
TTC-E5-G1-1	14	80	1000.0	0.1	RBF	0.95425	0.97516	0.94012	0.95732	0.99
EDT-E5-G1-1	6	20	0.01	10.0	Poly	0.93776	0.96271	0.91318	0.93729	0.97
RFC-E5-G1-1	8	40	1000.0	0.1	RBF	0.94323	0.96388	0.92225	0.94260	0.98
OC-E5-G1-1	10	60	100.0	1	Poly	0.95417	0.97627	0.93204	0.95364	0.97
VDS-E5-G1-1	7	30	1000.0	0.1	RBF	0.94387	0.93843	0.94906	0.94371	0.98
BWC-E5-G1-1	13	70	100.0	1	RBF	0.92795	0.94690	0.91064	0.92842	0.96
SD-E5-G1-2	5	20	100.0	-	LINEAR	0.91646	0.89144	0.94951	0.91956	0.91
SSC-E5-G1-2	11	40	1000.0	0.1	RBF	0.92904	0.93709	0.92308	0.93003	0.97
TTC-E5-G1-2	10	20	1	-	LINEAR	0.92957	0.91297	0.94901	0.93065	0.97
EDT-E5-G1-2	11	80	1000.0	1	RBF	0.92810	0.94000	0.91558	0.92763	0.98
RFC-E5-G1-2	7	40	100.0	1	RBF	0.93559	0.93598	0.93392	0.93495	0.97
OC-E5-G1-2	12	20	1	0.1	RBF	0.93530	0.93904	0.93137	0.93519	0.98
VDS-E5-G1-2	7	30	1000.0	0.1	RBF	0.93171	0.93923	0.92727	0.93321	0.96
BWC-E5-G1-2	12	30	1000.0	1	RBF	0.90833	0.93561	0.87571	0.90467	0.93
SD-E5-G1-3	10	50	100.0	1	RBF	0.92661	0.94164	0.91260	0.92689	0.98
SSC-E5-G1-3	6	80	100.0	1	RBF	0.95752	0.97015	0.93525	0.95238	0.98
TTC-E5-G1-3	13	70	100.0	1	RBF	0.94541	0.95434	0.93304	0.94357	0.98
EDT-E5-G1-3	8	70	1000.0	1	RBF	0.94978	0.95763	0.94561	0.95158	0.98
RFC-E5-G1-3	10	20	100.0	0.1	RBF	0.93366	0.93076	0.93831	0.93452	0.98
OC-E5-G1-3	10	50	1000.0	0.1	RBF	0.94102	0.94459	0.93717	0.94087	0.99
VDS-E5-G1-3	9	60	1000.0	0.1	RBF	0.95090	0.94516	0.95752	0.95130	0.99
BWC-E5-G1-3	7	60	100.0	1	RBF	0.91653	0.94406	0.88525	0.91371	0.95
SD-E5-G1-4	9	70	1000.0	1	RBF	0.93886	0.96313	0.91266	0.93722	0.99
SSC-E5-G1-4	9	70	1000.0	0.1	RBF	0.94978	0.94583	0.95781	0.95178	0.99
TTC-E5-G1-4	8	80	0.01	10.0	Poly	0.96405	0.96855	0.96250	0.96552	0.99
EDT-E5-G1-4	7	80	1000.0	1	RBF	0.94444	0.93919	0.94558	0.94237	0.98
RFC-E5-G1-4	12	40	100.0	1	RBF	0.94651	0.94843	0.94209	0.94525	0.98
OC-E5-G1-4	12	50	0.01	10.0	Poly	0.95413	0.96703	0.93867	0.95264	0.99
VDS-E5-G1-4	7	30	1000.0	1	Poly	0.95603	0.97876	0.93370	0.95570	0.99
BWC-E5-G1-4	13	60	1000.0	1	RBF	0.92799	0.94408	0.91401	0.92880	0.96
SD-E5-G1-5	9	80	100.0	1000.0	RBF	0.94771	0.94558	0.94558	0.94558	0.97
SSC-E5-G1-5	9	30	1000.0	10.0	RBF	0.95603	0.95037	0.96276	0.95652	0.99
TTC-E5-G1-5	12	70	100.0	100.0	RBF	0.96288	0.97917	0.95142	0.96509	0.99
EDT-E5-G1-5	12	70	1000.0	100.0	RBF	0.95852	0.98298	0.93902	0.96050	0.99
RFC-E5-G1-5	10	80	1000.0	100.0	RBF	0.95752	0.97945	0.93464	0.95652	0.98
OC-E5-G1-5	11	70	1000.0	100.0	RBF	0.96070	0.97458	0.95041	0.96234	0.99
VDS-E5-G1-5	7	60	100.0	1000.0	RBF	0.95417	0.95593	0.94949	0.95270	0.98
BWC-E5-G1-5	13	80	1000.0	100.0	RBF	0.93464	0.95270	0.91558	0.93377	0.95
SD-E5-G1-6	6	20	1	100.0	Poly	0.93448	0.94324	0.92471	0.93388	0.98
SSC-E5-G1-6	8	70	1000.0	1000.0	RBF	0.96070	0.96581	0.95763	0.96170	0.99
TTC-E5-G1-6	11	60	1000.0	1000.0	RBF	0.95254	0.94212	0.96382	0.95285	0.99
EDT-E5-G1-6	12	70	1000.0	1000.0	RBF	0.93886	0.94142	0.94142	0.94142	0.98
RFC-E5-G1-6	12	50	1000.0	1000.0	RBF	0.93840	0.93834	0.93583	0.93708	0.99
OC-E5-G1-6	10	30	1000.0	1000.0	RBF	0.95697	0.96811	0.94679	0.95733	0.99
VDS-E5-G1-6	6	70	1000.0	1000.0	RBF	0.95415	0.94397	0.96476	0.95425	0.99
BWC-E5-G1-6	10	30	1000.0	1000.0	RBF	0.91300	0.94422	0.87941	0.91066	0.96

Fonte: Elaborada pelo autor.

Com base nas análises e tendo em vista os resultados apresentados nas Tabelas 28 e 32, conclui-se que a escolha de uma técnica de normalização adequada possibilita uma melhoria, ainda que mínima, no desempenho do sistema. Além disso, notou-se uma acentuada melhoria em relação à PFE quanto as distâncias ao VO, indicando que a

aplicação de uma técnica específica pode ter evidenciado a estrutura dos dados. A obtenção de acurácias e *F1-scores* que se aproximaram ou superaram os 95% indica que certas configurações exibiram desempenhos equiparáveis aos de ensaios anteriores. Isso sugere que alguns modelos se mostraram eficazes na classificação das observações, conseguindo um bom equilíbrio entre a detecção precisa de cigarras e a minimização de FPs.

Conclui-se que o sistema proposto, com vetores de *features* no formato F1, demonstra eficácia mesmo quando se empregam sinais de curta duração com uma taxa de amostragem reduzida, desde que satisfaça o Teorema de Nyquist. A utilização de parâmetros mais flexíveis para a EMD e a robustez e precisão evidenciadas nos testes dos modelos, que se mostraram satisfatórios com diferentes técnicas de normalização, consolidam a hipótese inicialmente proposta nesta subseção.

Nos próximos grupos de experimentos, serão concentrados esforços para o aprimoramento do sistema proposto. O objetivo é otimizar o desempenho dos classificadores ao considerar vetores no formato F2. A utilização desse formato é prevista para possibilitar uma separação mais acurada das frequências dos sinais com base nas bandas críticas da EB. Espera-se que tal abordagem amplie a capacidade do modelo de discernir padrões sutis e complexos nos dados, contribuindo para aprimorar ainda mais a precisão e a confiabilidade das classificações realizadas.

4.2.2 Grupo G2

Neste grupo de experimentos, a detecção de cigarras também se concentra na discriminação entre as classes “cigarra” e “ruído”. Contudo, ao contrário do grupo anterior, os vetores de *features* foram determinados no formato F2. Esse formato leva em consideração as correspondências entre as FIs das IMFs e as 25 bandas críticas da EB para distribuição das energias entre as *features*. Essa nova estratégia integra a HT (segunda etapa da HHT), permitindo a extração precisa e a representação das frequências dominantes em cada IMF. Conforme argumentado na [seção 3.1](#), acredita-se que esta abordagem possa aprimorar a identificação da assinatura acústica das cigarras, pois resulta em uma representação mais alinhada à natureza acústica dos sinais, além de permitir combinações mais ricas e significativas entre as *features*, aspecto que será explorado no ensaio E7. Portanto, a hipótese é que a representação dos sinais em vetores através desta metodologia possa conferir uma vantagem adicional àquela empregada nos experimentos do grupo G1, potencializando o desempenho dos modelos classificadores.

4.2.2.1 Experimento E6

Nos experimentos anteriores, evidenciou-se a robustez e precisão do sistema proposto na classificação de sinais representados por vetores no formato F1. Também se explorou

a possibilidade de reduzir o custo computacional sem comprometer o desempenho dos modelos classificadores. Apesar dos resultados satisfatórios já obtidos, a hipótese deste ensaio é de que vetores no formato F2 possam potencializar ainda mais o desempenho dos modelos. Neste contexto, o experimento E6 foi realizado com sinais derivados dos sinais originais, os quais foram capturados a uma taxa de amostragem de 44.1 kHz e 16 bits de quantização. Foram consideradas duração e taxa de amostragem de 1 segundo e 6 kHz, respectivamente, para cada sinal. No tratamento via EMD, aplicaram-se os 8 critérios de parada e estipulou-se um máximo de 700 iterações por IMF. Os vetores de *features* passaram por um processo de normalização utilizando as técnicas MN, MMN e LS, descritas na [seção 2.5](#). Para a técnica MMN, realizou-se o reescalonamento das *features* para o intervalo $[0, 1]$, definindo $a = 0$ e $b = 1$. Por outro lado, para a técnica LS, exploraram-se cinco variações do coeficiente v , sendo $v \in \{0.01, 0.1, 1, 10, 100\}$. Os conjuntos de vetores analisados foram gerados considerando-se as k primeiras *features*, com k variando entre 2 e 25, para todas as configurações. Os parâmetros específicos, associados a cada critério de parada, seguem os mais flexíveis adotados nos ensaios E4 e E5 do grupo G1. A única exceção é para o critério BWC, cuja configuração é derivada de E3-G1-3. As configurações detalhadas deste experimento estão disponíveis na [Tabela 33](#).

E6-G2: Resultados do Módulo MEF

Para o experimento E6-G2, os resultados obtidos no módulo MEF são consistentes com aqueles de E5-G1. Especificamente, os resultados coincidem com os de E4-G1-1 para o critério SSC, com E3-G1-3 para o critério BWC e com E4-G1-2 para os demais critérios. Esta consistência deve-se ao fato de a HT ser aplicada a cada IMF previamente extraída, permitindo a obtenção das FIs para a formação dos vetores no formato F2.

E6-G2: Resultados do Módulo MNF

Seguindo, aplica-se o módulo MNF para normalização dos vetores, agora todos com um número máximo de *features* fixo. As técnicas adotadas neste ensaio foram MN, MMN e LS, conforme descrito na [Tabela 33](#). Na [Figura 103](#), são apresentados os gráficos de radar correspondentes aos vetores derivados dos introduzidos em E5-G1 e ilustrados na [Figura 81](#), aqui no formato F2.

Semelhante à estratégia anterior, as classes se mostram visualmente distinguíveis, como pode ser observado na [Figura 103](#). Para os sinais escolhidos como exemplos, os vetores resultantes para SD-E6-G2-1 e SD-E6-G2-2 são visualmente idênticos. Isso indica que as técnicas de normalização MN e MMN tendem a produzir vetores semelhantes nesse contexto. Comparados aos gráficos anteriormente apresentados, a distinção entre as representações é evidente. Nos vetores no formato F1 relativos à classe “cigarra”,

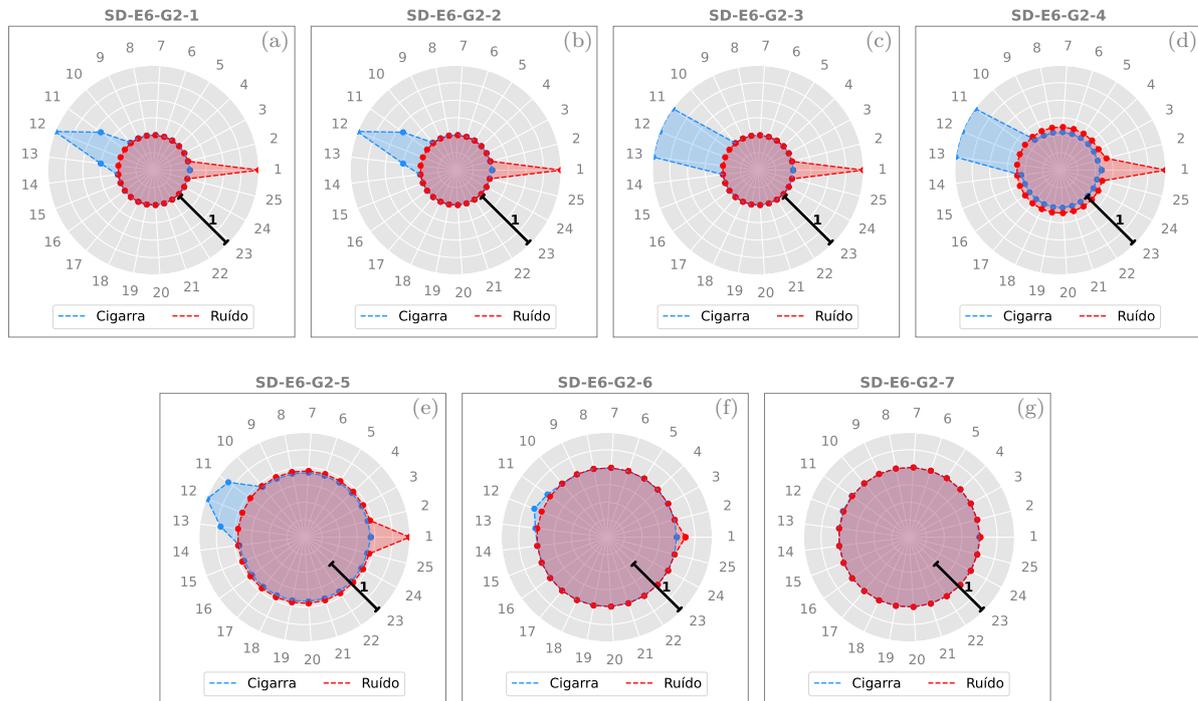
Tabela 33 – Configurações para o experimento E6 do grupo G2.

Rótulos	Amostragem (kHz)	Tempo (s)	Configurações da EMD		Norma	It. Max.
			Critério de parada	Parâmetros		
SD-E6-G2-1	6	1	SD	$\varepsilon = 0.3$	MN	700
SSC-E6-G2-1			SSC	$S = 2$		
TTC-E6-G2-1			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E6-G2-1			EDT	$\varepsilon = 0.1$		
RFC-E6-G2-1			RFC	$R = 30$		
OC-E6-G2-1			OC	$\varepsilon = 0.2$		
VDS-E6-G2-1			VDS	95% de $m(t) < 0.05$		
BWC-E6-G2-1			BWC	mínimo de B_f^2 encontrado		
SD-E6-G2-2	6	1	SD	$\varepsilon = 0.3$	MMN	700
SSC-E6-G2-2			SSC	$S = 2$		
TTC-E6-G2-2			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E6-G2-2			EDT	$\varepsilon = 0.1$		
RFC-E6-G2-2			RFC	$R = 30$		
OC-E6-G2-2			OC	$\varepsilon = 0.2$		
VDS-E6-G2-2			VDS	95% de $m(t) < 0.05$		
BWC-E6-G2-2			BWC	mínimo de B_f^2 encontrado		
SD-E6-G2-3	6	1	SD	$\varepsilon = 0.3$	LS(0.01)	700
SSC-E6-G2-3			SSC	$S = 2$		
TTC-E6-G2-3			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E6-G2-3			EDT	$\varepsilon = 0.1$		
RFC-E6-G2-3			RFC	$R = 30$		
OC-E6-G2-3			OC	$\varepsilon = 0.2$		
VDS-E6-G2-3			VDS	95% de $m(t) < 0.05$		
BWC-E6-G2-3			BWC	mínimo de B_f^2 encontrado		
SD-E6-G2-4	6	1	SD	$\varepsilon = 0.3$	LS(0.1)	700
SSC-E6-G2-4			SSC	$S = 2$		
TTC-E6-G2-4			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E6-G2-4			EDT	$\varepsilon = 0.1$		
RFC-E6-G2-4			RFC	$R = 30$		
OC-E6-G2-4			OC	$\varepsilon = 0.2$		
VDS-E6-G2-4			VDS	95% de $m(t) < 0.05$		
BWC-E6-G2-4			BWC	mínimo de B_f^2 encontrado		
SD-E6-G2-5	6	1	SD	$\varepsilon = 0.3$	LS(1)	700
SSC-E6-G2-5			SSC	$S = 2$		
TTC-E6-G2-5			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E6-G2-5			EDT	$\varepsilon = 0.1$		
RFC-E6-G2-5			RFC	$R = 30$		
OC-E6-G2-5			OC	$\varepsilon = 0.2$		
VDS-E6-G2-5			VDS	95% de $m(t) < 0.05$		
BWC-E6-G2-5			BWC	mínimo de B_f^2 encontrado		
SD-E6-G2-6	6	1	SD	$\varepsilon = 0.3$	LS(10)	700
SSC-E6-G2-6			SSC	$S = 2$		
TTC-E6-G2-6			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E6-G2-6			EDT	$\varepsilon = 0.1$		
RFC-E6-G2-6			RFC	$R = 30$		
OC-E6-G2-6			OC	$\varepsilon = 0.2$		
VDS-E6-G2-6			VDS	95% de $m(t) < 0.05$		
BWC-E6-G2-6			BWC	mínimo de B_f^2 encontrado		
SD-E6-G2-7	6	1	SD	$\varepsilon = 0.3$	LS(100)	700
SSC-E6-G2-7			SSC	$S = 2$		
TTC-E6-G2-7			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E6-G2-7			EDT	$\varepsilon = 0.1$		
RFC-E6-G2-7			RFC	$R = 30$		
OC-E6-G2-7			OC	$\varepsilon = 0.2$		
VDS-E6-G2-7			VDS	95% de $m(t) < 0.05$		
BWC-E6-G2-7			BWC	mínimo de B_f^2 encontrado		

Fonte: Elaborada pelo autor.

observa-se um pico de energia na primeira IMF e um decrescimento acentuado nas IMFs subsequentes. Em contrapartida, no formato F2, as energias são distribuídas nas *features* 11 à 13, que correspondem às frequências entre 1 270 Hz e 2 000 Hz, conforme especificado na Tabela 3. Esse resultado é esperado, dado que a frequência dominante da *Quesada gigas* nas regiões onde os áudios foram coletados é próxima de 1 705 Hz (MACCAGNAN, 2008). Já os vetores correspondentes à classe “ruído”, no formato F1, possuíam uma ampla

Figura 103 – Exemplos de vetores de *features* formados pelas configurações SD-E6-G2-1 à SD-E6-G2-7. Estes vetores correspondem aos representados na Figura 81, porém, no formato F2.



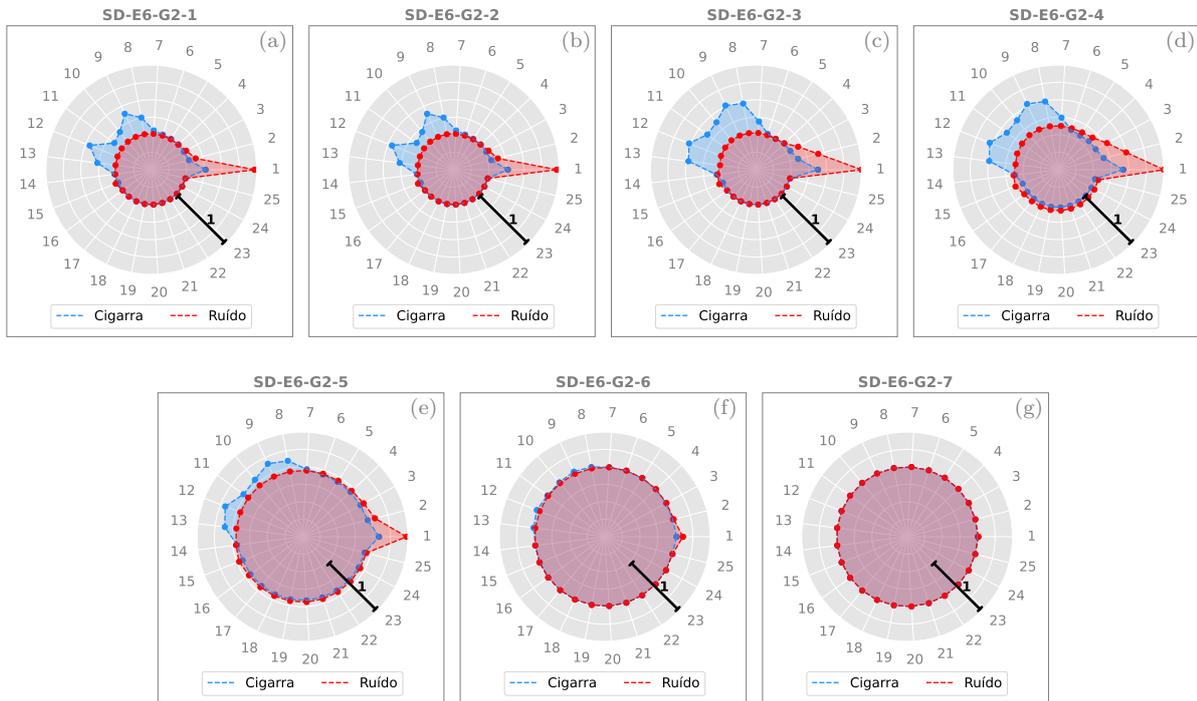
Fonte: Produzido pelo autor.

distribuição de energia nas IMFs intermediárias, e seus correspondentes no formato F2 exibem um pico proeminente na primeira *feature*, seguido por um decrescimento acentuado nas subsequentes.

Os outros exemplos, ilustrados nas Figuras 103c à 103g, derivam da normalização dos vetores descritos pela técnica LS, que é uma transformação não linear. Como em E5-G1, estes apresentam as diferenças mais acentuadas quando comparados a SD-E6-G2-1 e SD-E6-G2-2. Nos casos E6-G2-3 e E6-G2-4, é evidente que as *features* com maiores concentrações de energias se aproximam do valor 1. Por outro lado, E6-G2-5, E6-G2-6 e E6-G2-7 tendem a comprimir as energias em direção à energia média. Esta compressão torna-se gradativamente mais intensa de E6-G2-5 para E6-G2-7. Essa tendência também é refletida nas médias, como ilustrado na Figura 104. Nesse caso, a descrição para os vetores da classe “ruído” se mantém em média, enquanto para os vetores da classe “cigarra”, observa-se um pico na primeira *feature* e a distribuição de energia estende-se, indo da oitava à décima terceira *feature*.

Os gráficos reforçam as diferenças notáveis entre os vetores das classes “cigarra” e “ruído”. Contudo, uma exceção é notada em E6-G2-7, onde as distinções entre os vetores tornam-se visualmente imperceptíveis, visto que se aproximam significativamente da média. Nesse caso, o desempenho do SVM pode ser comprometido, como mencionado em caso semelhante no ensaio E5-G1. Contudo, não se pode descartar completamente a capacidade

Figura 104 – Gráficos de radar das *features*, em média, para as classes “cigarra” e “ruído” das configurações SD-E6-G2-1 à SD-E6-G2-7.



Fonte: Produzido pelo autor.

do modelo de apresentar um desempenho satisfatório, que depende da natureza específica dos dados e da implementação do algoritmo SVM.

Esse padrão de distribuição das *features* reescaladas e transformadas, foi identificado em todas as configurações exploradas e realça a relevância e eficiência dessas características para a classificação dos sinais, reforçando a hipótese proposta nesta subseção. Novamente, os gráficos pertinentes às representações das distribuições médias das energias no formato radar, correspondentes às demais configurações deste ensaio foram omitidos visando evitar redundâncias e assegurar clareza e objetividade na exposição dos resultados.

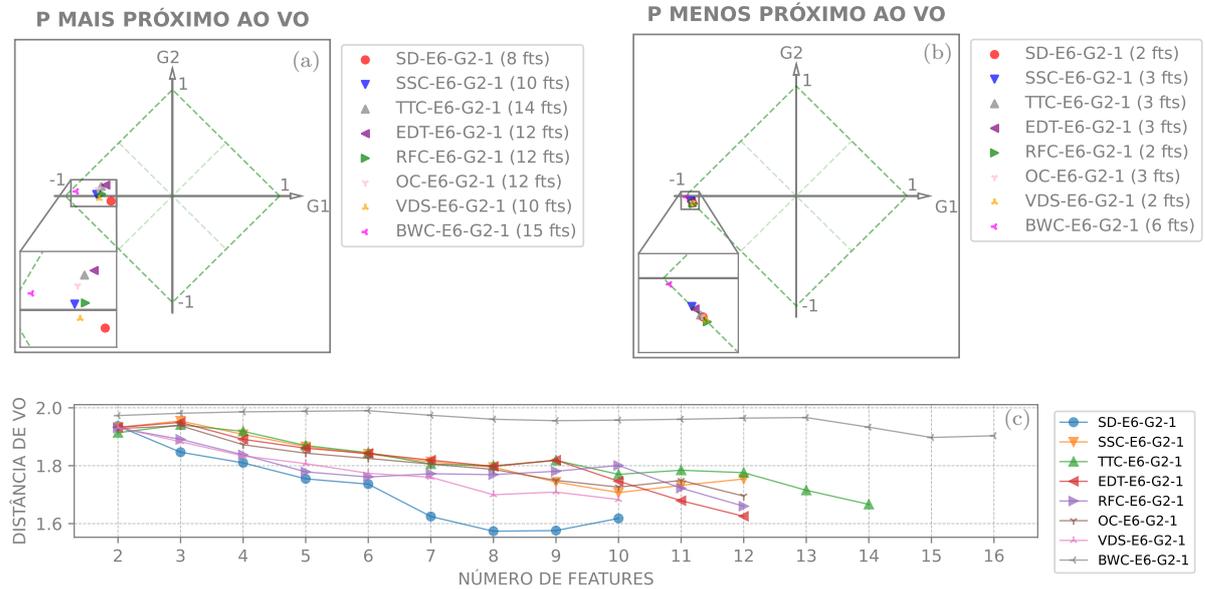
E6-G2: Resultados do Módulo MPFE

Dando continuidade à avaliação dos vetores, novamente todos os conjuntos gerados pela variação do número de *features* em ordem crescente foram submetidos ao módulo MPFE. Especificamente, consideraram-se as k primeiras *features*, com k variando entre 2 e M , para todas as configurações.

As Figuras 105 à 111 destacam tanto os melhores quanto os piores resultados para as configurações examinadas, bem como todas as distâncias ao VO referentes aos pontos P associados aos conjuntos de vetores em análise.

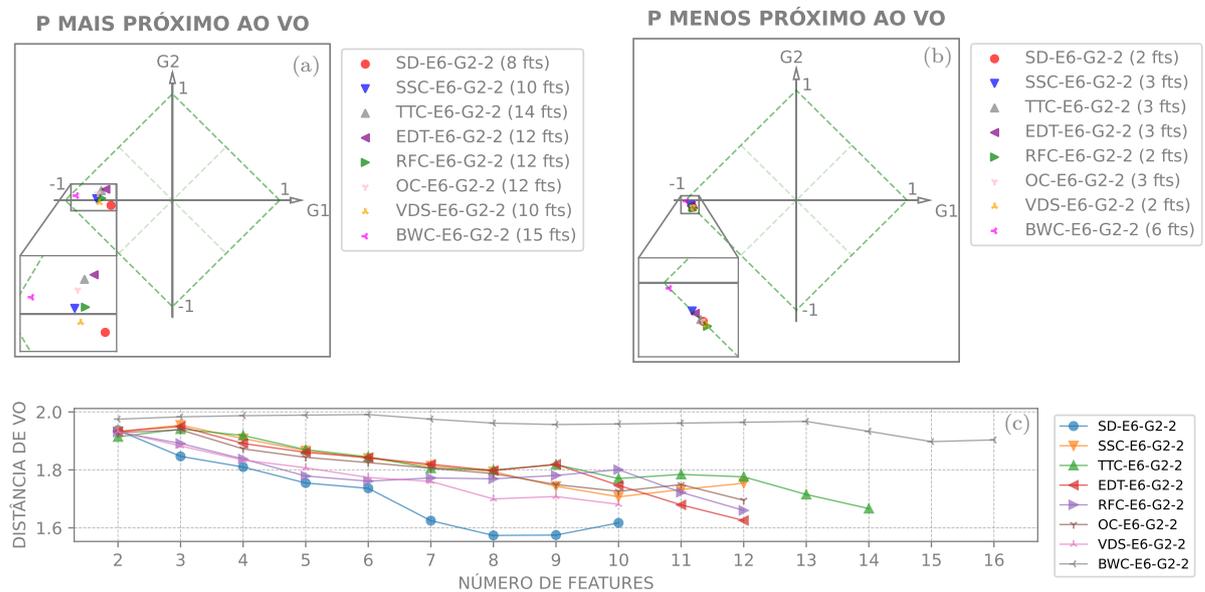
Observa-se que as configurações E6-G2-1 à E6-G2-4 não alteraram de forma significativa os resultados das análises PFE, os pontos se mantêm próximos ao vértice

Figura 105 – Resumo dos resultados do módulo MPFE para E6-G2-1. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

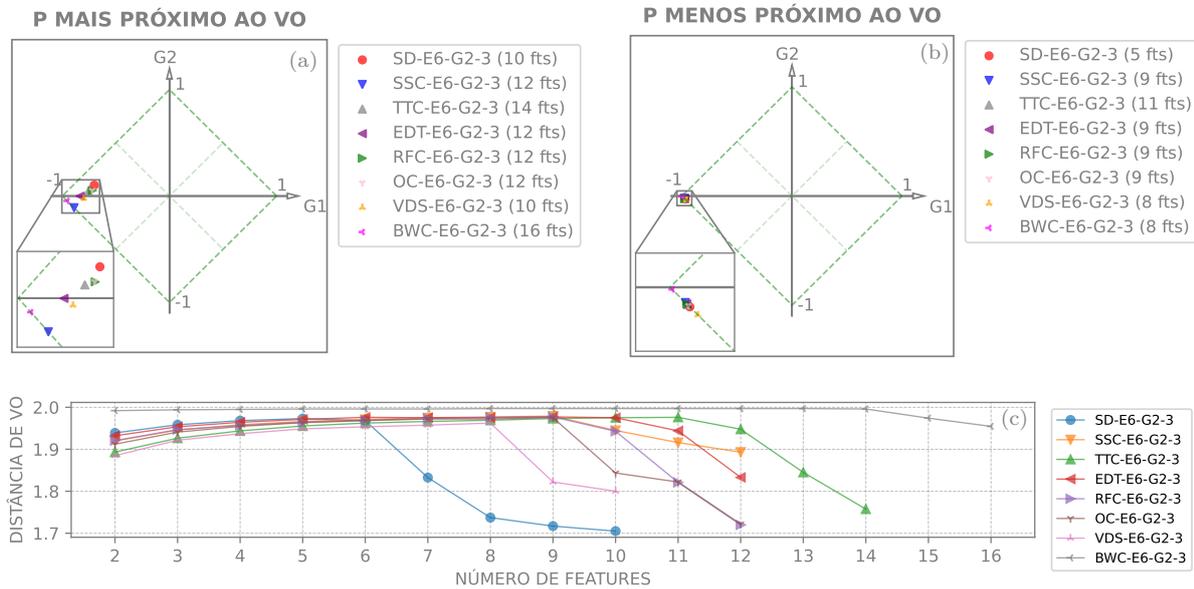
Figura 106 – Resumo dos resultados do módulo MPFE para E6-G2-2. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

$(-1, 0)$, conforme ilustrado nas Figuras 105 à 108. Este vértice corresponde à falsidade, ou seja, o resultado sugere que os vetores intraclasse continuam dispersos e os interclasse exibem uma considerável sobreposição. As distâncias resultantes encontram-se nas faixas

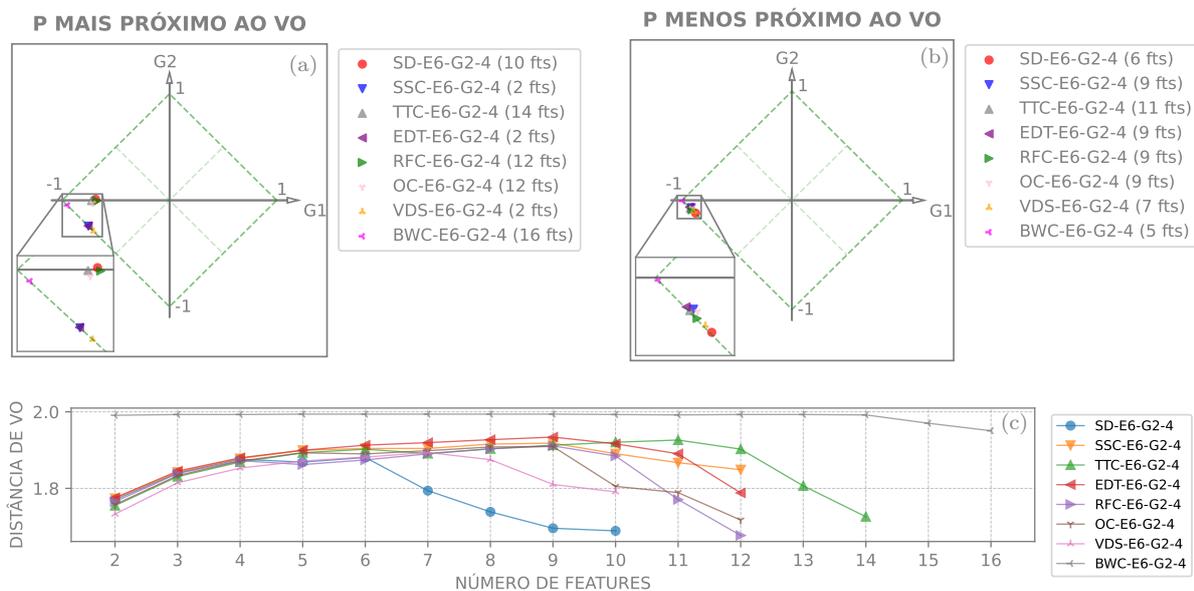
Figura 107 – Resumo dos resultados do módulo MPFE para E6-G2-3. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

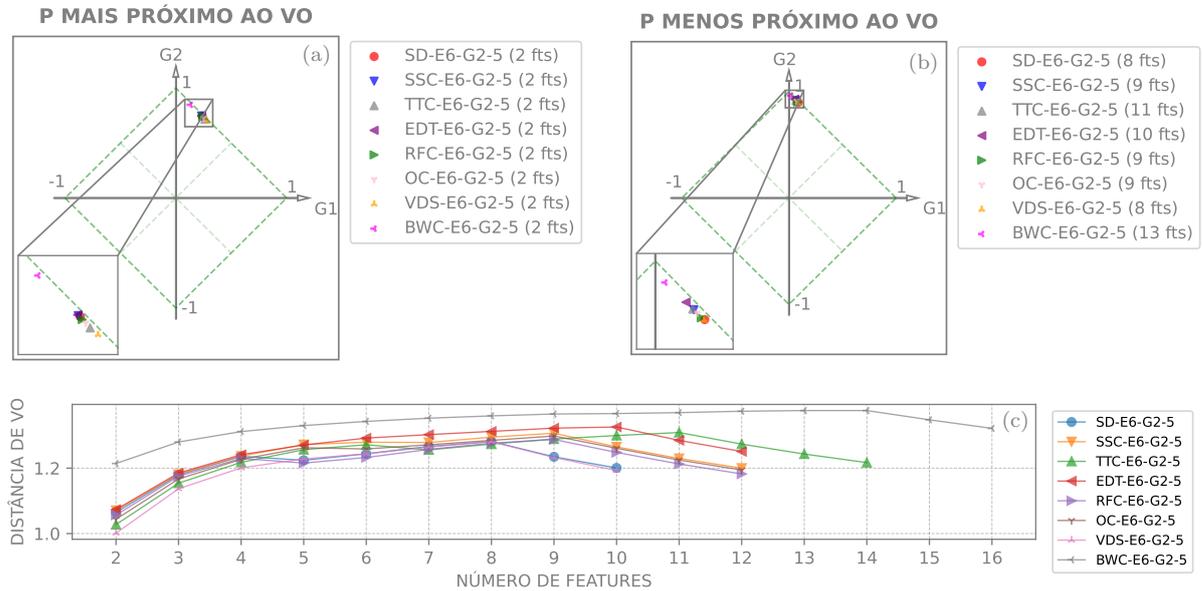
semelhantes às observadas em ensaios anteriores. Especificamente, os melhores resultados correspondem a E6-G2-1 e E6-G2-2, e situaram-se em torno de 1.6, um valor comparável aos melhores resultados dos ensaios anteriores.

Figura 108 – Resumo dos resultados do módulo MPFE para E6-G2-4. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



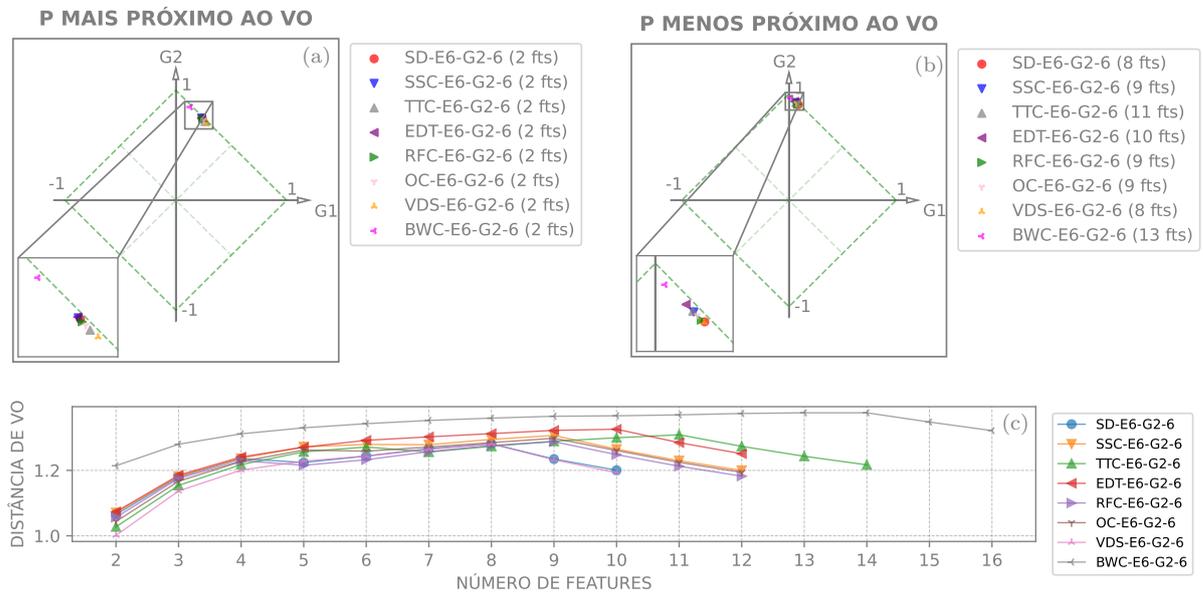
Fonte: Produzido pelo autor.

Figura 109 – Resumo dos resultados do módulo MPFE para E6-G2-5. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

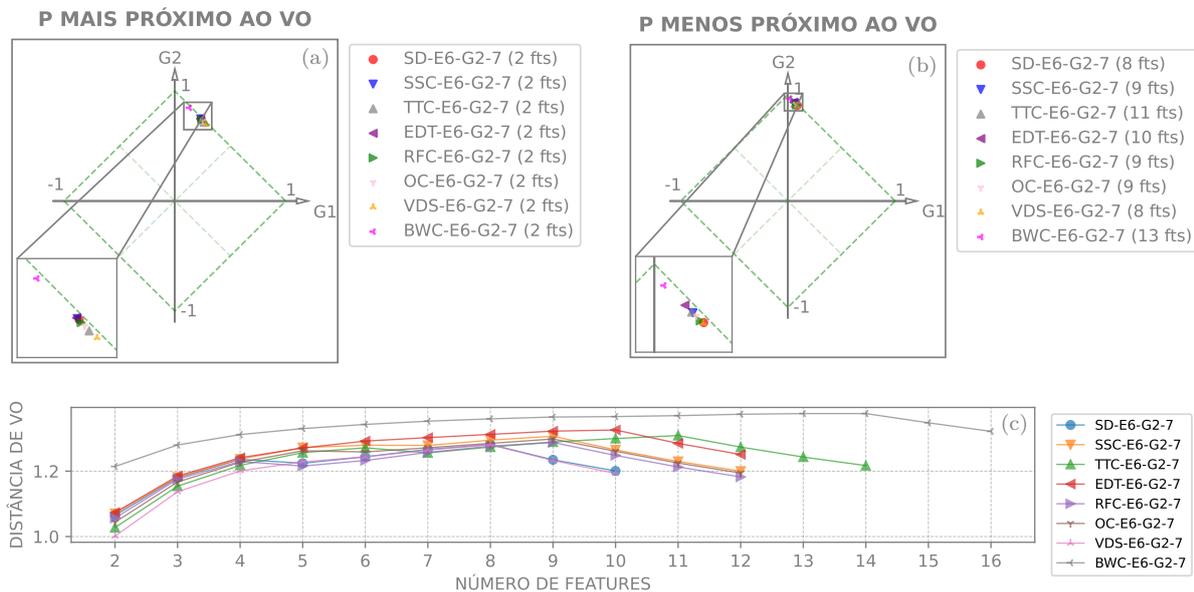
Figura 110 – Resumo dos resultados do módulo MPFE para E6-G2-6. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Em contraste, as configurações E6-G2-5 à E6-G2-7 reproduziram o efeito observado em E5-G1, onde os pontos se aproximaram do VO, porém situando-se mais próximos do vértice (0, 1), que é referente à ambiguidade. Tal constatação indica que, nas condições

Figura 111 – Resumo dos resultados do módulo MPFE para E6-G2-7. Em (a) apresentam-se os melhores pontos P ; em (b) os piores pontos P ; e (c) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

avaliadas, existe uma notável similaridade entre os vetores intraclasse e interclasse. Observa-se ainda que as distâncias menores, em relação a VO, associam-se ao menor número de *features*. Os desempenhos mais notáveis aproximam-se de 1 para as três configurações, atingindo exatamente esse valor para as configurações correspondentes ao critério de parada VDS nos três cenários. Conforme a análise PFE indica, os vetores gerados no formato F2 não exercem um impacto significativo nos resultados em relação aos ensaios anteriores.

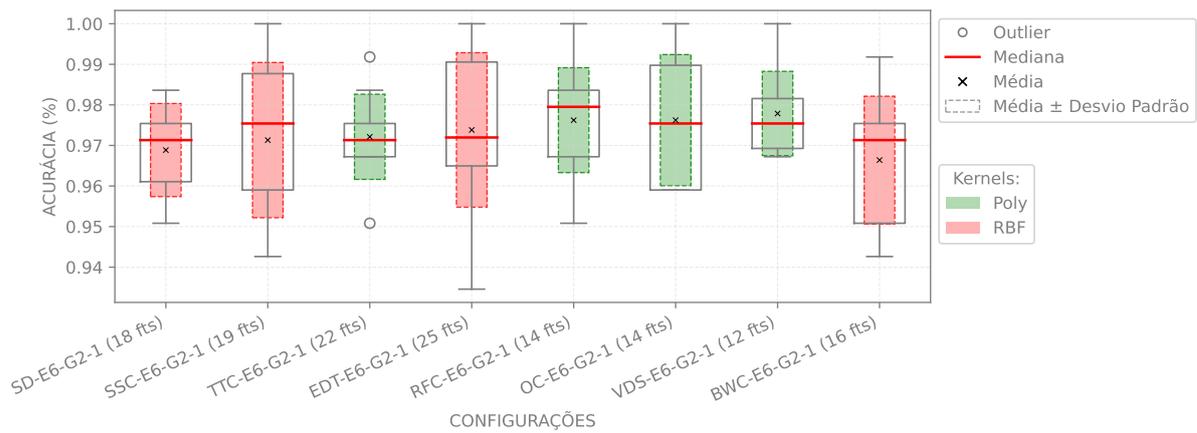
E6-G2: Resultados do módulo MTT

Prosseguindo com a avaliação de desempenho dos modelos SVM, o módulo MTT processa todos os conjuntos de vetores formados ao se variar a quantidade de *features*, em sequência crescente. Os parâmetros designados para o treinamento do classificador estão elencados na Tabela 6. Assim como nos experimentos anteriores, o limiar de treinamento foi definido por múltiplos de 10 no intervalo de 20 a 80.

Como mencionado, neste ensaio os máximos de *features* são fixos e correspondem às 25 bandas críticas da EB. Posto isto, considerando a validação cruzada com $k = 10$ partições e o fato de que o *kernel* linear não utiliza o parâmetro γ , foram realizados um total de 10 348 800 treinamentos distintos para todas as configurações, especificadas na Tabela 33. Ao final deste processo, os modelos que exibiram maiores médias de acurácias no processo de validação cruzada foram eleitos para os testes definitivos, utilizando o conjunto de dados especificamente reservado para essa finalidade.

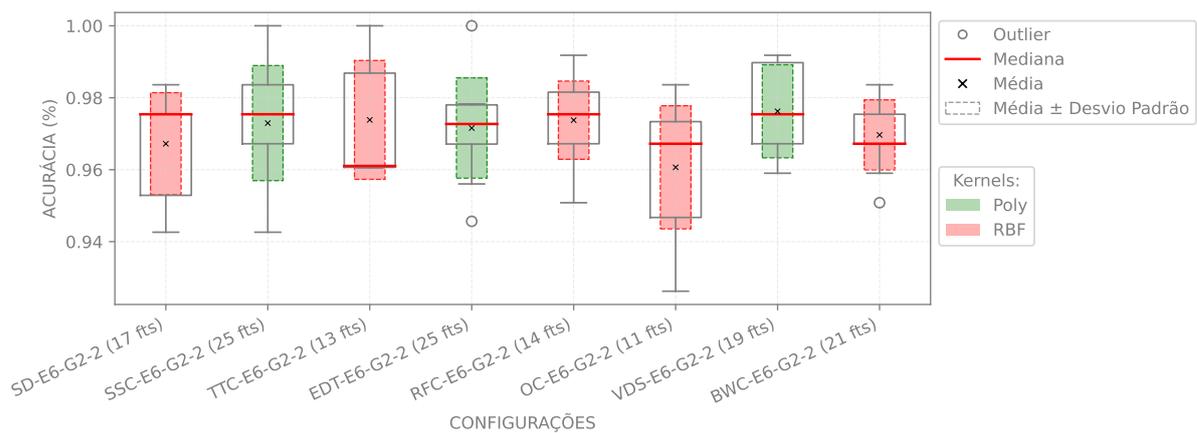
Após o processamento de todos os conjuntos de vetores, considerando a variação do número de *features*, os resultados obtidos nos treinamentos com validação cruzada para os modelos que exibiram maior eficácia nos testes subsequentes, abrangendo todas as configurações, foram ilustrados nas Figuras 112 à 118.

Figura 112 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-1. O número de *features* corresponde às primeiras bandas críticas da EB.



Fonte: Produzido pelo autor.

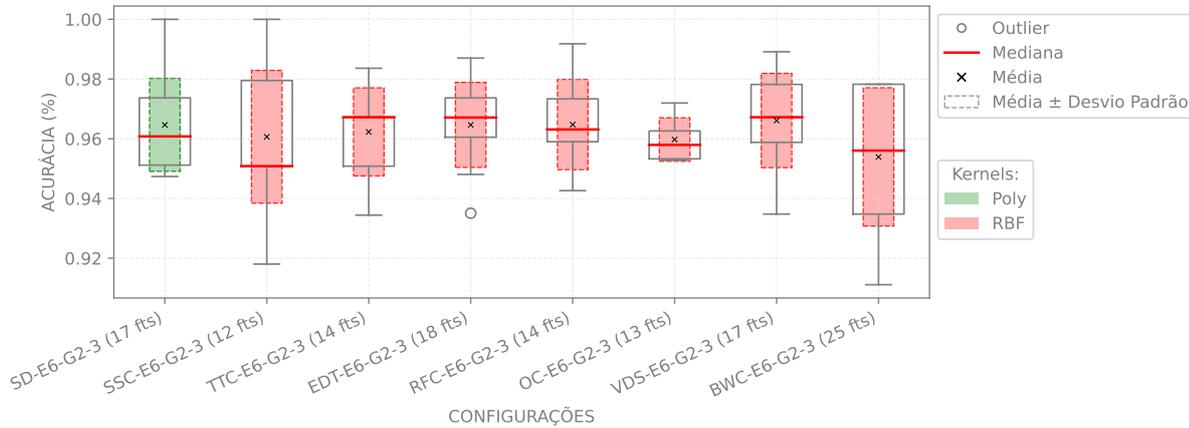
Figura 113 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-2. O número de *features* corresponde às primeiras bandas críticas da EB.



Fonte: Produzido pelo autor.

Nos resultados correspondentes às configurações avaliadas neste experimento, observa-se que os treinamentos referentes aos modelos de melhor desempenho nos testes exibiram acurácias superiores a 92% e médias consideravelmente superiores às obtidas nos ensaios anteriores, estando acima de 96%. Apenas as configurações BWC-E6-G2-3 (5 fts)

Figura 114 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-3. O número de *features* corresponde às primeiras bandas críticas da EB.

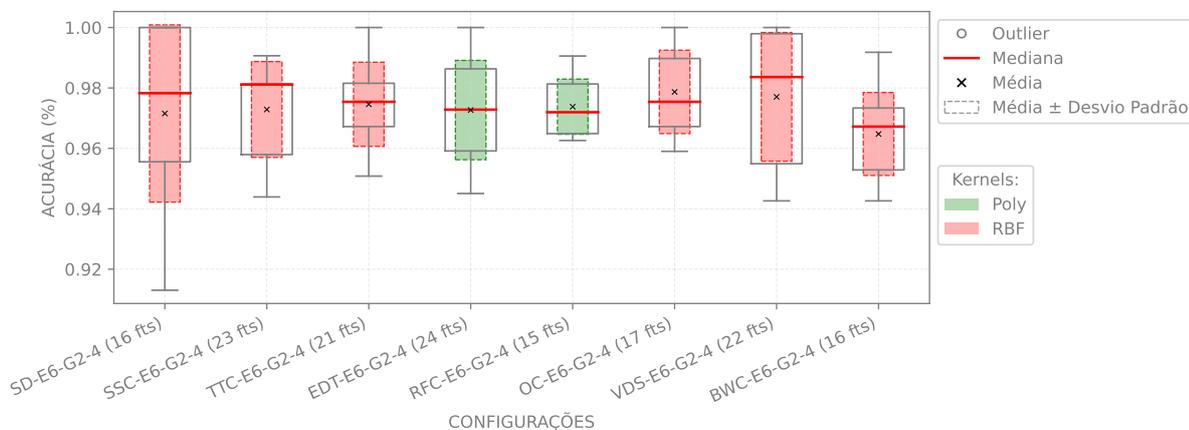


Fonte: Produzido pelo autor.

e BWC-E6-G2-7 (21 fts) constituem exceções. O primeiro modelo apresentou acurácia mínima de 91% e máxima próxima a 98%, enquanto o segundo obteve mínima de 92.6% e máxima de 99.1%. As faixas definidas pelas médias \pm desvios padrão permaneceram acima de 94%, ou com extremidade inferior do intervalo muito próxima a essa taxa.

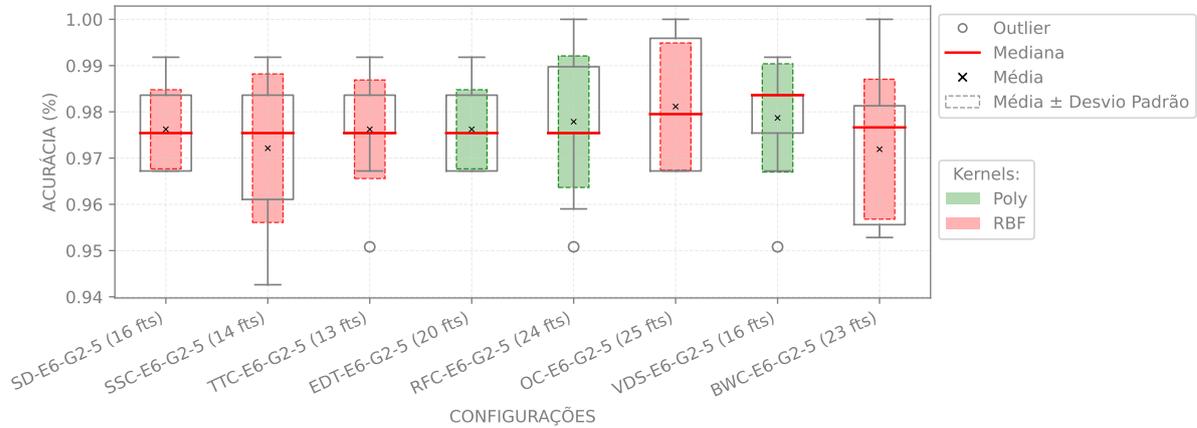
No que se refere aos *kernels*, o RBF mostrou-se novamente predominante entre os melhores hiperparâmetros, com uma ocorrência de 76.78%, seguido pelo *kernel* polinomial, com 23.22%.

Figura 115 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-4. O número de *features* corresponde às primeiras bandas críticas da EB.



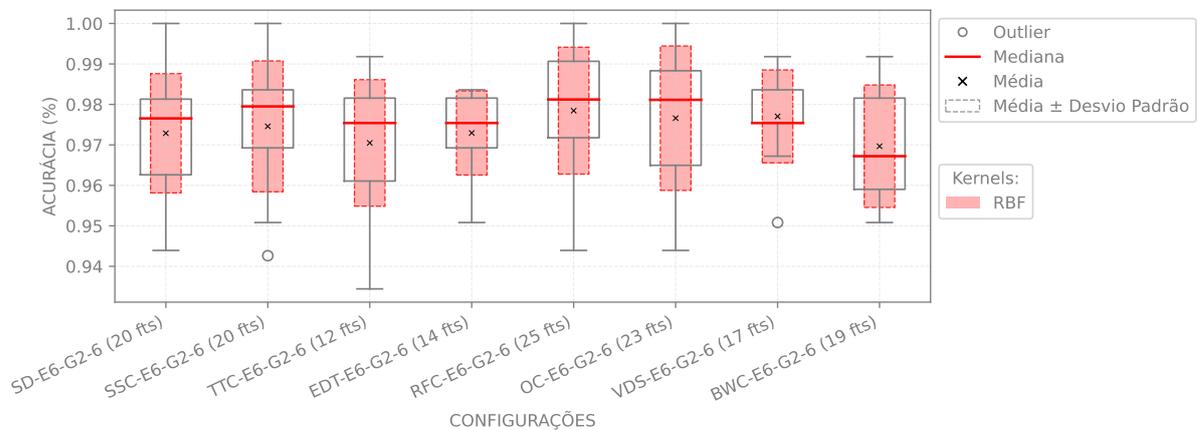
Fonte: Produzido pelo autor.

Figura 116 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-5. O número de *features* corresponde às primeiras bandas críticas da EB.



Fonte: Produzido pelo autor.

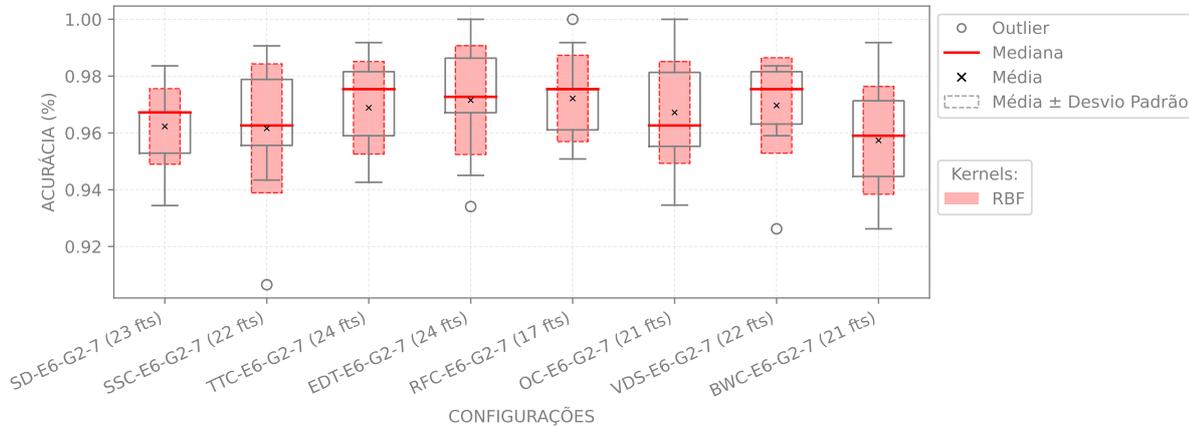
Figura 117 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-6. O número de *features* corresponde às primeiras bandas críticas da EB.



Fonte: Produzido pelo autor.

Em relação às distribuições das acurácias, os diagramas de caixa apresentam comportamentos variados, sendo predominantemente assimétricos no intervalo interquartil em relação à mediana. Algumas configurações mostram distribuições com intervalos mais amplos, como é o caso da SD-E6-G2-4 (16 fts), enquanto outras apresentam intervalos mais confinados, como a OC-E6-G2-3 (13 fts). Intervalos mais amplos indicam uma variação significativa nos resultados para essas configurações. Em contraste, intervalos mais estreitos sugerem que a configuração demonstra maior estabilidade e previsibilidade. Tal variabilidade pode originar-se da instabilidade particular da configuração ou de outros fatores não controlados no experimento. No contexto desta pesquisa, uma menor

Figura 118 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E6-G2-7. O número de *features* corresponde às primeiras bandas críticas da EB.

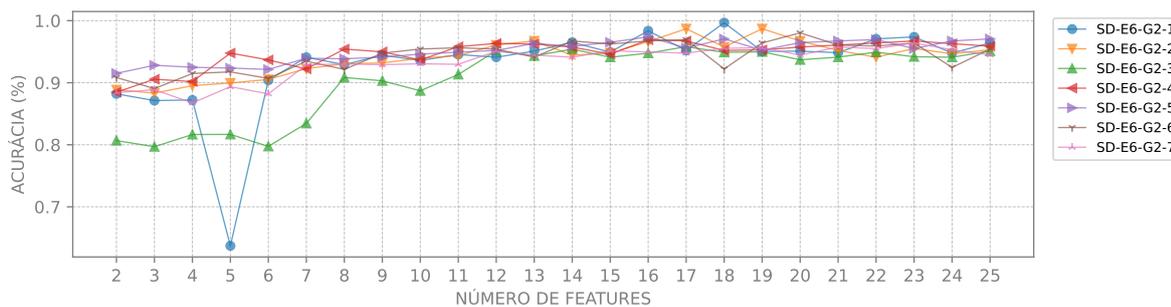


Fonte: Produzido pelo autor.

variabilidade é desejável, pois indica que o modelo é robusto e confiável nas condições estipuladas.

Quanto à avaliação dos modelos, as Figuras 119 à 126 ilustram os resultados dos testes dos melhores modelos em todos os cenários avaliados, agrupados por critério de parada.

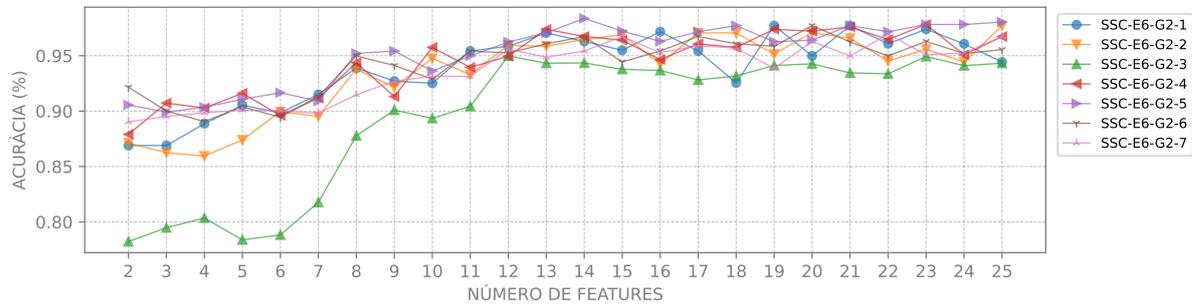
Figura 119 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada SD. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

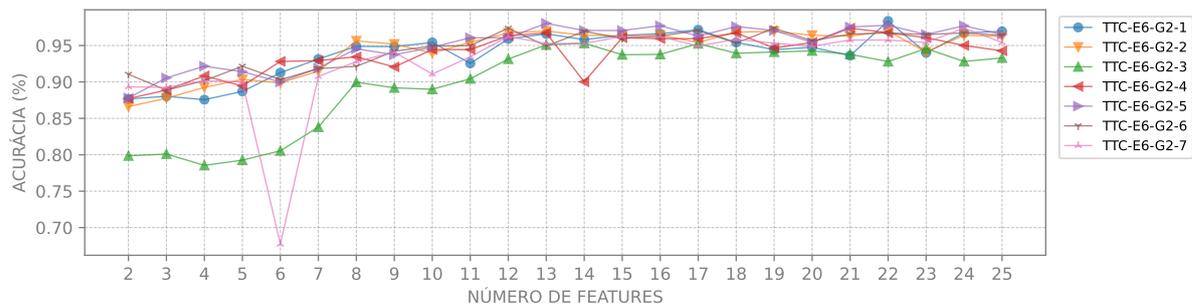
Nas Figuras apresentadas, constatam-se oscilações marcantes nos resultados a partir das técnicas de normalização utilizadas. Estas exerceram influências variadas, tanto de maneira benéfica quanto adversa, de forma similar ao que foi observado no ensaio E5-G1. No entanto, ficou evidente que os desempenhos dos modelos foram potencializados. As melhores configurações de E6-G2 resultaram em acurácias que superaram os 95%, alcançando 99.67% no melhor cenário, no qual o modelo cometeu apenas um erro de classificação.

Figura 120 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada SSC. O número de *features* é dado pela ordem de extração das IMFs.



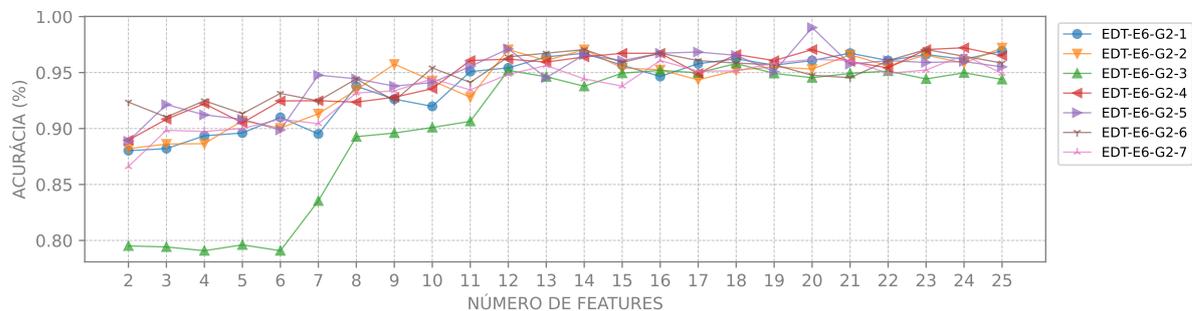
Fonte: Produzido pelo autor.

Figura 121 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada TTC. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

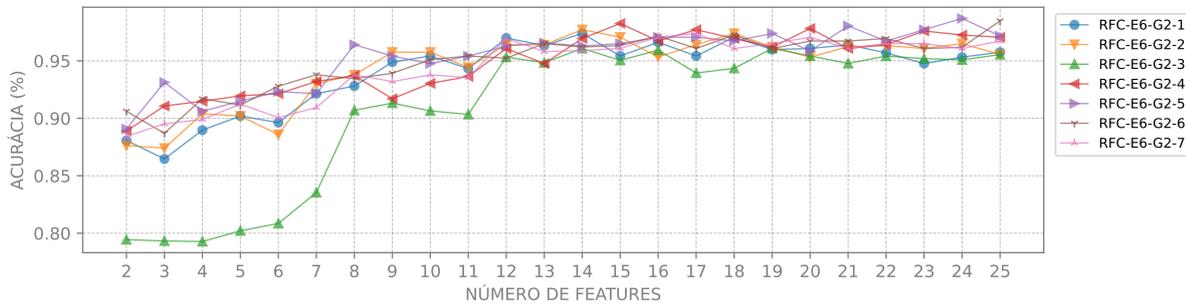
Figura 122 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada EDT. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

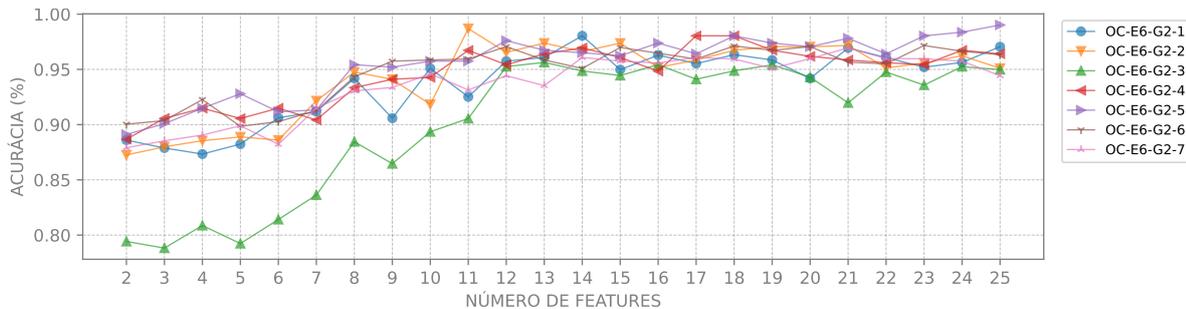
Em certas situações, como no caso de SD-E6-G2-1 (18 fts), a normalização potencializou a estrutura inerente dos dados, propiciando uma classificação mais acertada (acurácia de 99.67% no caso mencionado). No entanto, em outros contextos, como observado em TTC-E6-G2-7 (6 fts), as conexões essenciais entre as *features* foram possivelmente

Figura 123 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada RFC. O número de *features* é dado pela ordem de extração das IMFs.



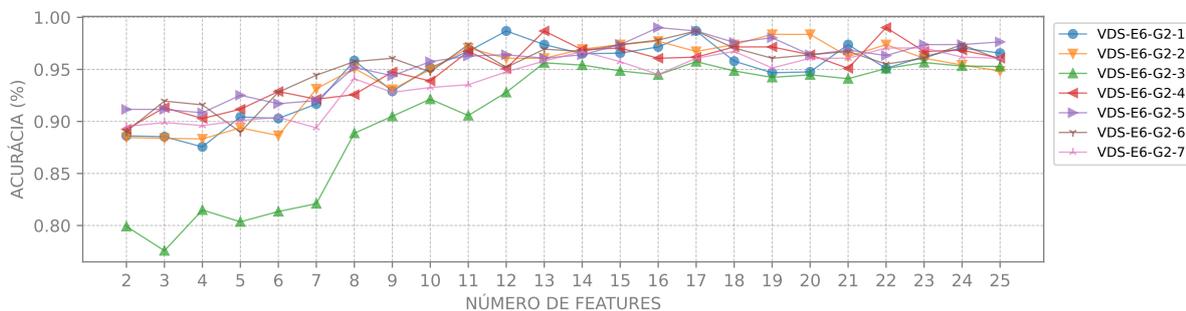
Fonte: Produzido pelo autor.

Figura 124 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada OC. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

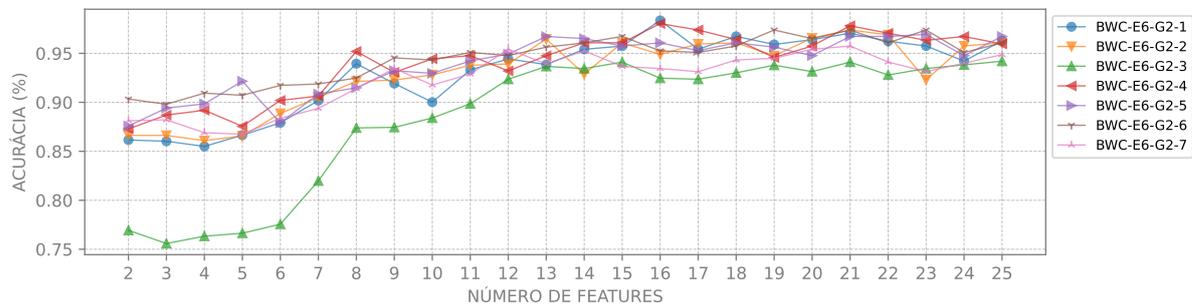
Figura 125 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada VDS. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

obscurecidas, levando a performances abaixo do esperado (acurácia de 67.5% para o caso mencionado). Estas variações de resultados, assim como no ensaio anterior, reforçam a premissa de que a escolha criteriosa da técnica de normalização é vital para maximizar as performances dos modelos classificadores.

Figura 126 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E6-G2 para o critério de parada BWC. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

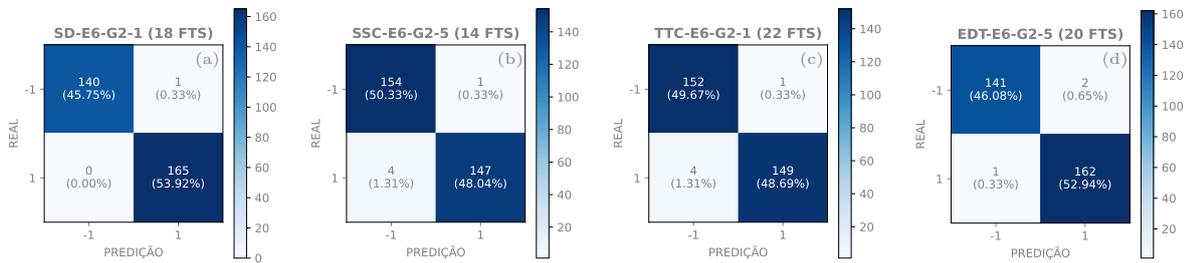
A configuração E6-G2-3 provocou uma redução no desempenho dos modelos para todos os critérios de parada, sugerindo que a transformação a que os vetores foram submetidos pode ter obscurecido características fundamentais dos respectivos sinais. Em tais circunstâncias, as acurácias alcançaram, de forma geral, valores superiores a 90% apenas quando se considerou 11 ou mais *features*. Em contraste, nas outras configurações, todos os critérios de parada conseguiram superar esta marca com apenas duas *features*, pelo menos para uma das técnicas de normalização.

Corroborando com os resultados de E5-G1, observou-se que determinadas técnicas de normalização resultaram em desempenhos equivalentes ou superiores quando associadas a um número distinto de *features*, seja em quantidades maiores ou menores. Esse fenômeno sugere que a eficácia de uma técnica de normalização pode estar relacionada à dimensionalidade dos dados. Como mencionado anteriormente, este aspecto destaca a relevância de uma avaliação metódica da interação entre a técnica de normalização empregada e a dimensionalidade do conjunto de dados no processo de otimização dos modelos. Estudos nessa direção foram realizados com a utilização da PFE para redimensionar os vetores através das melhores combinações de *features*, conservando apenas as de maior relevância. Tais resultados estão detalhados no próximo ensaio deste grupo.

Nas Figuras 127 e 128, são apresentadas as MCs referentes aos resultados dos modelos que exibiram melhores desempenhos nos testes para cada critério de parada. Observa-se, como mencionado anteriormente, que a configuração SD-E6-G2-1 (18 fts) obteve o melhor desempenho neste ensaio, classificando erroneamente apenas uma instância de 306 avaliadas.

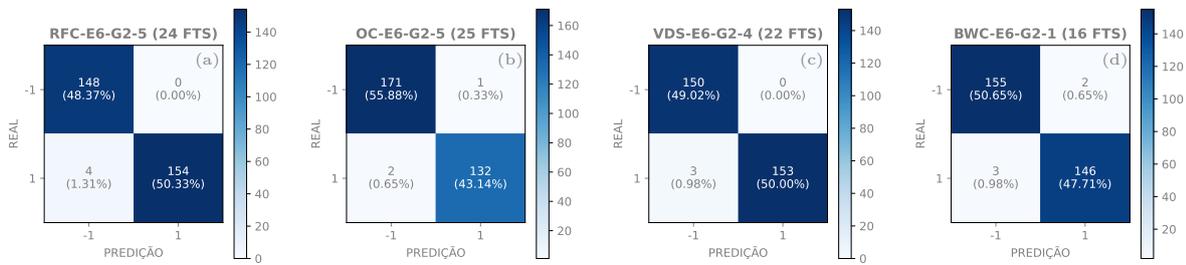
Os hiperparâmetros determinados para os modelos de melhor desempenho, bem como as métricas acurácia, precisão, *recall*, *F1-score* e AUC, estão detalhados na Tabela 34. Os modelos alcançaram um AUC mínimo de 0.96, no caso SSC-E6-G2-3 (12 fts), atingindo 1.00 em vários outros. As configurações que proporcionaram o melhor desempenho, em

Figura 127 – MCs das melhores configurações em E6-G2 para os critérios de parada SD, SSC, TTC e EDT. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.



Fonte: Produzido pelo autor.

Figura 128 – MCs das melhores configurações em E6-G2 para os critérios de parada RFC, OC, VDS e BWC. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.



Fonte: Produzido pelo autor.

termos de acurácia e $F1$ -score, para cada critério de parada estão destacadas na Tabela 34. Priorizou-se novamente o $F1$ -score máximo, conforme descrito anteriormente.

Com base nas análises e tendo em vista os resultados apresentados nas Tabelas 28 e 34, conclui-se que vetores definidos no formato F2 possibilitam uma melhoria significativa no desempenho do sistema. Além disso, os resultados do módulo MPFE se mantiveram consistentes com os apresentados em E5-G1, indicando que a aplicação de uma técnica específica de normalização pode evidenciar a estrutura dos dados. A obtenção de acurácias e $F1$ -scores que superaram 99% indica que as melhores configurações exibiram desempenhos superiores aos dos ensaios anteriores.

Conclui-se que o sistema proposto, com vetores de *features* no formato F2, demonstra eficácia mesmo quando se empregam sinais de curta duração com uma taxa de amostragem reduzida, desde que satisfaça o Teorema de Nyquist. A utilização de parâmetros mais flexíveis para a EMD e a robustez e precisão evidenciadas nos testes dos modelos, que se mostraram satisfatórios com diferentes técnicas de normalização, consolidam a hipótese inicialmente proposta nesta subsecção.

Tabela 34 – Melhores resultados em E6-G2. As configurações destacadas são as que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada. O termo “Poly” refere-se ao *kernel* Polinomial.

Configuração	Num. features	Amostras treino (%)	C	γ	Kernel	Acurácia	Precisão	Recall	F1-score	AUC
SD-E6-G2-1	18	80	1000.0	10.0	RBF	0.99673	0.99398	1.00000	0.99698	1.00
SSC-E6-G2-1	19	80	1000.0	10.0	RBF	0.97712	0.97917	0.97241	0.97578	1.00
TTC-E6-G2-1	22	80	0.001	100.0	Poly	0.98366	0.99333	0.97386	0.98350	0.99
EDT-E6-G2-1	25	70	1000.0	10.0	RBF	0.96943	0.96957	0.96957	0.96957	0.99
RFC-E6-G2-1	14	80	0.001	100.0	Poly	0.97386	0.99333	0.95513	0.97386	0.99
OC-E6-G2-1	14	80	0.001	100.0	Poly	0.98039	0.98758	0.97546	0.98148	0.99
VDS-E6-G2-1	12	80	0.001	100.0	Poly	0.98693	1.00000	0.97484	0.98726	0.98
BWC-E6-G2-1	16	80	1000.0	10.0	RBF	0.98366	0.98649	0.97987	0.98316	0.99
SD-E6-G2-2	17	80	1000.0	10.0	RBF	0.98693	0.99310	0.97959	0.98630	0.99
SSC-E6-G2-2	25	80	0.001	100.0	Poly	0.97712	0.99338	0.96154	0.97720	1.00
TTC-E6-G2-2	13	50	1000.0	1	RBF	0.96986	0.98953	0.95214	0.97047	0.99
EDT-E6-G2-2	25	60	0.01	100.0	Poly	0.97218	0.98693	0.95873	0.97262	0.98
RFC-E6-G2-2	14	80	1000.0	10.0	RBF	0.97712	0.97333	0.97987	0.97659	0.99
OC-E6-G2-2	11	80	1000.0	1	RBF	0.98693	1.00000	0.97500	0.98734	0.99
VDS-E6-G2-2	19	80	1000.0	1	Poly	0.98366	0.99254	0.97080	0.98155	0.99
BWC-E6-G2-2	21	80	1000.0	10.0	RBF	0.97386	0.97368	0.97368	0.97368	0.98
SD-E6-G2-3	17	50	100.0	1	Poly	0.95806	0.97548	0.93963	0.95722	0.97
SSC-E6-G2-3	12	40	100.0	0.1	RBF	0.94978	0.99310	0.90947	0.94945	0.96
TTC-E6-G2-3	14	40	1	1	RBF	0.95306	0.98420	0.92373	0.95301	0.97
EDT-E6-G2-3	18	50	100.0	1	RBF	0.95806	0.98596	0.92857	0.95640	0.98
RFC-E6-G2-3	14	80	100.0	1	RBF	0.96078	0.98582	0.93289	0.95862	0.97
OC-E6-G2-3	13	70	1	1	RBF	0.95633	0.98598	0.92544	0.95475	0.96
VDS-E6-G2-3	17	60	100.0	0.1	RBF	0.95745	0.99658	0.92089	0.95724	0.97
BWC-E6-G2-3	25	30	100.0	0.1	RBF	0.94200	0.98174	0.90130	0.93981	0.96
SD-E6-G2-4	16	30	100.0	1	RBF	0.96913	0.97500	0.96205	0.96848	0.99
SSC-E6-G2-4	23	70	1000.0	1	RBF	0.97817	0.97748	0.97748	0.97748	0.99
TTC-E6-G2-4	21	80	1000.0	1	RBF	0.97386	0.99351	0.95625	0.97452	0.98
EDT-E6-G2-4	24	60	100.0	1	Poly	0.97218	0.98013	0.96417	0.97209	0.97
RFC-E6-G2-4	15	70	100.0	1	Poly	0.98253	0.99573	0.97083	0.98312	0.99
OC-E6-G2-4	17	80	1000.0	1	RBF	0.98039	0.98601	0.97241	0.97917	1.00
VDS-E6-G2-4	22	80	1000.0	1	RBF	0.99020	1.00000	0.98077	0.99029	0.99
BWC-E6-G2-4	16	80	1000.0	1	RBF	0.98039	1.00000	0.96000	0.97959	0.98
SD-E6-G2-5	16	80	100.0	10.0	RBF	0.97386	0.99333	0.95513	0.97386	0.98
SSC-E6-G2-5	14	80	1000.0	10.0	RBF	0.98366	0.99324	0.97351	0.98328	1.00
TTC-E6-G2-5	13	80	1000.0	10.0	RBF	0.98039	0.98052	0.98052	0.98052	0.99
EDT-E6-G2-5	20	80	100.0	1	Poly	0.99020	0.98780	0.99387	0.99083	1.00
RFC-E6-G2-5	24	80	100.0	1	Poly	0.98693	1.00000	0.97468	0.98718	0.99
OC-E6-G2-5	25	80	1000.0	10.0	RBF	0.99020	0.99248	0.98507	0.98876	1.00
VDS-E6-G2-5	16	80	100.0	1	Poly	0.99020	1.00000	0.98125	0.99054	1.00
BWC-E6-G2-5	23	70	1000.0	10.0	RBF	0.96943	0.98760	0.95600	0.97154	0.99
SD-E6-G2-6	20	70	1000.0	1000.0	RBF	0.98035	0.99574	0.96694	0.98113	0.99
SSC-E6-G2-6	20	80	1000.0	1000.0	RBF	0.97712	0.97203	0.97887	0.97544	0.99
TTC-E6-G2-6	12	80	1000.0	1000.0	RBF	0.97386	0.99338	0.95541	0.97403	0.99
EDT-E6-G2-6	14	80	1000.0	1000.0	RBF	0.97059	0.97810	0.95714	0.96751	0.99
RFC-E6-G2-6	25	70	1000.0	1000.0	RBF	0.98472	0.97826	0.99119	0.98468	0.99
OC-E6-G2-6	23	70	1000.0	100.0	RBF	0.97162	0.99130	0.95397	0.97228	0.99
VDS-E6-G2-6	17	80	1000.0	1000.0	RBF	0.98693	0.97945	0.99306	0.98621	1.00
BWC-E6-G2-6	19	80	1000.0	1000.0	RBF	0.97386	0.97419	0.97419	0.97419	0.98
SD-E6-G2-7	23	80	1000.0	1000.0	RBF	0.96405	0.99286	0.93289	0.96194	0.99
SSC-E6-G2-7	22	70	1000.0	1000.0	RBF	0.96943	1.00000	0.94142	0.96983	0.99
TTC-E6-G2-7	24	80	1000.0	1000.0	RBF	0.97386	0.98611	0.95946	0.97260	1.00
EDT-E6-G2-7	24	60	1000.0	1000.0	RBF	0.96563	1.00000	0.92833	0.96283	0.98
RFC-E6-G2-7	17	80	1000.0	1000.0	RBF	0.97386	0.98765	0.96386	0.97561	0.99
OC-E6-G2-7	21	70	1000.0	1000.0	RBF	0.96943	0.99524	0.94144	0.96759	0.99
VDS-E6-G2-7	22	80	1000.0	1000.0	RBF	0.97059	0.98529	0.95035	0.96751	1.00
BWC-E6-G2-7	21	80	1000.0	1000.0	RBF	0.95752	1.00000	0.91391	0.95502	0.99

Fonte: Elaborada pelo autor.

No próximo ensaio, exploram-se combinações entre as *features*, selecionando aquelas que determinam as menores distâncias de P ao VO para formar os conjuntos a serem analisados. Tal abordagem é coerente no contexto dos vetores definidos no formato F2, pois as FIs das componentes dos sinais orientam as distribuições das energias nos vetores, diferentemente dos vetores no formato F1, como discutido na [seção 3.1](#). Espera-se que tal abordagem amplie a capacidade do modelo de discernir padrões sutis e complexos nos dados, contribuindo para aprimorar ainda mais a precisão e a confiabilidade das classificações realizadas.

4.2.2.2 Experimento E7

Nos ensaios precedentes, o número k de *features* oscilou no grupo G1 de 2 até M , enquanto no ensaio E6-G2, a variação ocorreu entre 2 e 25, sempre considerando-se as primeiras k *features*. A hipótese para esta fase é que, as 25 *features* combinadas de k em k , com k variando de 2 a 25, possibilitem reduzir as distâncias dos pontos P aos VOs. Além disso, supõem-se que, ao considerar-se as combinações mais promissoras sugeridas pela análise PFE, possa-se obter acurácias equiparáveis às obtidas em E6-G2 e reforçar a capacidade de generalização dos melhores modelos, reduzindo assim o número de amostras necessárias para treinamento.

Neste contexto, o experimento E7 foi realizado com sinais derivados dos sinais originais, os quais foram capturados a uma taxa de amostragem de 44.1 kHz e 16 bits de quantização. Foram consideradas duração e taxa de amostragem de 1 segundo e 6 kHz, respectivamente, para cada sinal. No tratamento via EMD, aplicaram-se os 8 critérios de parada e estipulou-se um máximo de 700 iterações por IMF. Os vetores de *features* foram definidos no formato F2 e passaram por um processo de normalização utilizando as técnicas MN, MMN e LS, descritas na [seção 2.5](#). Para a técnica MMN, realizou-se o reescalonamento das *features* para o intervalo $[0, 1]$, definindo $a = 0$ e $b = 1$. Por outro lado, para a técnica LS, exploraram-se cinco variações do coeficiente v , sendo $v \in \{0.01, 0.1, 1, 10, 100\}$. Os parâmetros específicos, associados a cada critério de parada, seguem os mais flexíveis adotados nos ensaios E4 e E5 do grupo G1. A única exceção é para o critério BWC, cuja configuração é derivada de E3-G1-3. As configurações investigadas neste experimento são idênticas às de E6-G2 e estão disponíveis na [Tabela 33](#), portanto, os rótulos de E7-G2 correspondem aos seus respectivos em E6-G2. Por exemplo, SD-E7-G2-3 corresponde a SD-E6-G2-3.

E7-G2: Resultados do Módulo MEF

Para o experimento E7-G2, os resultados obtidos no módulo MEF são consistentes com aqueles de E5-G1 e E6-G2. Especificamente, os resultados coincidem com os de E4-G1-1 para o critério SSC, com E3-G1-3 para o critério BWC e com E4-G1-2 para os demais critérios. Esta consistência deve-se ao fato de que a particularidade deste ensaio está na seleção combinada das *features* dos vetores, os quais foram definidos nos ensaios anteriores.

E7-G2: Resultados do Módulo MNF

Tal como observado no módulo MEF, os resultados do módulo MNF são consistentes com os registrados em E6-G2. Esta consonância pode ser atribuída à particularidade deste

ensaio, que reside na seleção combinada das *features* dos vetores, sem alterar aqueles estabelecidos em ensaios anteriores.

E7-G2: Resultados do Módulo MPFE

Dando sequência à avaliação dos vetores, todos os conjuntos derivados das possíveis combinações de *features* foram submetidos ao módulo MPFE. Especificamente, consideraram-se as 25 *features* combinadas de k em k , com k inteiro variando entre 2 e 25, abrangendo todas as configurações. O número total de combinações possíveis para k *features*, expresso por $C(25, k)$, pode ser calculado pela [Equação \(4.5\)](#) (ARFKEN; WEBER, 2007).

$$C(25, k) = \frac{25!}{k!(25 - k)!} \quad (4.5)$$

A [Tabela 35](#) apresenta os valores correspondentes às $C(25, k)$ combinações possíveis para os conjuntos de k *features* avaliados. Para cada configuração indicada na [Tabela 33](#) foram examinadas 33 554 406 combinações, somando um total de 1 879 046 736 combinações avaliadas. A métrica para determinação dos melhores resultados foi a distância mínima entre o ponto P, que representa o conjunto avaliado, e o VO.

Tabela 35 – Número de combinações para 25 de k em k , onde $2 \leq k \leq 25$ e $k \in \mathbb{Z}$.

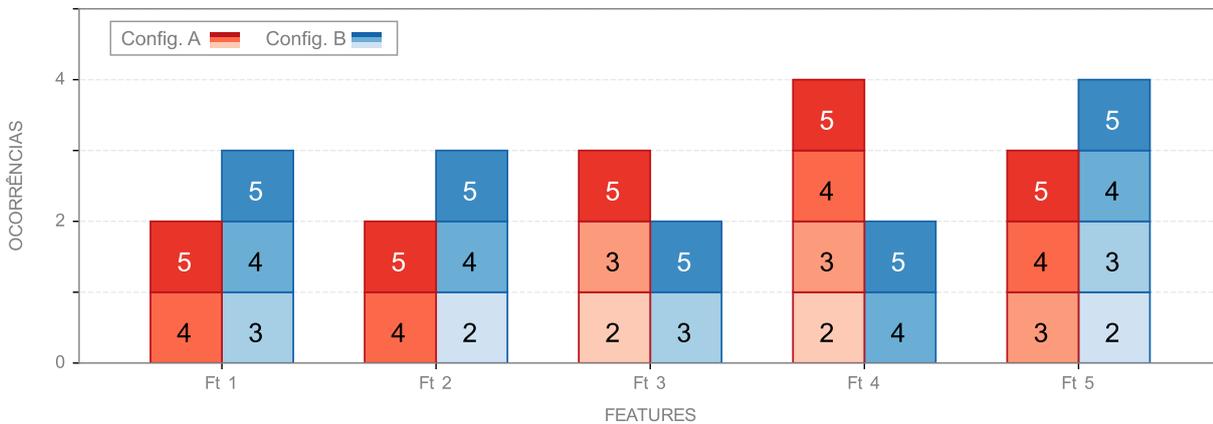
k	C(25, k)	k	C(25, k)
2	300	14	4 457 400
3	2 300	15	3 268 760
4	12 650	16	2 042 975
5	53 130	17	1 081 575
6	177 100	18	480 700
7	480 700	19	177 100
8	1 081 575	20	53 130
9	2 042 975	21	12 650
10	3 268 760	22	2 300
11	4 457 400	23	300
12	5 200 300	24	25
13	5 200 300	25	1

Fonte: Elaborada pelo autor.

Para as representações gráficas das combinações das *features*, propõe-se uma adaptação dos gráficos de barras, frequentemente utilizados em análises estatísticas (SHAH; HOEFFNER, 2002). A [Figura 129](#) apresenta um exemplo, construído de forma aleatória, no qual vetores com cinco *features* geram as combinações retratadas, levando em consideração duas configurações distintas. Cada grupo de barras evidencia uma *feature* específica. Individualmente, cada barra simboliza uma configuração, indicada por uma cor. Tons

mais suaves denotam um número menor de combinações, enquanto tons mais escuros correspondem a quantidades maiores de *features* combinadas. A altura de cada barra expressa o número de ocorrências de uma determinada *feature* ao longo das combinações mais eficazes de uma configuração específica. Por fim, os números inteiros k , presentes em cada quadrado, sinalizam o conjunto de vetores definido pela quantidade k de *features*, que o compõe, com k variando de 2 a 5.

Figura 129 – Exemplo gerado aleatoriamente onde vetores compostos por cinco *features* produzem as combinações ilustradas, considerando-se duas configurações distintas.



Fonte: Produzido pelo autor.

Dessa forma, neste exemplo, para as configurações A e B, as *features* representadas no eixo horizontal que apresentaram as maiores ocorrências (indicadas no eixo vertical) foram a quarta e quinta, respectivamente, ambas com quatro ocorrências. Os conjuntos formados por vetores definidos pelas combinações são organizados conforme a descrição a seguir:

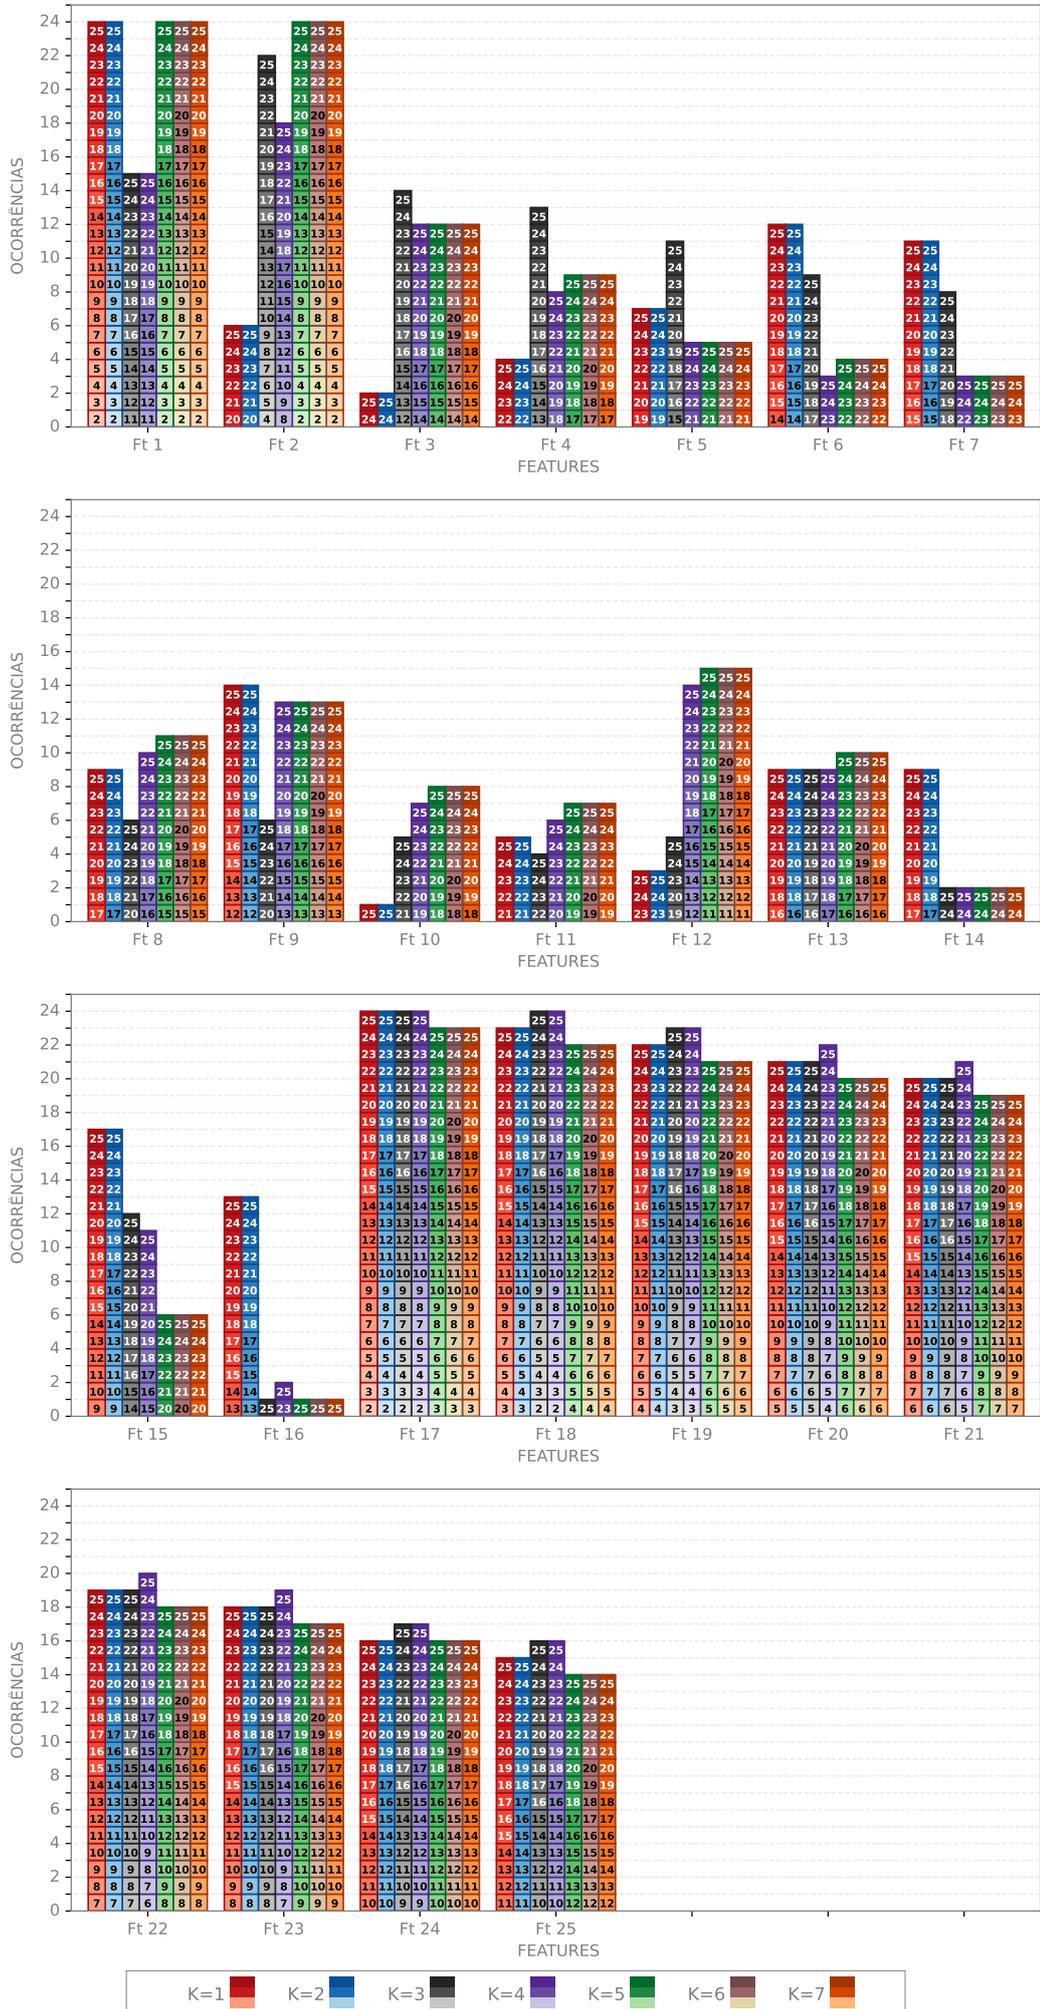
- Conjuntos compostos por vetores de 2 *features*:
 - Configuração A: fts 3 e 4.
 - Configuração B: fts 2 e 5.
- Conjuntos compostos por vetores de 3 *features*:
 - Configuração A: fts 3, 4 e 5.
 - Configuração B: fts 1, 3 e 5.
- Conjuntos compostos por vetores de 4 *features*:
 - Configuração A: fts 1, 2, 4 e 5.
 - Configuração B: fts 1, 2, 4 e 5.

- Conjuntos compostos por vetores de 5 *features*:
 - Ambas as configurações determinam um conjunto formado por vetores que envolvem todas as *features*.

Apresentam-se, nas Figuras 130 à 137, as combinações mais destacadas entre todas as avaliadas neste estudo, para todas as configurações indicadas na Tabela 33. Nota-se pela variação no número de ocorrências em cada grupo de barras, correspondente a cada *feature*, a influência das técnicas de normalização sobre a importância de cada *feature*. Para SD-E7-G2, por exemplo, a primeira *feature* constitui todos os melhores conjuntos de vetores, segundo a PFE, para as técnicas MN, MMN, LS(1), LS(10), LS(100) enquanto LS(0.01) e LS(0.1) influenciam esta mesma *feature*, em ambos os casos, a constituir apenas 15 das 24 variações com as melhores combinações. Este comportamento pode ser observado para todas as configurações avaliadas.

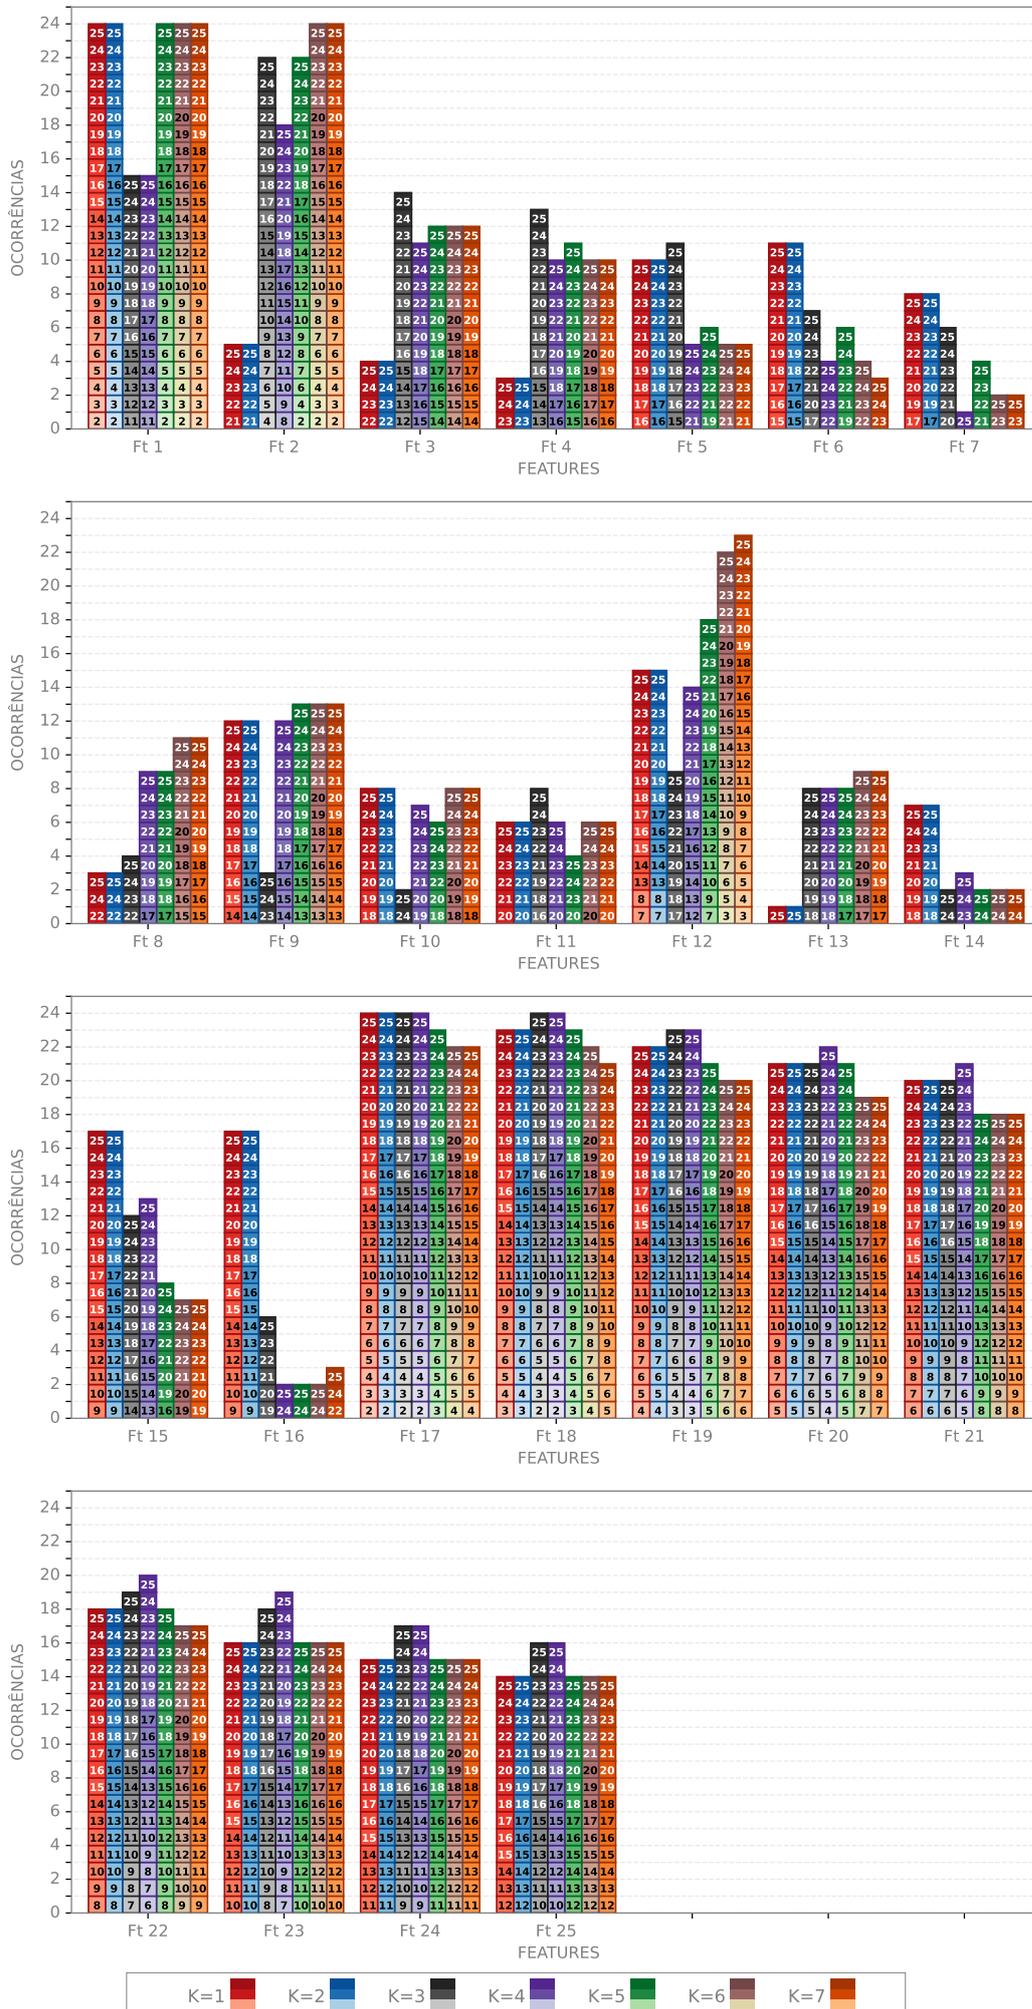
Analisando a Figura 104, que ilustra as *features* em média, que também representam SD-E7-G2, é natural esperar que as sete *features* mais influentes sejam a 1ª e da 8ª à 13ª, pois são as que estão em destaque nos gráficos de radar para todas as técnicas de normalização. Porém, na prática, ao executar o módulo PFE para as combinações, os resultados variam, atribuindo importância a outras *features*. Dentre as melhores combinações para sete *features* em SD-E7-G2, aparecem as 9 seguintes: 1ª, 2ª, 17ª à 23ª, conforme Figura 130. O mesmo comportamento pode ser observado para as outras configurações, que incluem da 17ª à 23ª, com algumas exceções, como SSC-E7-G2-{5, 6, 7} que incluem a 12ª; TTC-E7-G2-{5, 6, 7} incluem a 9ª e a 12ª; EDT-E7-G2-{5, 6, 7} incluem a 12ª; OC-E7-G2-{1, 2} incluem a 12ª; OC-E7-G2-{5, 6, 7} incluem a 9ª e a 12ª; VDS-E7-G2-{5, 6, 7} incluem a 12ª; BWC-E7-G2-{5, 6, 7} incluem a 8ª, 9ª e a 12ª.

Figura 130 – Melhores combinações de *features* em SD-E7-G2-K.



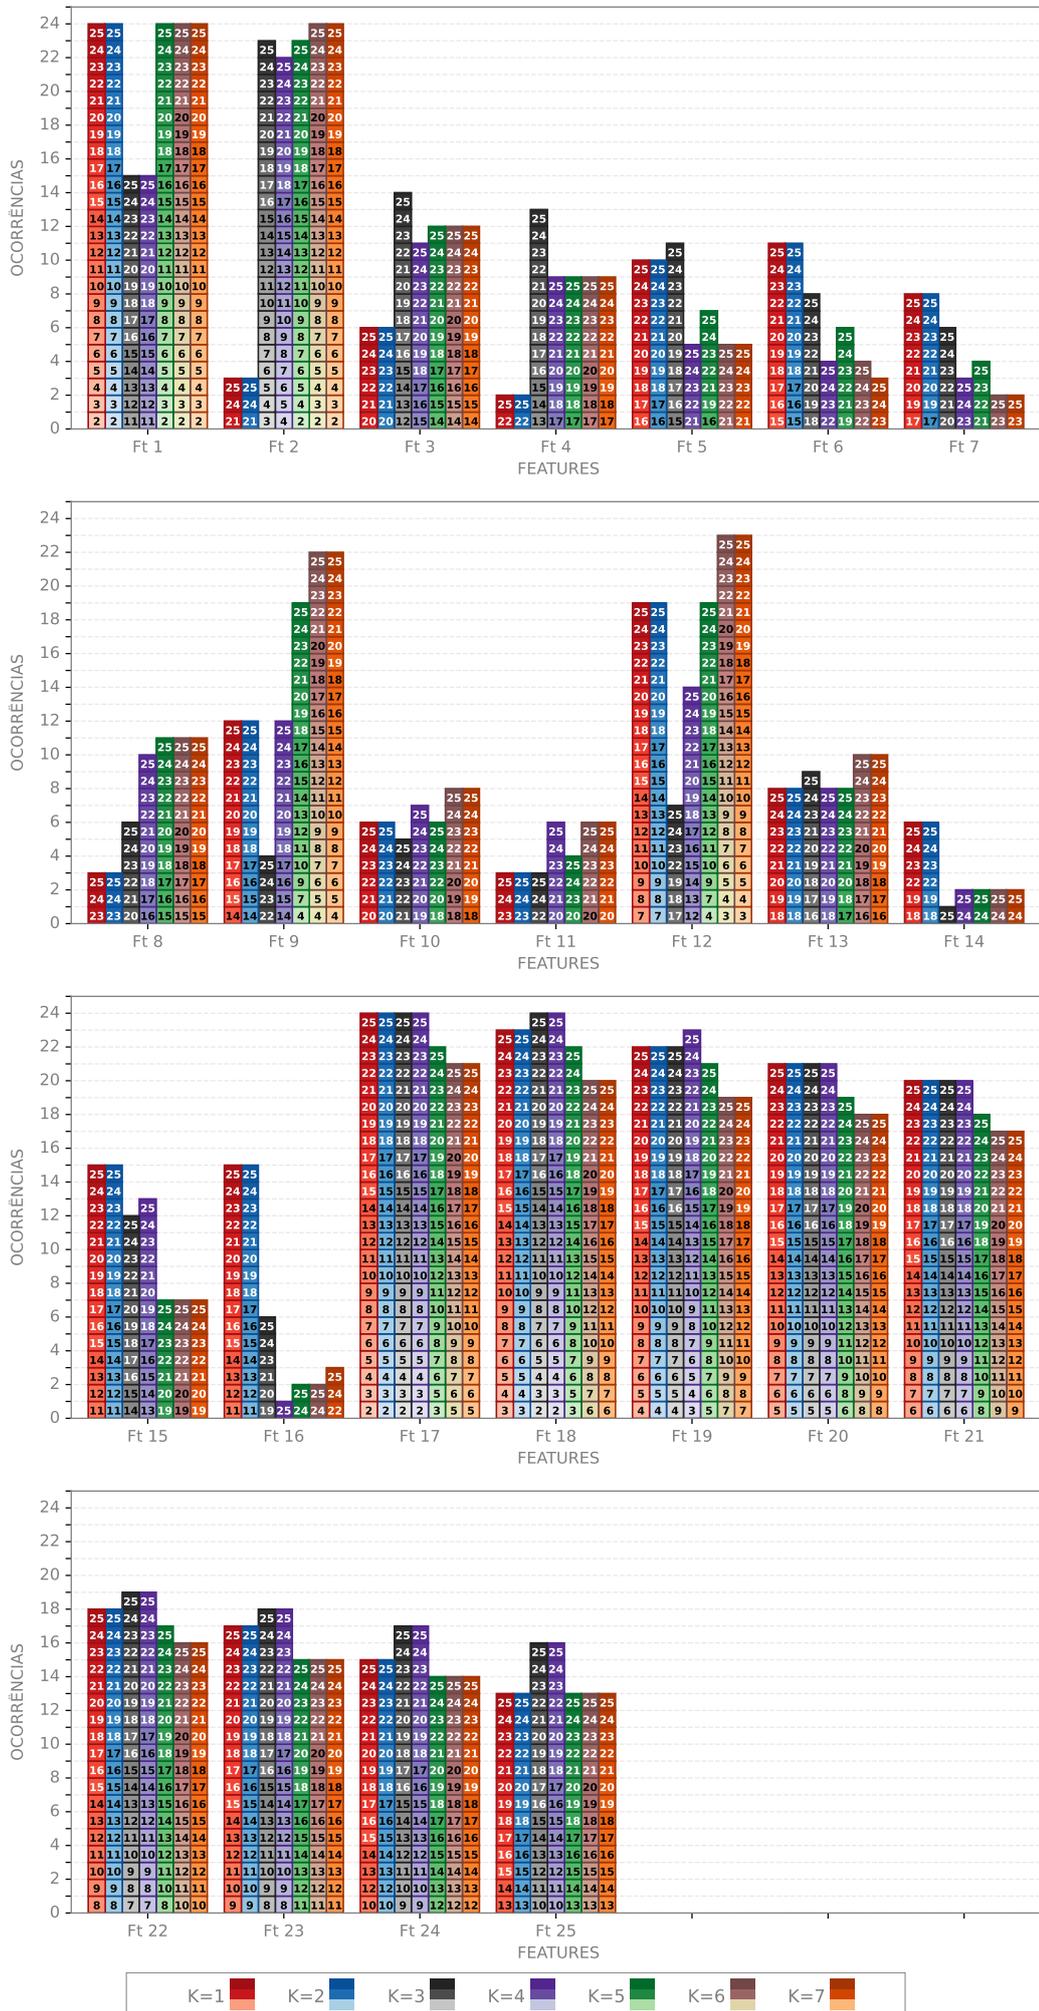
Fonte: Produzido pelo autor.

Figura 131 – Melhores combinações de *features* em SSC-E7-G2-K.



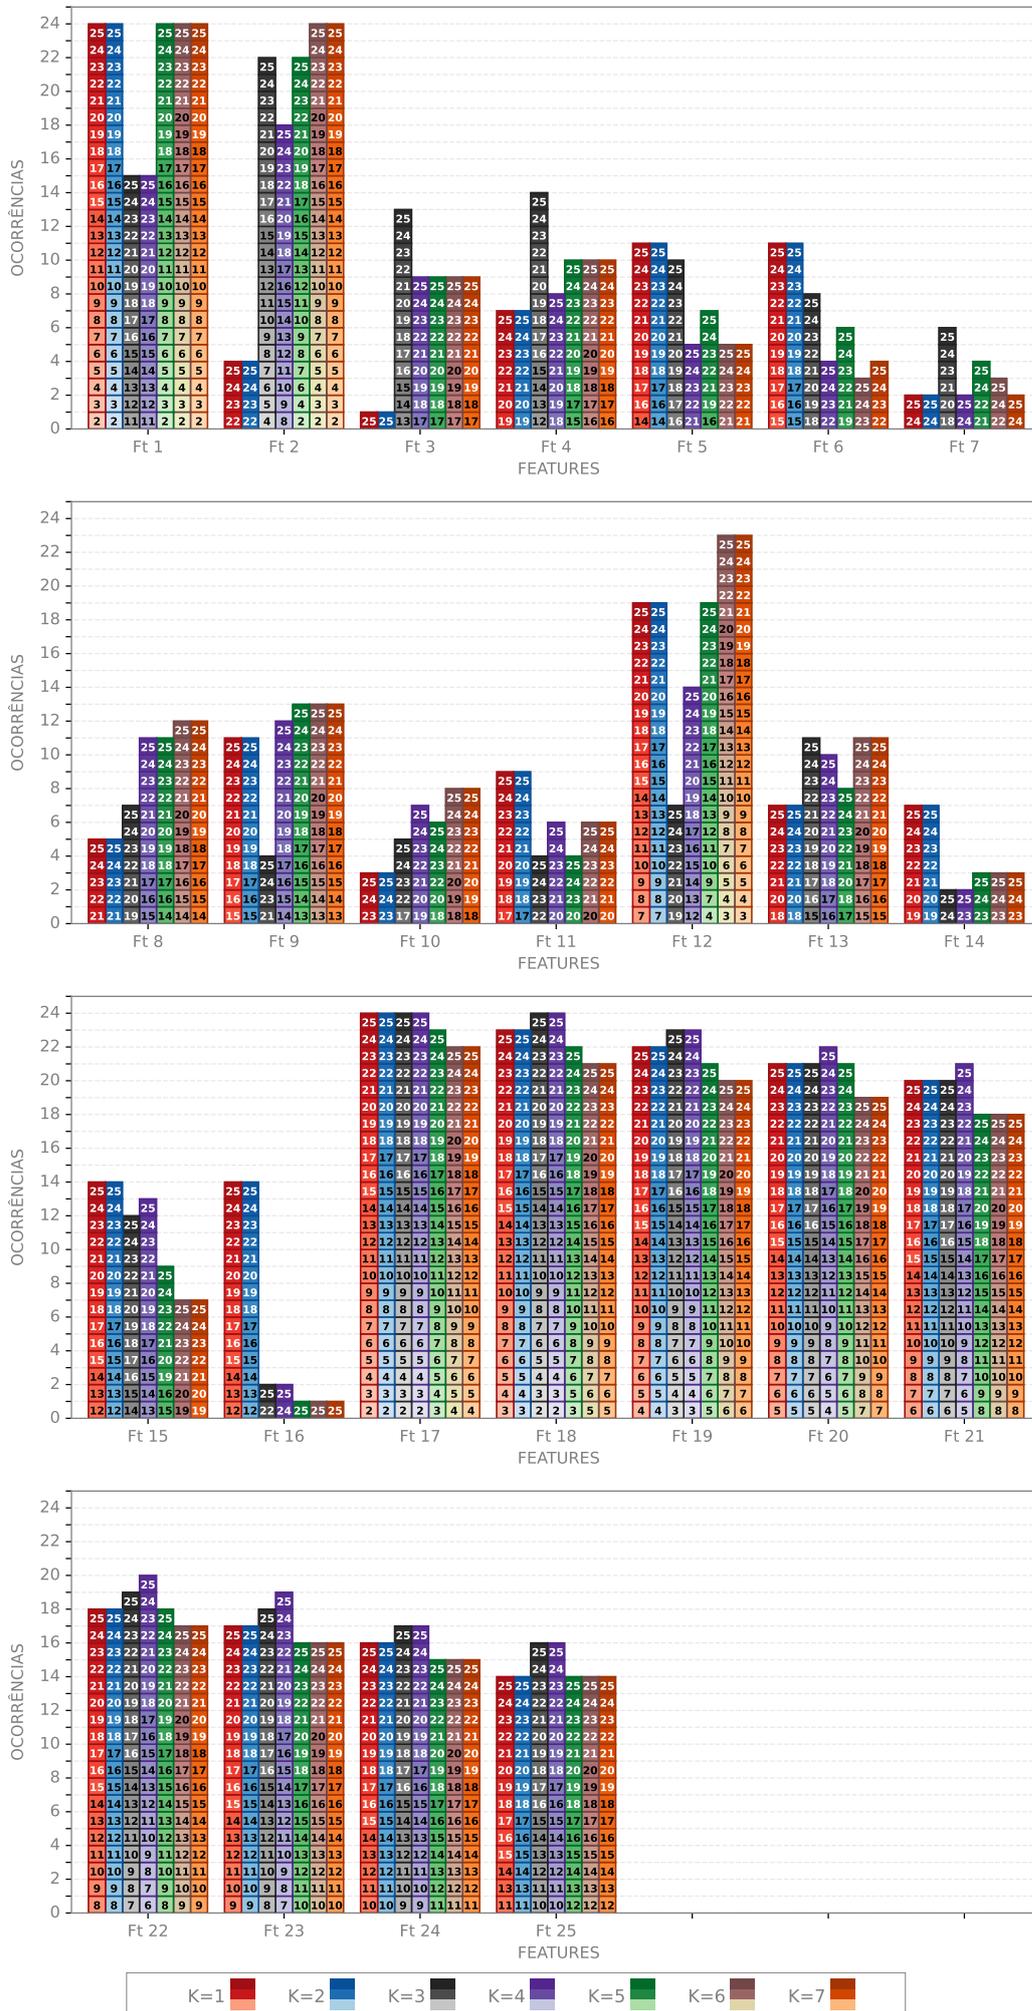
Fonte: Produzido pelo autor.

Figura 132 – Melhores combinações de *features* em TTC-E7-G2-K.



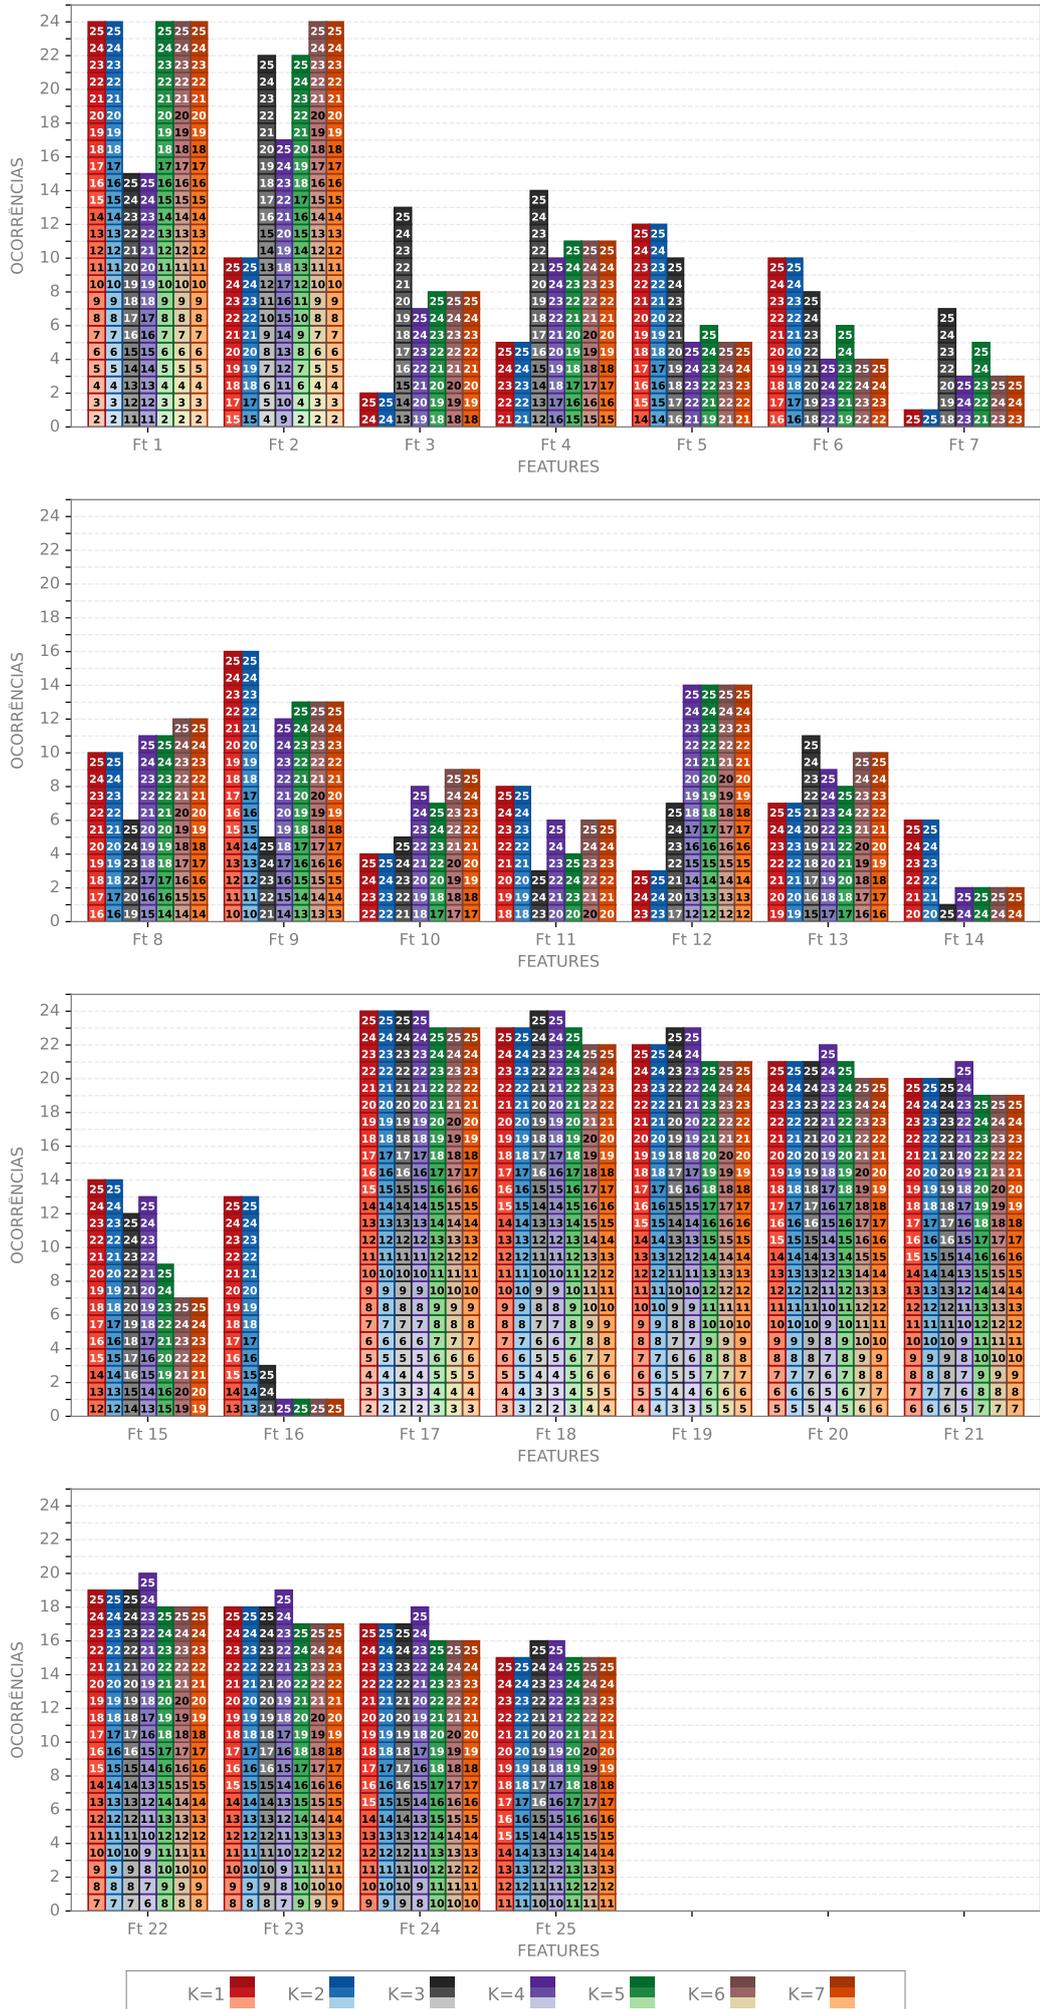
Fonte: Produzido pelo autor.

Figura 133 – Melhores combinações de *features* em EDT-E7-G2-K.



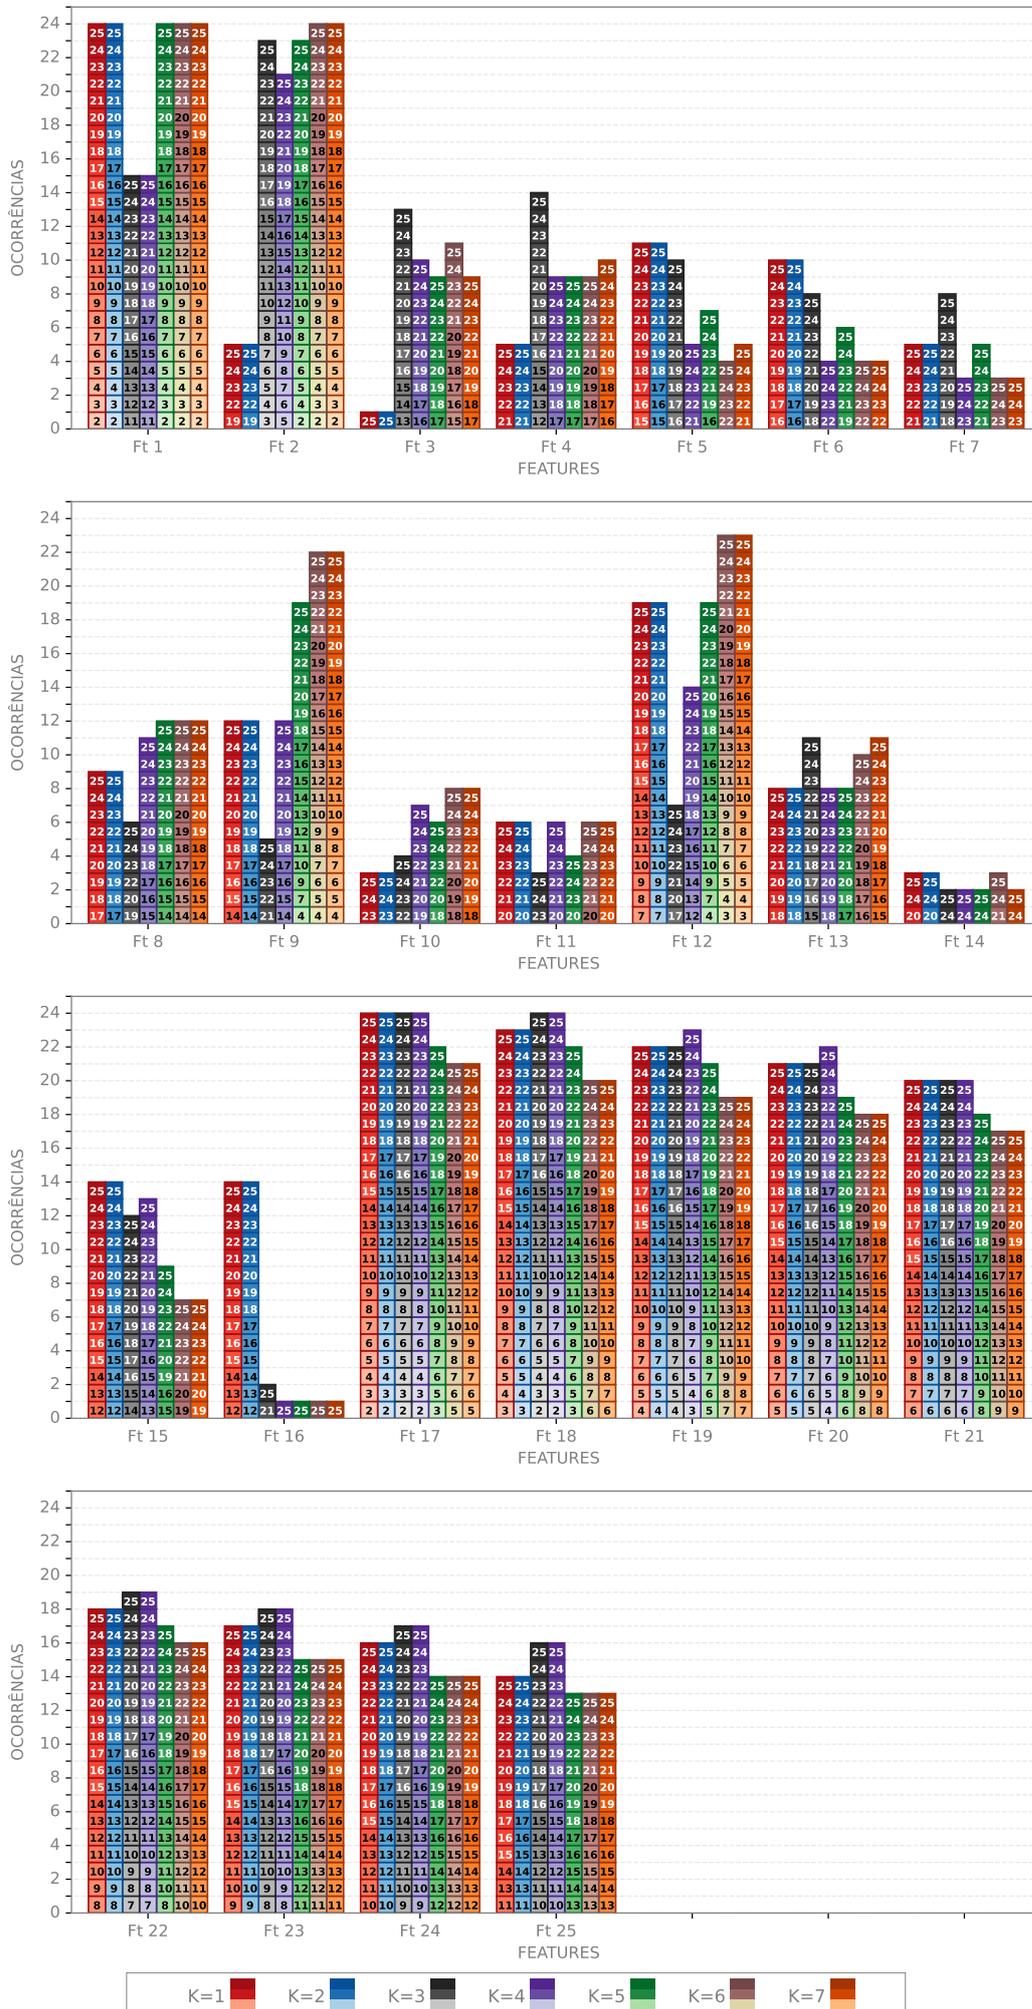
Fonte: Produzido pelo autor.

Figura 134 – Melhores combinações de *features* em RFC-E7-G2-K.



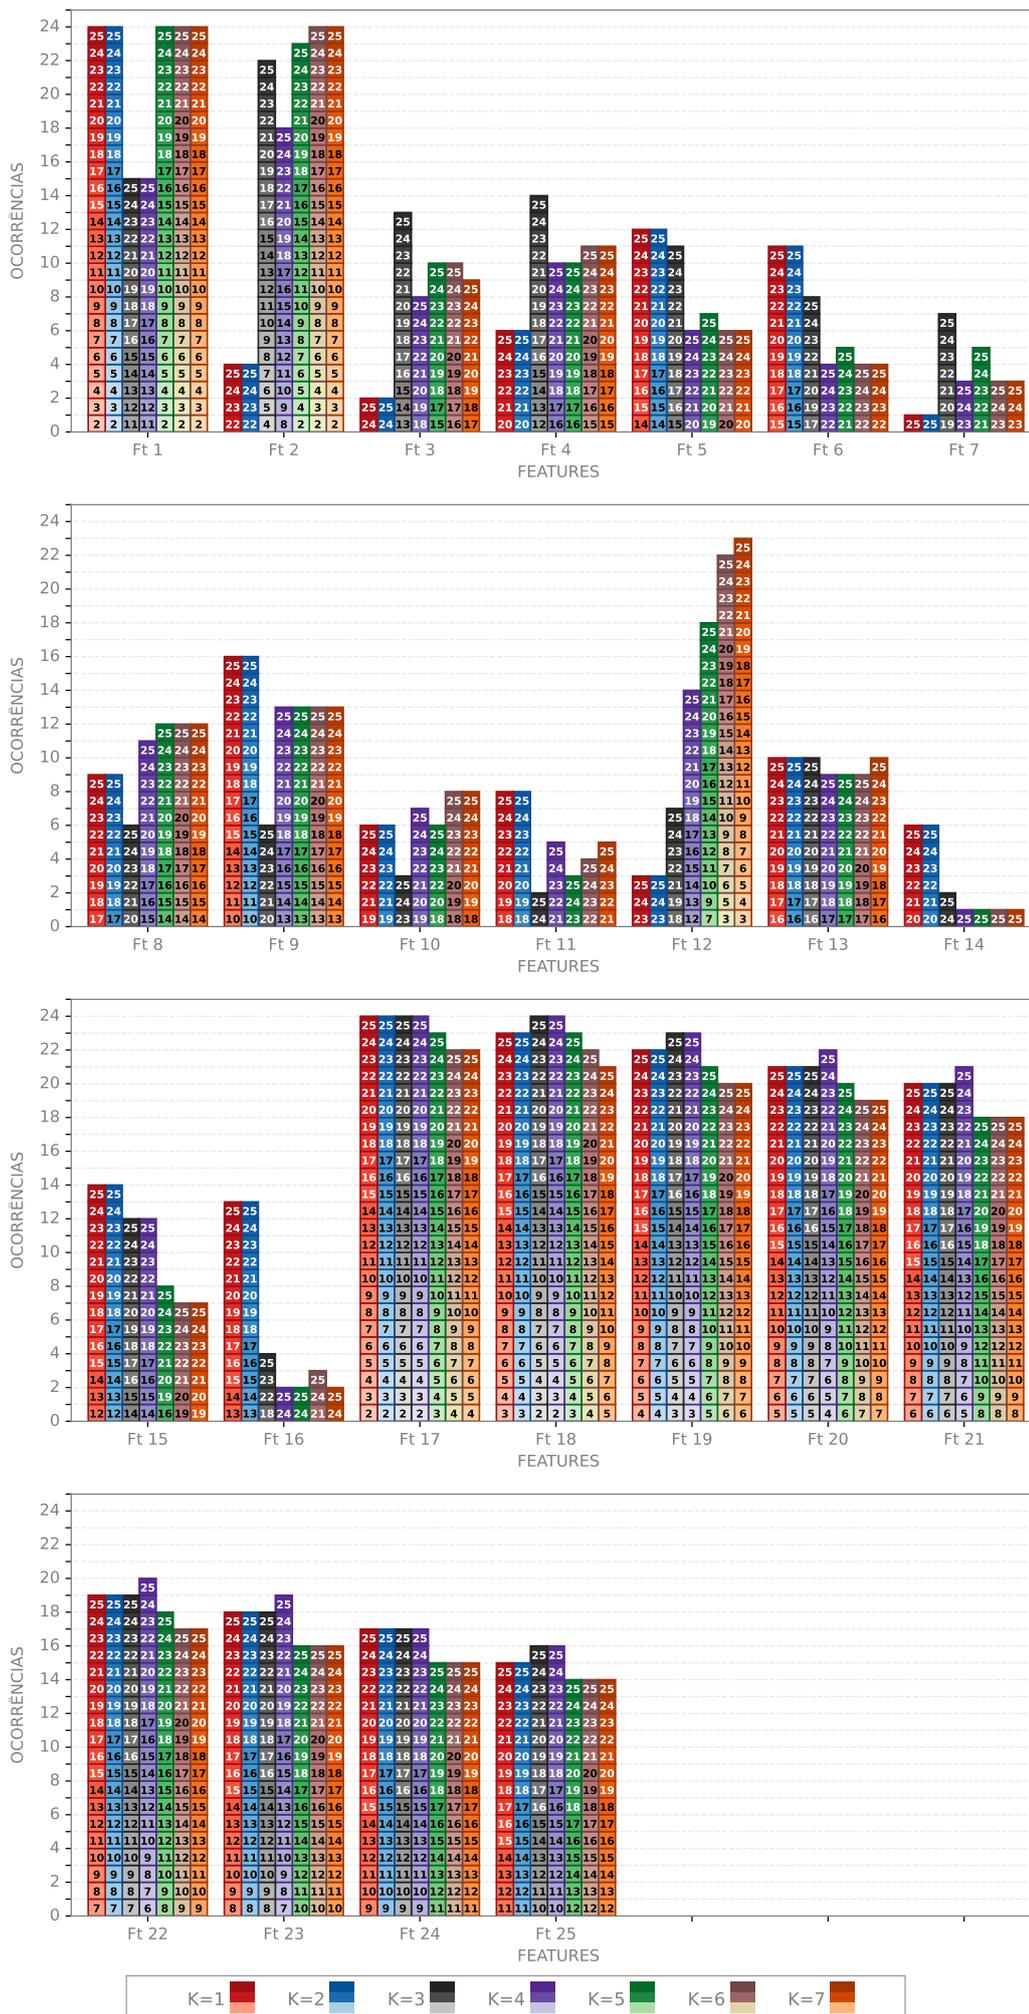
Fonte: Produzido pelo autor.

Figura 135 – Melhores combinações de *features* em OC-E7-G2-K.



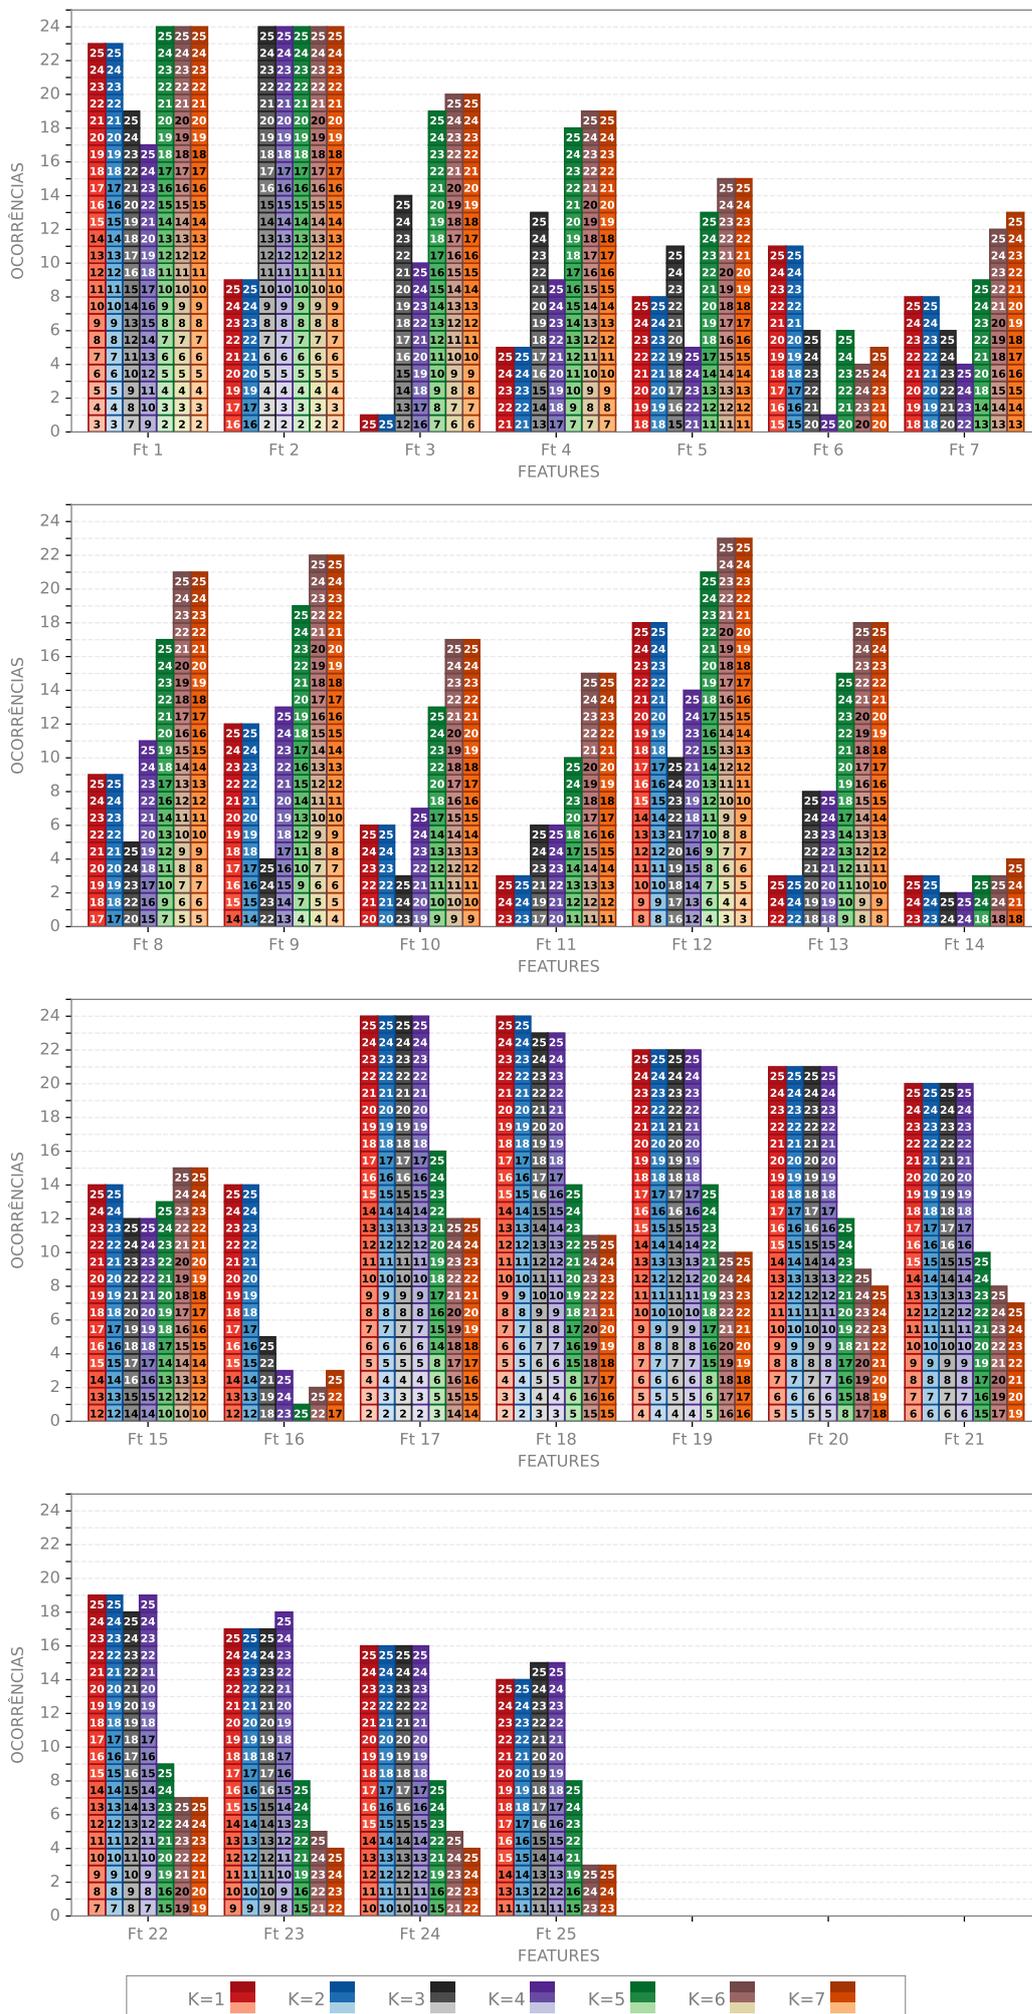
Fonte: Produzido pelo autor.

Figura 136 – Melhores combinações de *features* em VDS-E7-G2-K.



Fonte: Produzido pelo autor.

Figura 137 – Melhores combinações de *features* em BWC-E7-G2-K.



Fonte: Produzido pelo autor.

São 12 as *features* mais influentes, que constituem pelo menos 20 dos 24 melhores conjuntos advindos das combinações para alguma técnica de normalização e critério de parada, são: 1^a, 2^a, 3^a, 8^a, 9^a, 12^a, 17^a à 22^a; conforme Tabela 36.

Tabela 36 – *Features* que constituem pelo menos 20 dos 24 melhores conjuntos advindos das combinações de *features* para alguma técnica de normalização e critério de parada. As cores correspondem às configurações conforme Figuras 130 à 137.

	SD	SSC	TTC	EDT	RFC	OC	VDS	BWC
1	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■
2	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■
3								■ ■
4								
5								
6								
7								
8								■ ■
9			■ ■			■ ■		■ ■
10								
11								
12		■ ■	■ ■	■ ■		■ ■	■ ■	■ ■
13								
14								
15								
16								
17	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■
18	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■
19	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■
20	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■
21	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■
22	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■	■ ■ ■ ■ ■
23								
24								
25								

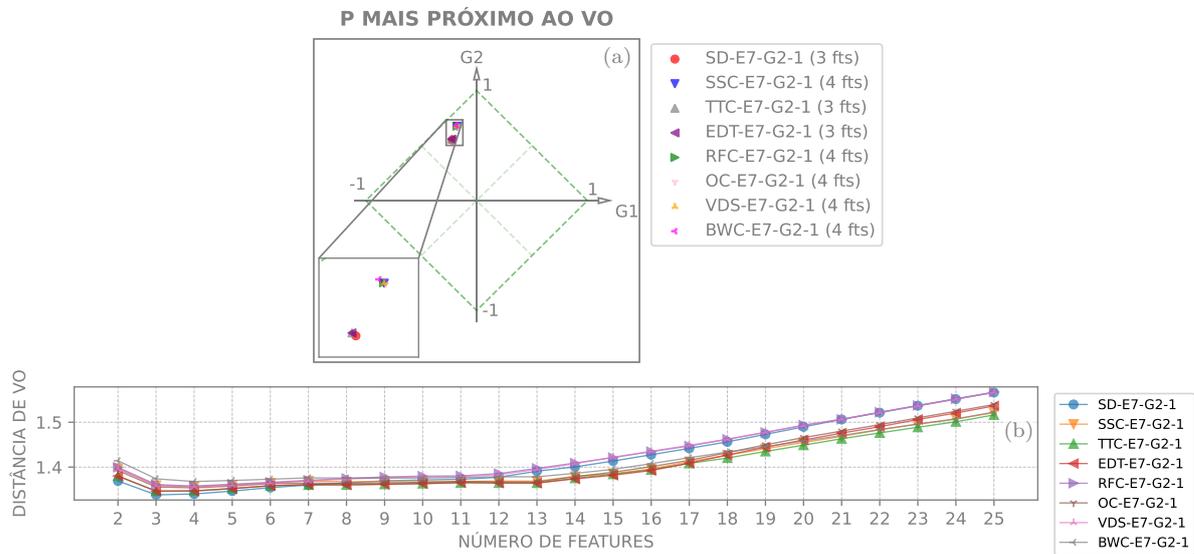
Fonte: Elaborada pelo autor.

As Figuras 138 à 144 destacam os melhores resultados para as configurações examinadas, bem como todas as distâncias ao VO referentes aos pontos P associados aos conjuntos de vetores em análise.

Observa-se que as configurações E7-G2-1 à E7-G2-4 alteraram de forma significativa os resultados em comparação a E6-G2-{1 a 4}, os pontos se mantêm no segundo quadrante, porém, próximos ao vértice (0, 1), conforme ilustrados nas Figuras 138 à 141. Este vértice corresponde à ambiguidade, ou seja, os resultados sugerem que existe uma notável similaridade entre os vetores intraclasse e interclasse. Os desempenhos mais notáveis aproximam-se de 1.1, atingindo exatamente esse valor para RFC-E7-G2-4 (2 a 10 fts).

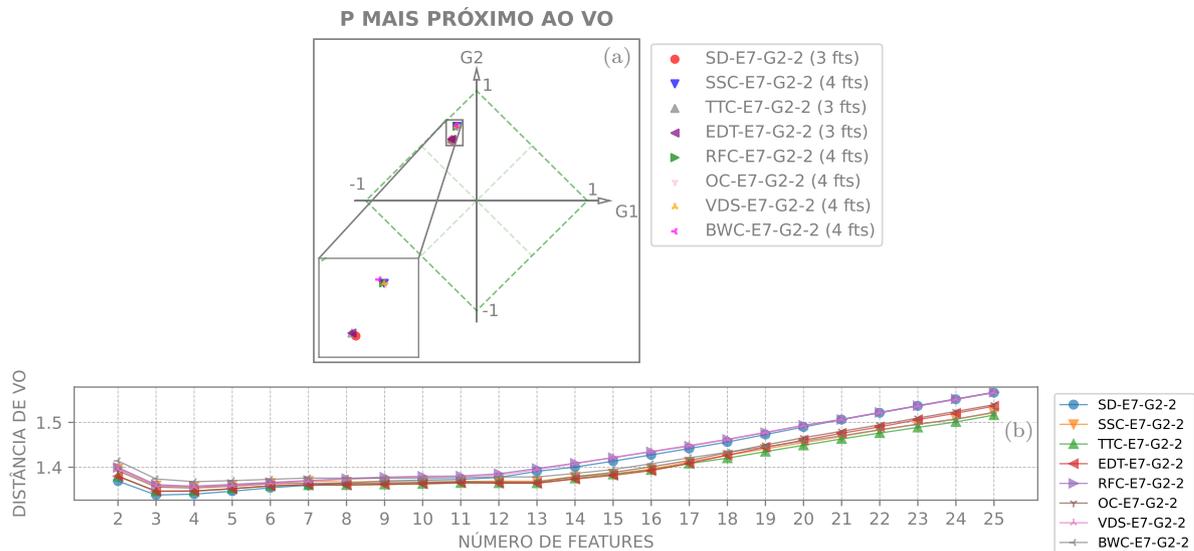
Em contraste, as configurações E7-G2-{5 a 7} reproduziram e melhoraram o efeito observado em E6-G2-{5 à 7}, onde os pontos se aproximaram do VO. Apesar de ainda situarem mais próximos do vértice (0, 1), que é referente à ambiguidade. Tal constatação indica que, nas condições avaliadas, apesar de existir uma notável similaridade entre os vetores intraclasse e interclasse, tais efeitos foram reduzidos, ampliando a qualidade

Figura 138 – Resumo dos resultados do módulo MPFE para E7-G2-1. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Figura 139 – Resumo dos resultados do módulo MPFE para E7-G2-2. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO.

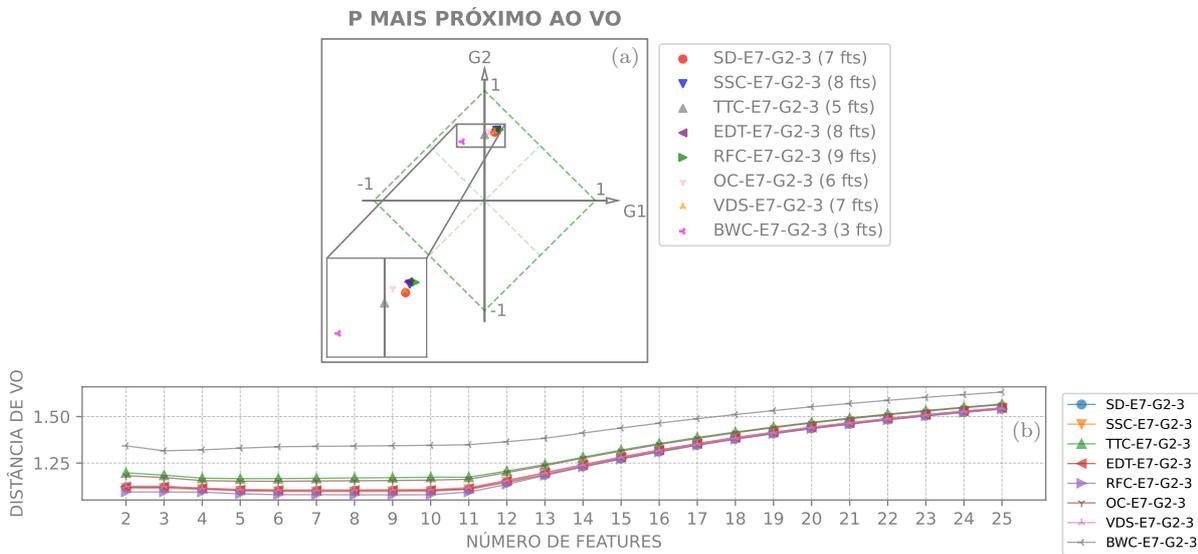


Fonte: Produzido pelo autor.

dos conjuntos analisados. Os desempenhos mais notáveis aproximam-se de 0.75, com destaque para SD-E7-G2-5 (2 fts), que representa o melhor resultado obtido em todos os experimentos.

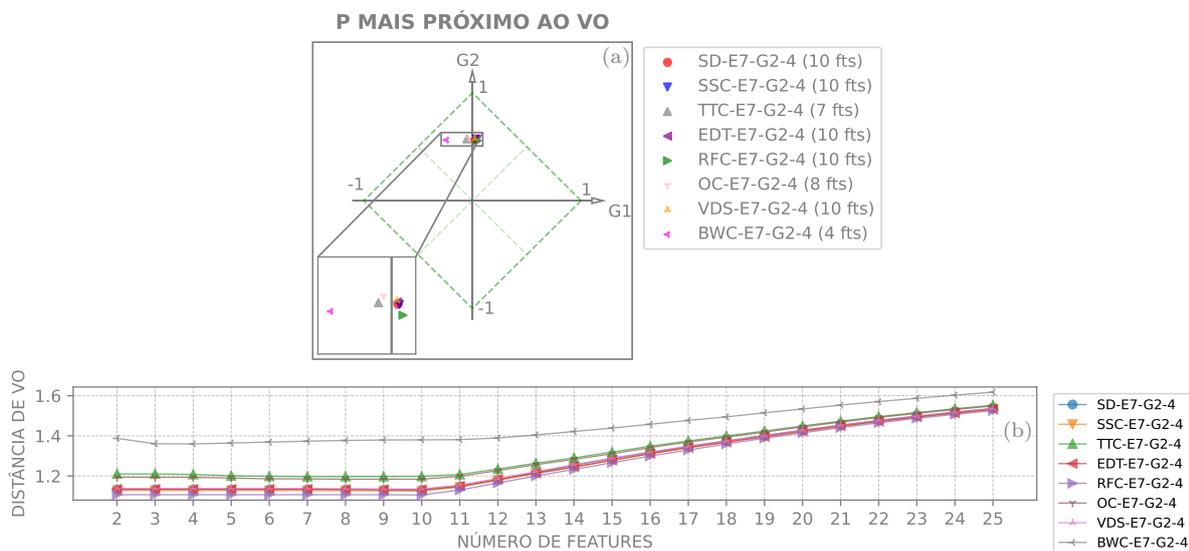
Adicionalmente, observa-se em todos os casos que as distâncias menores, em relação a VO, associam-se ao menor número de *features*, aumentando progressivamente. Conforme a análise PFE indica, os conjuntos gerados por combinações das *features*, com vetores

Figura 140 – Resumo dos resultados do módulo MPFE para E7-G2-3. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Figura 141 – Resumo dos resultados do módulo MPFE para E7-G2-4. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO.



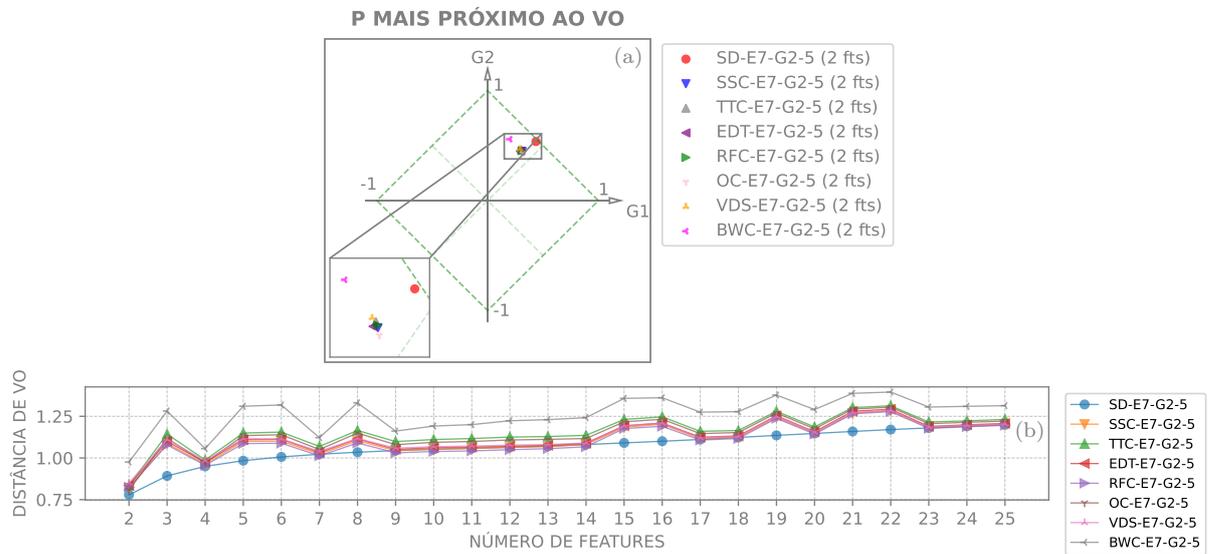
Fonte: Produzido pelo autor.

no formato F2, sofrem um impacto significativo nos resultados em relação aos ensaios anteriores.

E7-G2: Resultados do módulo MTT

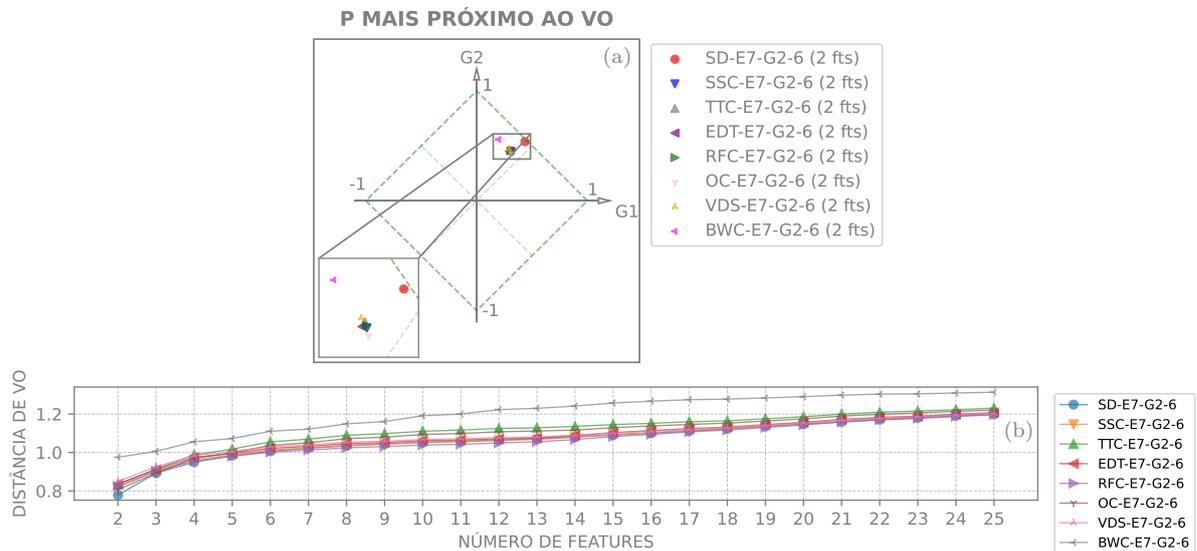
A análise de desempenho dos modelos SVM prossegue com o processamento pelo módulo MTT de todos os conjuntos de vetores derivados das variadas combinações de

Figura 142 – Resumo dos resultados do módulo MPFE para E7-G2-5. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

Figura 143 – Resumo dos resultados do módulo MPFE para E7-G2-6. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO.

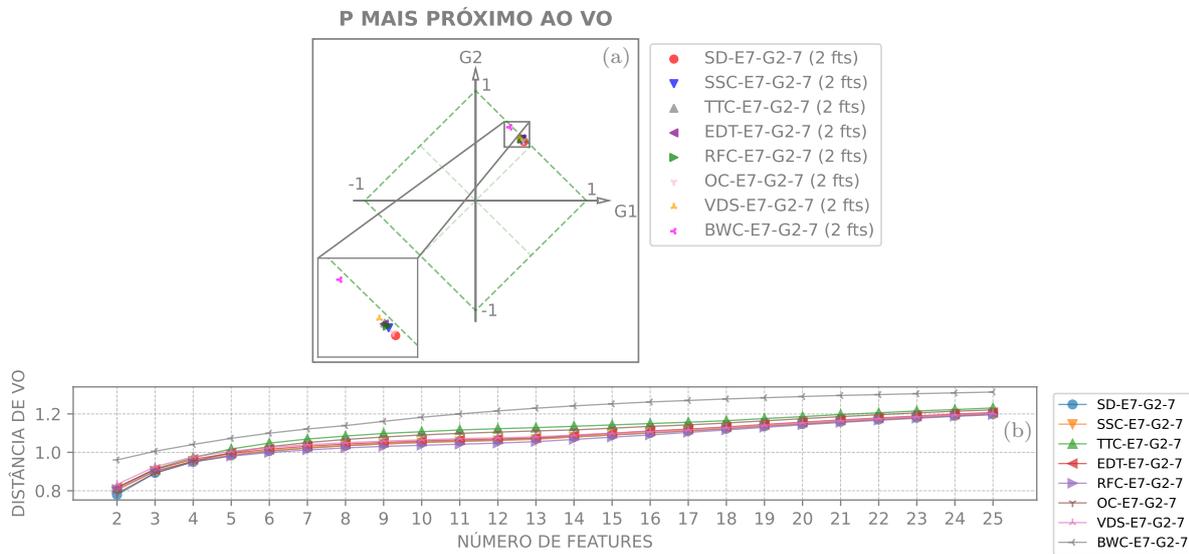


Fonte: Produzido pelo autor.

features possíveis. Os parâmetros atribuídos para os treinamentos dos classificadores mantêm-se consistentes com os previamente estabelecidos, conforme detalhado na Tabela 6. O limiar de treinamento foi estipulado em múltiplos de 10, variando no intervalo de 20 a 80.

Os máximos de *features* são fixos (correspondentes às 25 bandas críticas da EB) e foram realizados um total de 10 348 800 treinamentos distintos para todas as configurações,

Figura 144 – Resumo dos resultados do módulo MPFE para E7-G2-7. Em (a) apresentam-se os melhores pontos P e (b) exibe as distâncias em relação ao VO.



Fonte: Produzido pelo autor.

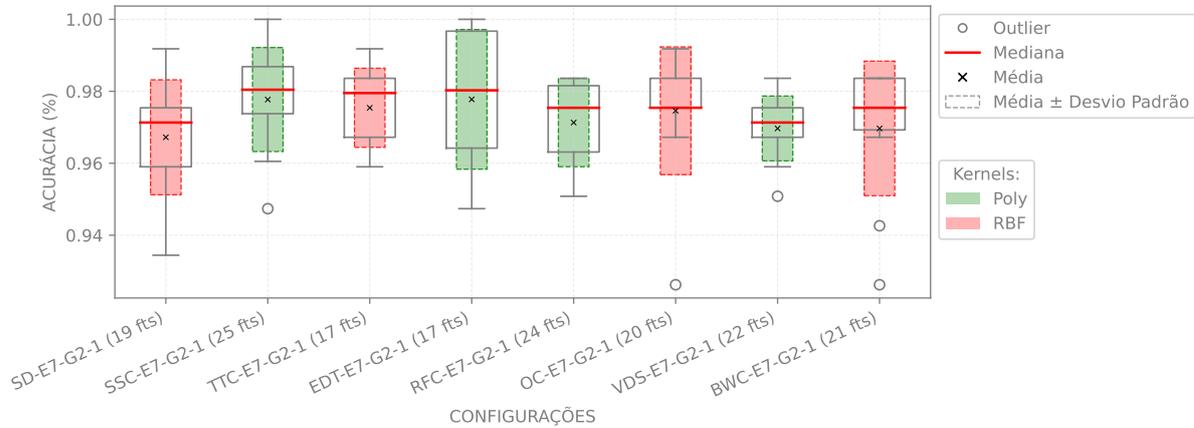
especificadas na [Tabela 33](#), assim como no ensaio E6-G2. Ao final deste processo, os modelos que exibiram maiores médias de acurácias no processo de validação cruzada foram eleitos para os testes definitivos, utilizando o conjunto de dados especificamente reservado para essa finalidade.

Após o processamento de todos os conjuntos de vetores, considerando a variação do número de *features*, os resultados obtidos nos treinamentos com validação cruzada para os modelos que exibiram maior eficácia nos testes subsequentes, abrangendo todas as configurações, foram ilustrados nas Figuras 145 à 151.

Nos resultados correspondentes às configurações avaliadas neste experimento, observa-se que os treinamentos referentes aos modelos de melhor desempenho nos testes exibiram acurácias consistentes com as apresentadas em E6-G2, superiores a 92%. Entretanto, algumas configurações, como SSC-E7-G2-7 (25 fts), EDT-E7-G2-6 (24 fts) e BWC-E7-G2-7 (25 fts), constituem exceções. Especificamente, o modelo SSC-E7-G2-7 apresentou acurácia mínima de 90.2% e máxima próxima a 98.9%. O modelo EDT-E7-G2-6 teve uma acurácia mínima de 91.3% (*outlier*) e máxima de 100%. O BWC-E7-G2-7, por sua vez, atingiu uma acurácia máxima de 97.7% e mínima de 90% (*outlier*). As faixas definidas pelas médias \pm desvios padrão permaneceram acima de 94%, ou com extremidade inferior do intervalo muito próxima a essa taxa.

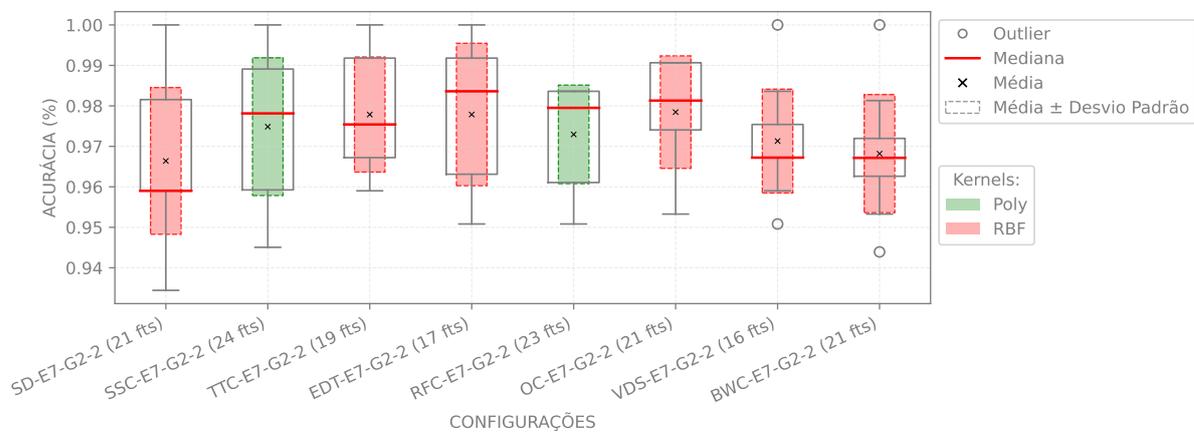
No que se refere aos *kernels*, o RBF mostrou-se novamente predominante entre os melhores hiperparâmetros, com uma ocorrência de 78.57%, seguido pelo *kernel* polinomial, com 21.43%. Embora o *kernel* polinomial geralmente tenha uma ligeira vantagem em termos de acurácia média, é importante notar que a diferença entre os dois não é drástica.

Figura 145 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-1. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.



Fonte: Produzido pelo autor.

Figura 146 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-2. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.

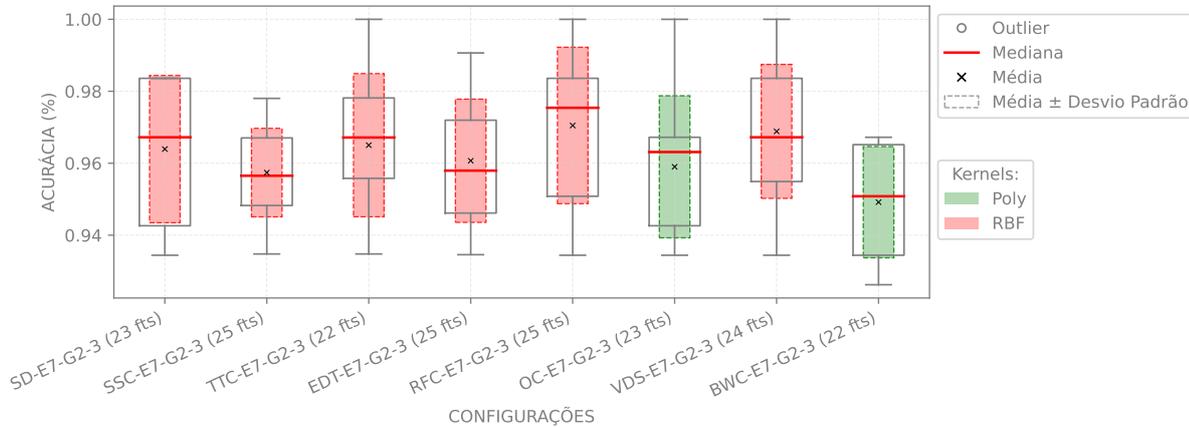


Fonte: Produzido pelo autor.

Em algumas configurações, o *kernel* RBF até supera o polinomial.

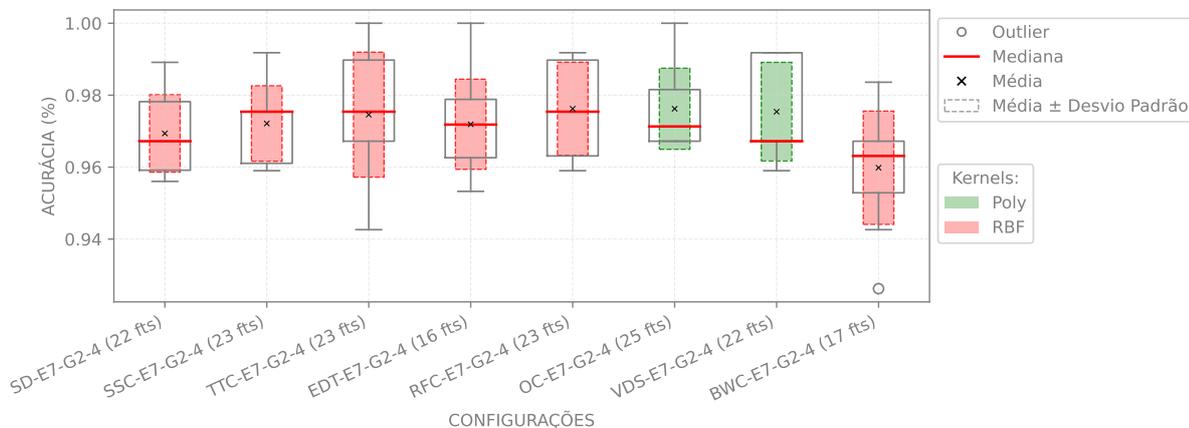
Em relação às distribuições das acurácias, os diagramas de caixa apresentam comportamentos variados, assim como em E6-G2, sendo predominantemente assimétricos no intervalo interquartil em relação à mediana. Algumas configurações mostram distribuições com intervalos mais amplos, como é o caso da SSC-E7-G2-7 (25 fts), enquanto outras apresentam intervalos mais estreitos, como a SD-E7-G2-6 (17 fts). Intervalos mais amplos indicam uma variação significativa nos resultados para essas configurações. Em contraste, intervalos mais estreitos sugerem que a configuração demonstra maior estabilidade e previsibilidade. Como mencionado em relação à E6-G2, esta variabilidade observada pode

Figura 147 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-3. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.



Fonte: Produzido pelo autor.

Figura 148 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-4. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.



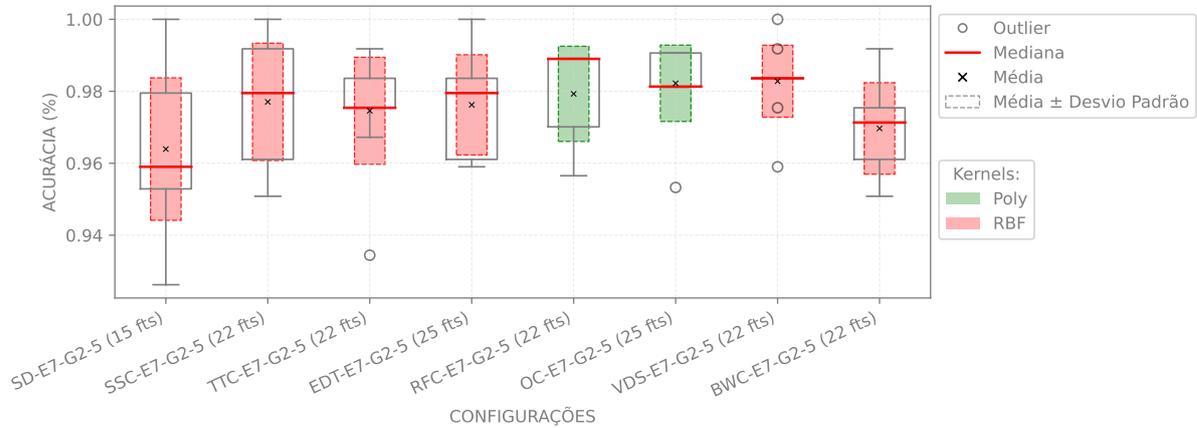
Fonte: Produzido pelo autor.

originar-se da instabilidade particular da configuração ou de outros fatores não controlados no experimento. Evidentemente, no contexto desta pesquisa, uma menor variabilidade é desejável, pois indica que o modelo é robusto e confiável nas condições estipuladas.

Por fim, a presença de *outliers* para alguns modelos sugere que, embora a maioria dos treinamentos tenham produzido altas acurácias, houve algumas execuções atípicas. No entanto, as faixas de confiança (médias \pm desvios padrão) na maioria das configurações reforçam a ideia de que os modelos são, em geral, consistentes em seus desempenhos.

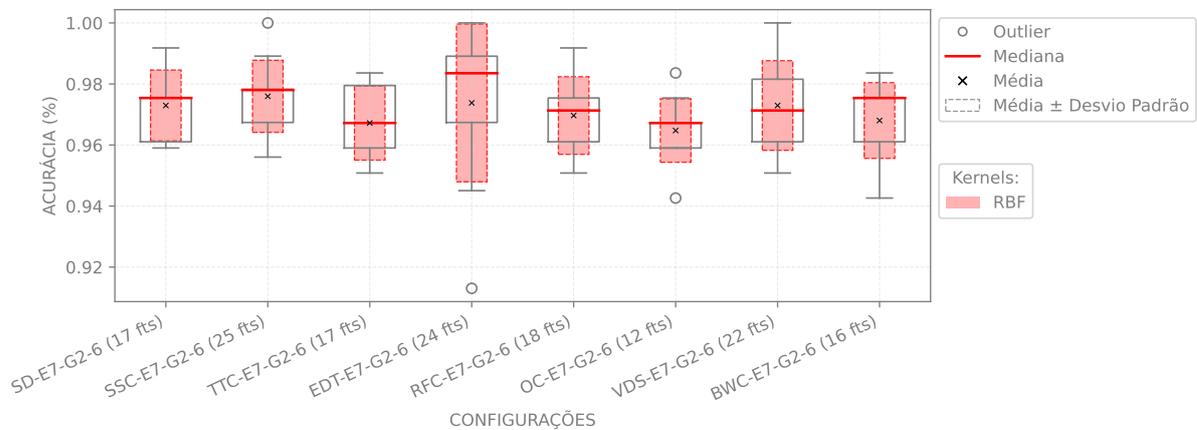
Quanto à avaliação dos modelos, as Figuras 152 à 159 ilustram os resultados dos

Figura 149 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-5. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.



Fonte: Produzido pelo autor.

Figura 150 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-6. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.

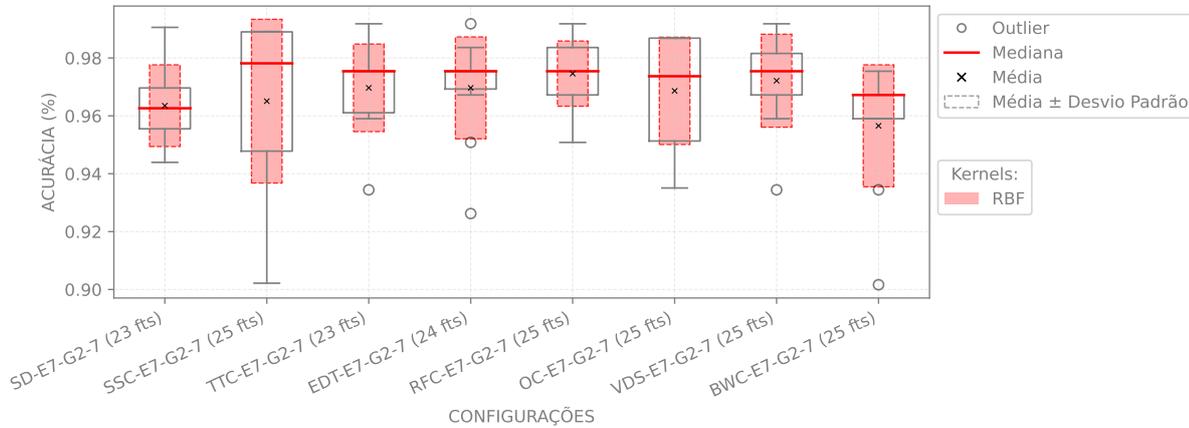


Fonte: Produzido pelo autor.

testes dos melhores modelos em todos os cenários avaliados, agrupados por critério de parada.

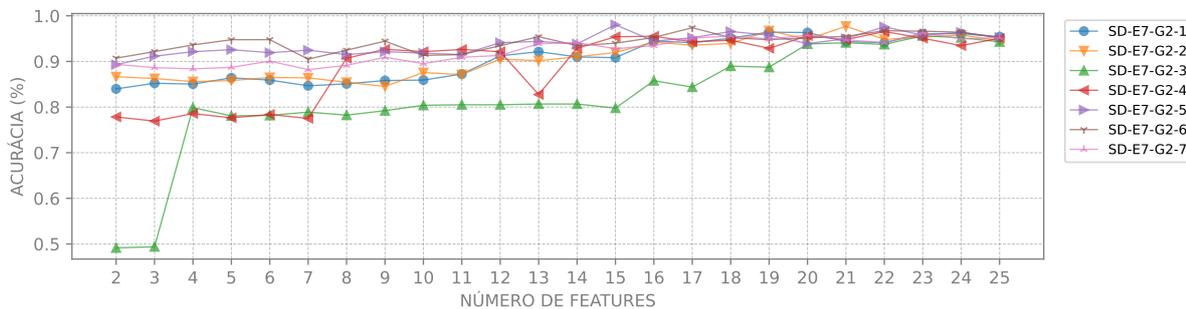
Nas Figuras apresentadas, constata-se que as oscilações observadas em E6-G2 foram suavizadas, com algumas exceções, e os desempenhos dos modelos em relação aos experimentos E1 ao E5 do grupo G1 também foram potencializados. As melhores configurações de E7-G2 resultaram em acurácias que superaram os 95%, alcançando 99.02% nos melhores cenários, VDS-E7-G2-2 (16 fts) e BWC-E7-G2-5 (22 fts), nos quais os modelos cometeram apenas três erros de classificação. Em certas situações, como no caso de SD-E7-G2-5 (15 fts), a normalização potencializou a estrutura inerente dos dados,

Figura 151 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E7-G2-7. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.



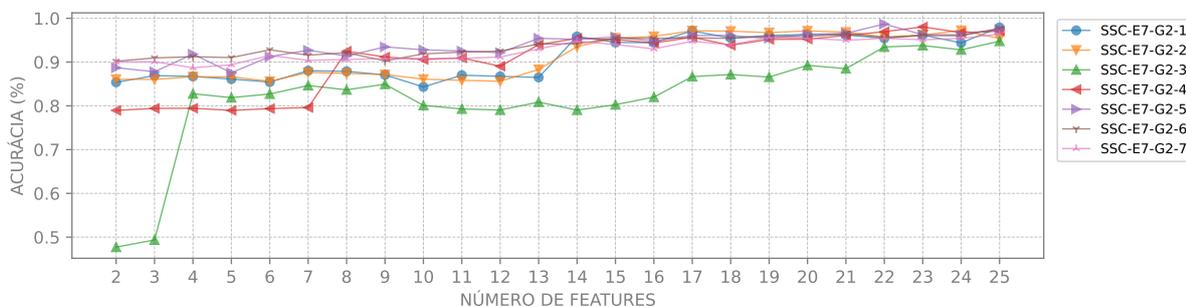
Fonte: Produzido pelo autor.

Figura 152 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada SD. O número de *features* é dado pela ordem de extração das IMFs.



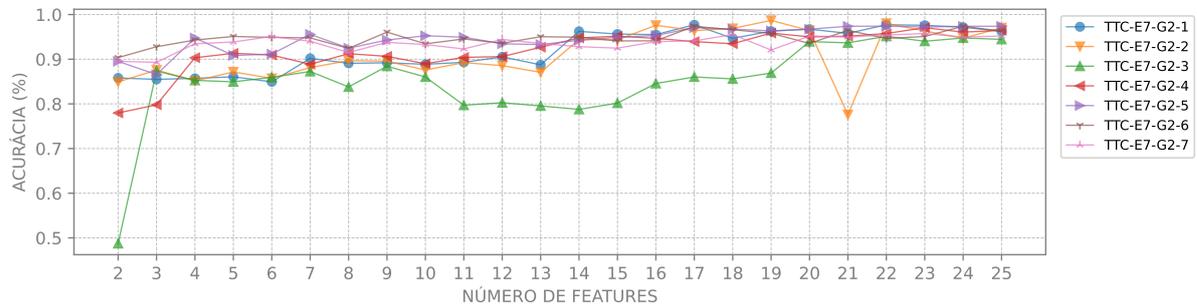
Fonte: Produzido pelo autor.

Figura 153 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada SSC. O número de *features* é dado pela ordem de extração das IMFs.



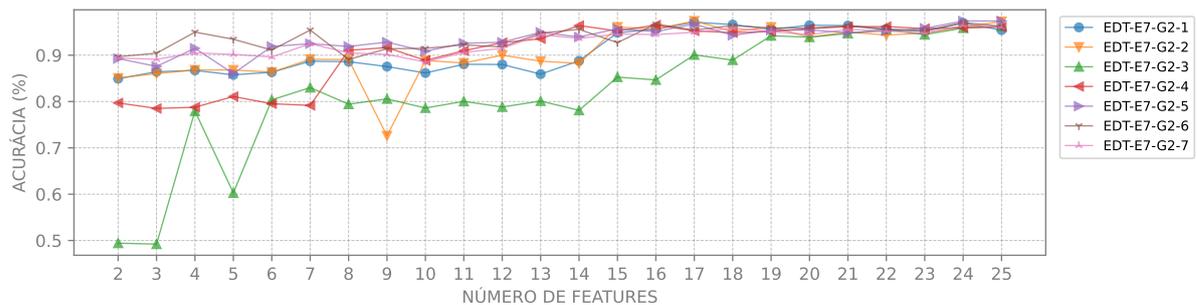
Fonte: Produzido pelo autor.

Figura 154 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada TTC. O número de *features* é dado pela ordem de extração das IMFs.



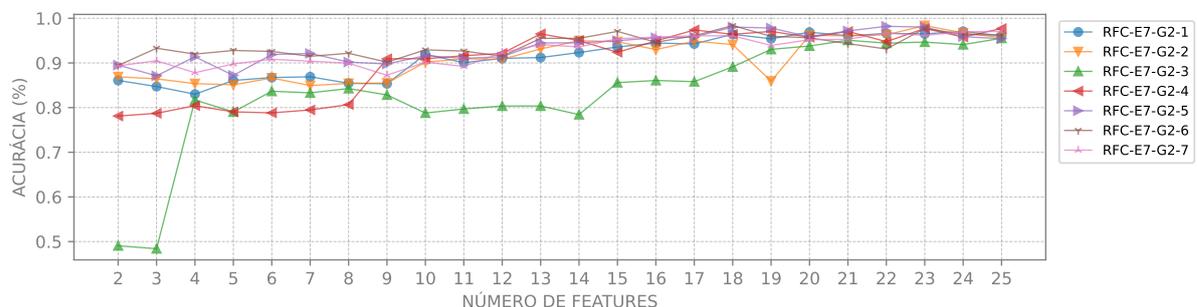
Fonte: Produzido pelo autor.

Figura 155 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada EDT. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

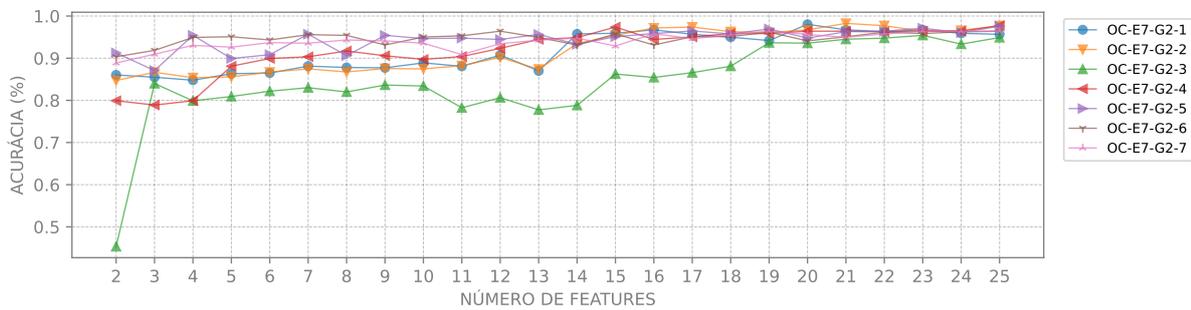
Figura 156 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada RFC. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

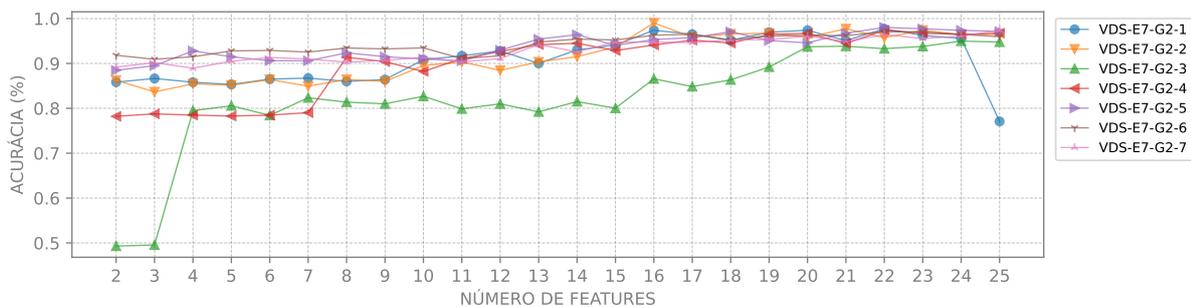
propiciando uma classificação mais acertada (acurácia de 98.03% para o caso mencionado). No entanto, em outros contextos, como observado em OC-E7-G2-3 (2 fts), as conexões essenciais entre as *features* foram possivelmente obscurecidas, levando a performances abaixo do esperado (inferior a 50% para o caso mencionado). Assim como nos ensaios

Figura 157 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada OC. O número de *features* é dado pela ordem de extração das IMFs.



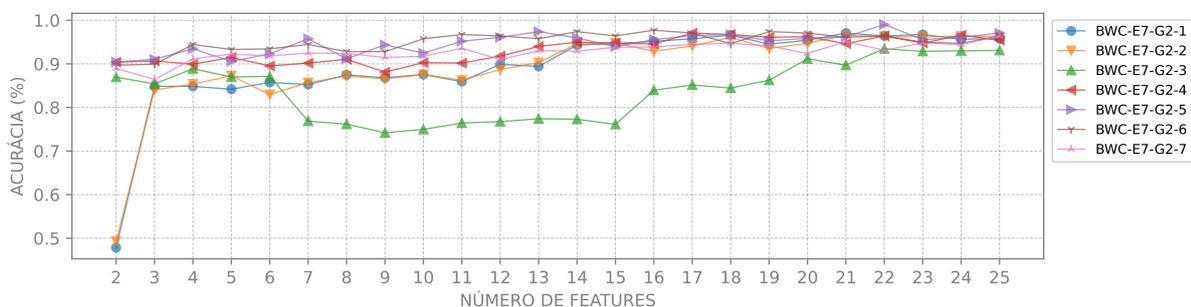
Fonte: Produzido pelo autor.

Figura 158 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada VDS. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

Figura 159 – Resultados dos testes dos melhores modelos em todos os cenários avaliados em E7-G2 para o critério de parada BWC. O número de *features* é dado pela ordem de extração das IMFs.



Fonte: Produzido pelo autor.

anteriores, estas diferenças reforçam a premissa de que a escolha criteriosa da técnica de normalização é vital para maximizar as performances dos modelos classificadores.

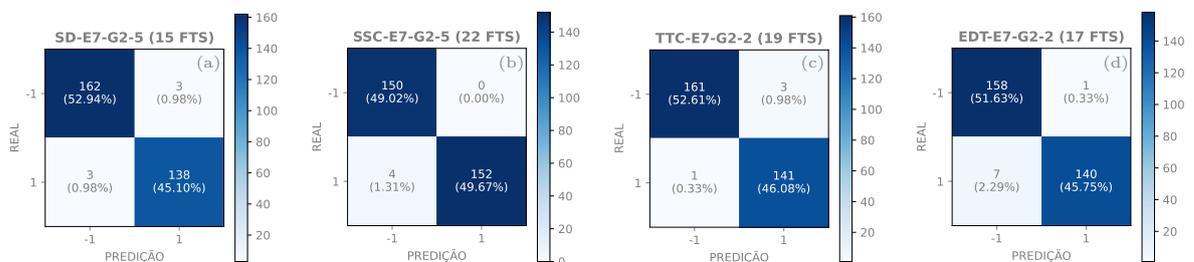
Novamente, nota-se que a configuração envolvendo a normalização LS(0.01) provocou uma redução nos desempenhos dos modelos para todos os critérios de parada (ensaios

E7-G2-3), sugerindo que a transformação a que os vetores foram submetidos pode ter obscurecido características fundamentais dos respectivos sinais. Em tais circunstâncias, as acurácias alcançaram, de forma geral, valores superiores a 90% apenas quando se considerou 19 ou mais *features*. Em contraste, nas outras configurações, todos os critérios de parada conseguiram superar esta marca com apenas duas *features*, para pelo menos uma das técnicas de normalização.

Permaneceu o comportamento de que determinadas técnicas de normalização resultam em desempenhos equivalentes ou superiores quando associadas a um número distinto de *features*, seja em quantidades maiores ou menores, observado nos ensaios E5-G1 e E6-G2, mesmo com a suavização das oscilações. Como mencionado anteriormente, esse fenômeno sugere que a eficácia de algumas técnicas de normalização pode estar relacionada à dimensionalidade dos dados.

Nas Figuras 160 e 161, são apresentadas as MCs referentes aos resultados dos modelos que exibiram melhores desempenhos nos testes para cada critério de parada. Observa-se, como mencionado anteriormente, que as configurações VDS-E7-G2-2 (16 fts) e BWC-E7-G2-5 (22 fts) obtiveram os melhores desempenhos neste ensaio, ambas classificando erroneamente apenas três instâncias de 306 avaliadas.

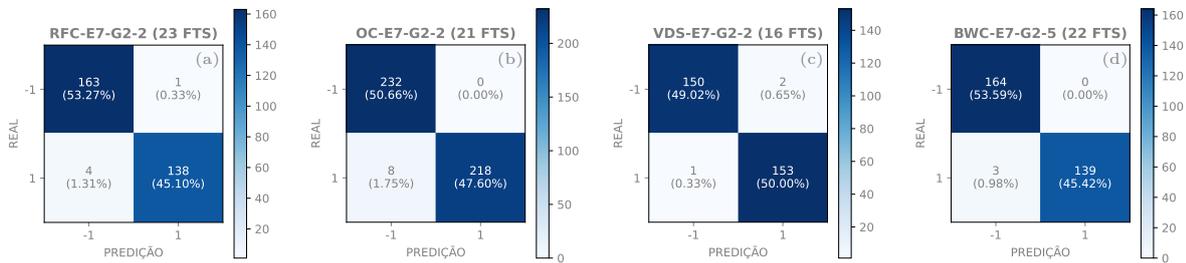
Figura 160 – MCs das melhores configurações em E7-G2 para os critérios de parada SD, SSC, TTC e EDT. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.



Fonte: Produzido pelo autor.

Os hiperparâmetros determinados para os modelos de melhor desempenho, bem como as métricas acurácia, precisão, *recall*, *F1-score* e AUC, estão detalhados na Tabela 37. Os modelos alcançaram um AUC mínimo de 0.94, no caso BWC-E6-G2-3 (22 fts), atingindo 1.00 em vários outros. As configurações que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada estão destacadas na Tabela 37. Priorizou-se novamente o *F1-score* máximo, conforme descrito anteriormente.

Figura 161 – MCs das melhores configurações em E7-G2 para os critérios de parada RFC, OC, VDS e BWC. Os escalares 1 e -1 representam, respectivamente, as classes “cigarra” e “ruído”.



Fonte: Produzido pelo autor.

Com base nas análises e tendo em vista os resultados apresentados nas Tabelas 28 e 37, conclui-se que os conjuntos de vetores definidos no formato F2, constituídos pelas melhores combinações de *features* conforme análise PFE, mantêm a melhoria no desempenho do sistema observada no ensaio E6-G2. Além disso, os resultados do módulo MPFE foram otimizados, indicando que as combinações de *features* específicas podem evidenciar a estrutura dos dados. A obtenção de acurácias e *F1-scores* que superaram 99% indica que as melhores configurações exibiram desempenhos superiores aos dos ensaios E1 a E5 do grupo G1 e equiparáveis aos resultados obtidos em E6-G2. Considerando ainda que em E6-G2, todos os melhores modelos precisaram de 80% das amostras para treinamento (Tabela 34) e que em E7-G2 foi possível reduzir essa porcentagem para 70% para o critério de parada OC (Tabela 37), confirma-se a hipótese inicialmente proposta nesta subseção.

No próximo grupo, explora-se o problema de classificação para três classes, visando a estimativa de densidade de cigarras. Espera-se que a utilização de parâmetros mais flexíveis para a EMD, assim como sinais com menores durações, taxas de amostragem reduzidas e as combinações de *features* possam fornecer resultados satisfatórios, assim como nos experimentos de identificação.

4.2.3 Grupo G3

Dada a habilidade do sistema proposto em identificar, com elevada precisão, a presença de cigarras por meio de sinais acústicos, os experimentos neste grupo foram dedicados à estimativa da densidade desses insetos pela distinção entre as classes “alta”, “baixa” e “ruído”. As configurações adotadas para o sistema estão alinhadas com as empregadas no ensaio E7-G2. Como mencionado, foram utilizados 315 sinais acústicos, distribuídos igualmente entre as três classes, destinados aos treinamentos dos classificadores SVM para estimativa de densidade de cigarras na lavoura.

Tabela 37 – Melhores resultados em E7-G2. As configurações destacadas são as que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada. O termo “Poly” refere-se ao *kernel* Polinomial.

Configuração	Num. features	Amostras treino (%)	C	γ	Kernel	Acurácia	Precisão	Recall	F1-score	AUC
SD-E7-G2-1	19	80	1000.0	10.0	RBF	0.96405	0.98765	0.94675	0.96677	0.99
SSC-E7-G2-1	25	50	0.01	100.0	Poly	0.97903	0.98919	0.96825	0.97861	0.98
TTC-E7-G2-1	17	80	1000.0	10.0	RBF	0.97712	0.98639	0.96667	0.97643	0.99
EDT-E7-G2-1	17	50	100.0	10.0	Poly	0.97117	0.97120	0.97120	0.97120	0.98
RFC-E7-G2-1	24	80	1000.0	1	Poly	0.97059	1.00000	0.93793	0.96797	0.98
OC-E7-G2-1	20	80	1000.0	10.0	RBF	0.98039	0.98101	0.98101	0.98101	1.00
VDS-E7-G2-1	22	80	1	10.0	Poly	0.97712	1.00000	0.95455	0.97674	0.99
BWC-E7-G2-1	21	80	1000.0	10.0	RBF	0.97059	0.96599	0.97260	0.96928	0.98
SD-E7-G2-2	21	80	1000.0	10.0	RBF	0.97712	0.98000	0.97351	0.97674	0.98
SSC-E7-G2-2	24	60	0.01	100.0	Poly	0.97218	0.98966	0.95349	0.97124	0.98
TTC-E7-G2-2	19	80	1000	10	RBF	0.98693	0.97917	0.99296	0.98601	0.99
EDT-E7-G2-2	17	80	1000	10	RBF	0.97386	0.99291	0.95238	0.97222	0.97
RFC-E7-G2-2	23	80	0.001	100	Poly	0.98366	0.99281	0.97183	0.98221	0.99
OC-E7-G2-2	21	70	1000	10	RBF	0.98253	1.00000	0.96460	0.98198	0.99
VDS-E7-G2-2	16	80	1000	10	RBF	0.99020	0.98710	0.99351	0.99029	0.99
BWC-E7-G2-2	21	70	1000.0	10.0	RBF	0.96507	0.97854	0.95397	0.96610	0.97
SD-E7-G2-3	23	40	100.0	1	RBF	0.95633	0.96963	0.93891	0.95402	0.98
SSC-E7-G2-3	25	60	100.0	0.01	RBF	0.94763	0.98221	0.91089	0.94521	0.95
TTC-E7-G2-3	22	30	100.0	1	RBF	0.95136	0.97041	0.93006	0.94981	0.95
EDT-E7-G2-3	25	70	100.0	1	RBF	0.96288	0.99061	0.93363	0.96128	0.97
RFC-E7-G2-3	25	40	100.0	0.1	RBF	0.95524	0.97018	0.93792	0.95378	0.97
OC-E7-G2-3	23	80	0.001	10.0	Poly	0.95425	1.00000	0.90210	0.94853	0.96
VDS-E7-G2-3	24	40	100.0	0.1	RBF	0.94978	0.98832	0.91164	0.94843	0.98
BWC-E7-G2-3	22	80	100.0	1	Poly	0.93464	1.00000	0.87578	0.93377	0.94
SD-E7-G2-4	22	60	1000.0	1	RBF	0.96563	0.97586	0.95286	0.96422	0.98
SSC-E7-G2-4	23	80	1000.0	1	RBF	0.98039	0.99310	0.96644	0.97959	0.98
TTC-E7-G2-4	23	80	1000.0	1	RBF	0.97059	0.99355	0.95062	0.97161	0.99
EDT-E7-G2-4	16	70	1000.0	10.0	RBF	0.96507	0.96759	0.95872	0.96313	0.98
RFC-E7-G2-4	23	80	1000.0	1	RBF	0.97712	0.97945	0.97279	0.97611	0.99
OC-E7-G2-4	25	80	0.01	10.0	Poly	0.97712	0.99275	0.95804	0.97509	0.99
VDS-E7-G2-4	22	80	0.01	10.0	Poly	0.97386	0.98561	0.95804	0.97163	0.98
BWC-E7-G2-4	17	80	1000.0	1	RBF	0.97059	0.98742	0.95732	0.97214	0.98
SD-E7-G2-5	15	80	100	10	RBF	0.98039	0.97872	0.97872	0.97872	1.00
SSC-E7-G2-5	22	80	1000	10	RBF	0.98693	1.00000	0.97436	0.98701	0.99
TTC-E7-G2-5	22	80	1000.0	10.0	RBF	0.97386	0.99281	0.95172	0.97183	0.97
EDT-E7-G2-5	25	80	1000.0	10.0	RBF	0.97386	1.00000	0.95062	0.97468	0.99
RFC-E7-G2-5	22	60	100.0	1	Poly	0.98200	0.99267	0.96786	0.98011	0.99
OC-E7-G2-5	25	70	100.0	1	Poly	0.97598	0.98630	0.96429	0.97517	0.99
VDS-E7-G2-5	22	80	1000.0	10.0	RBF	0.98039	0.98795	0.97619	0.98204	0.99
BWC-E7-G2-5	22	80	1000	10	RBF	0.99020	1.00000	0.97887	0.98932	1.00
SD-E7-G2-6	17	80	1000.0	1000.0	RBF	0.97386	0.98582	0.95862	0.97203	0.99
SSC-E7-G2-6	25	60	1000.0	100.0	RBF	0.97709	0.98966	0.96309	0.97619	0.98
TTC-E7-G2-6	17	80	1000.0	1000.0	RBF	0.97386	0.97872	0.96503	0.97183	0.99
EDT-E7-G2-6	24	60	1000.0	1000.0	RBF	0.97218	0.98299	0.96013	0.97143	0.98
RFC-E7-G2-6	18	80	1000.0	1000.0	RBF	0.98366	1.00000	0.96753	0.98350	0.98
OC-E7-G2-6	12	80	100.0	1000.0	RBF	0.96405	0.98540	0.93750	0.96085	0.97
VDS-E7-G2-6	22	80	1000.0	1000.0	RBF	0.97059	0.98649	0.95425	0.97010	0.99
BWC-E7-G2-6	16	80	1000.0	1000.0	RBF	0.97712	0.97368	0.98013	0.97690	0.98
SD-E7-G2-7	23	70	1000.0	1000.0	RBF	0.96288	0.99539	0.93103	0.96214	0.99
SSC-E7-G2-7	25	60	1000.0	1000.0	RBF	0.96399	0.98311	0.94481	0.96358	1.00
TTC-E7-G2-7	23	80	1000.0	1000.0	RBF	0.95752	1.00000	0.92216	0.95950	0.99
EDT-E7-G2-7	24	80	1000.0	1000.0	RBF	0.96405	0.99338	0.93750	0.96463	0.99
RFC-E7-G2-7	25	80	1000.0	1000.0	RBF	0.97059	1.00000	0.94194	0.97010	0.99
OC-E7-G2-7	25	50	1000.0	1000.0	RBF	0.96461	0.98611	0.94164	0.96336	1.00
VDS-E7-G2-7	25	80	1000.0	1000.0	RBF	0.97386	0.99387	0.95858	0.97590	1.00
BWC-E7-G2-7	25	80	1000.0	1000.0	RBF	0.96405	0.98667	0.94268	0.96417	1.00

Fonte: Elaborada pelo autor.

4.2.3.1 Experimento E8

A hipótese neste experimento é que para vetores estabelecidos no formato F2, as 25 *features* combinadas de k em k , com k variando de 2 a 25, possibilitem a determinação de modelos com altos desempenhos para a estimativa de densidade de indivíduos, assim como os resultados obtidos nos ensaios anteriores.

Neste contexto, o experimento E8 foi realizado com sinais derivados dos sinais originais e catalogados nas três classes investigadas. Foram consideradas duração e taxa de amostragem de 1 segundo e 6 kHz, respectivamente, para cada sinal. No tratamento via EMD, aplicaram-se os 8 critérios de parada e estipulou-se um máximo de 700 iterações

por IMF. Assim como no ensaio E7-G2, os vetores de *features* foram definidos no formato F2 e passaram por um processo de normalização utilizando as técnicas MN, MMN e LS, descritas na [seção 2.5](#). Para a técnica MMN, realizou-se o reescalonamento das *features* para o intervalo $[0, 1]$, definindo $a = 0$ e $b = 1$. Por outro lado, para a técnica LS, exploraram-se cinco variações do coeficiente v , sendo $v \in \{0.01, 0.1, 1, 10, 100\}$. Os parâmetros específicos, associados a cada critério de parada, seguem os mais flexíveis adotados nos ensaios E4 e E5 do grupo G1. A única exceção é para o critério BWC, cuja configuração é derivada de E3-G1-3. As configurações investigadas neste experimento são idênticas às de E6-G2 e estão disponíveis na [Tabela 33](#), portanto, os rótulos de E8-G2 correspondem aos seus respectivos em E6-G2. Por exemplo, SD-E8-G2-3 corresponde a SD-E6-G2-3, da mesma forma que desenvolvido em E7-G2.

E8-G3: Resultados do Módulo MEF

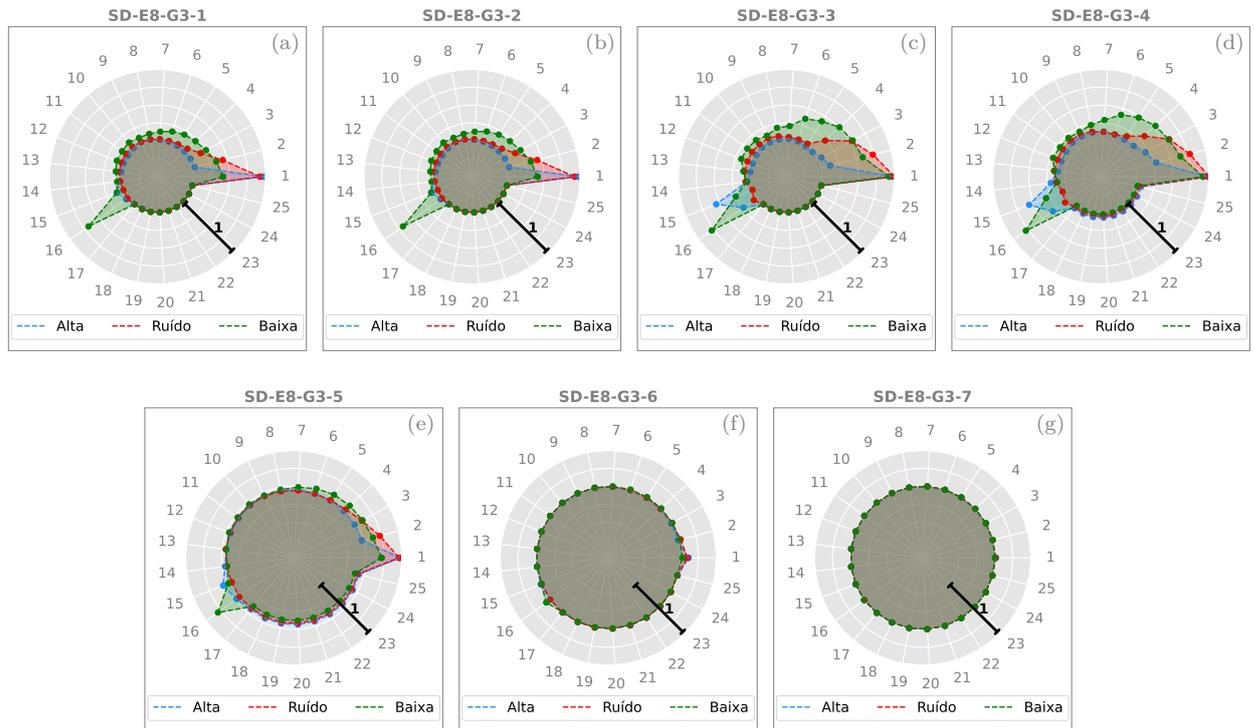
De forma análoga aos ensaios E6 e E7 do grupo G2, para E8-G3, os resultados obtidos no módulo MEF são consistentes com os obtidos em E4-G1-1 para o critério SSC, E3-G1-3 para BWC e E4-G1-2 para os demais critérios. Isso ocorre devido ao fato de que os 315 sinais acústicos utilizados nos experimentos desse grupo também pertencerem ao grupo de 1526 sinais empregados nos ensaios dos dois primeiros grupos, com o diferencial de que foram rotulados em três classes.

E8-G3: Resultados do Módulo MNF

Prosseguindo, o módulo MNF é empregado para a normalização dos vetores. Neste ensaio, adotaram-se as três técnicas de normalização (MN, MMN e LS), em consonância com os ensaios anteriores. Na [Figura 162](#), são exibidos os gráficos de radar que ilustram as médias dos vetores associados a cada classe. Analogamente ao que foi observado nos demais experimentos, as classes são visualmente distinguíveis.

Para a classe “ruído”, as energias são distribuídas principalmente, em média, nas quatro primeiras *features*, decrescendo progressivamente, com um pico proeminente na primeira. Os vetores associados à classe “baixa” evidenciam, em média, um padrão análogo, porém com uma distribuição de energia mais extensa, abrangendo até a décima quinta *feature*, e um pico na décima sexta. Em contrapartida, os vetores da classe “alta” direcionam as energias, em média, para as *features* de número 1, 15 e 16, com um ápice na primeira. As características observadas nos gráficos de distribuições das *features*, reescaladas e transformadas, são também identificadas nas demais configurações exploradas. Assim, visando evitar redundâncias, optou-se por apresentar somente os gráficos pertinentes às configurações SD-E8-G3.

Figura 162 – Gráficos de radar das *features*, em média, para as classes “alta”, “baixa” e “ruído” das configurações SD-E8-G3-1 à SD-E8-G3-7.



Fonte: Produzido pelo autor.

Os gráficos reforçam em média as diferenças notáveis entre os vetores das classes. No entanto, semelhante ao que foi constatado nos experimentos anteriores, as distinções entre os vetores tornam-se visualmente imperceptíveis em SD-E8-G3-7, uma vez que convergem significativamente em direção à média. Apesar deste comportamento, ensaios precedentes evidenciaram a capacidade dos modelos SVM em alcançar performances satisfatórias, o que também se espera neste ensaio.

E8-G3: Resultados do Módulo MPFE

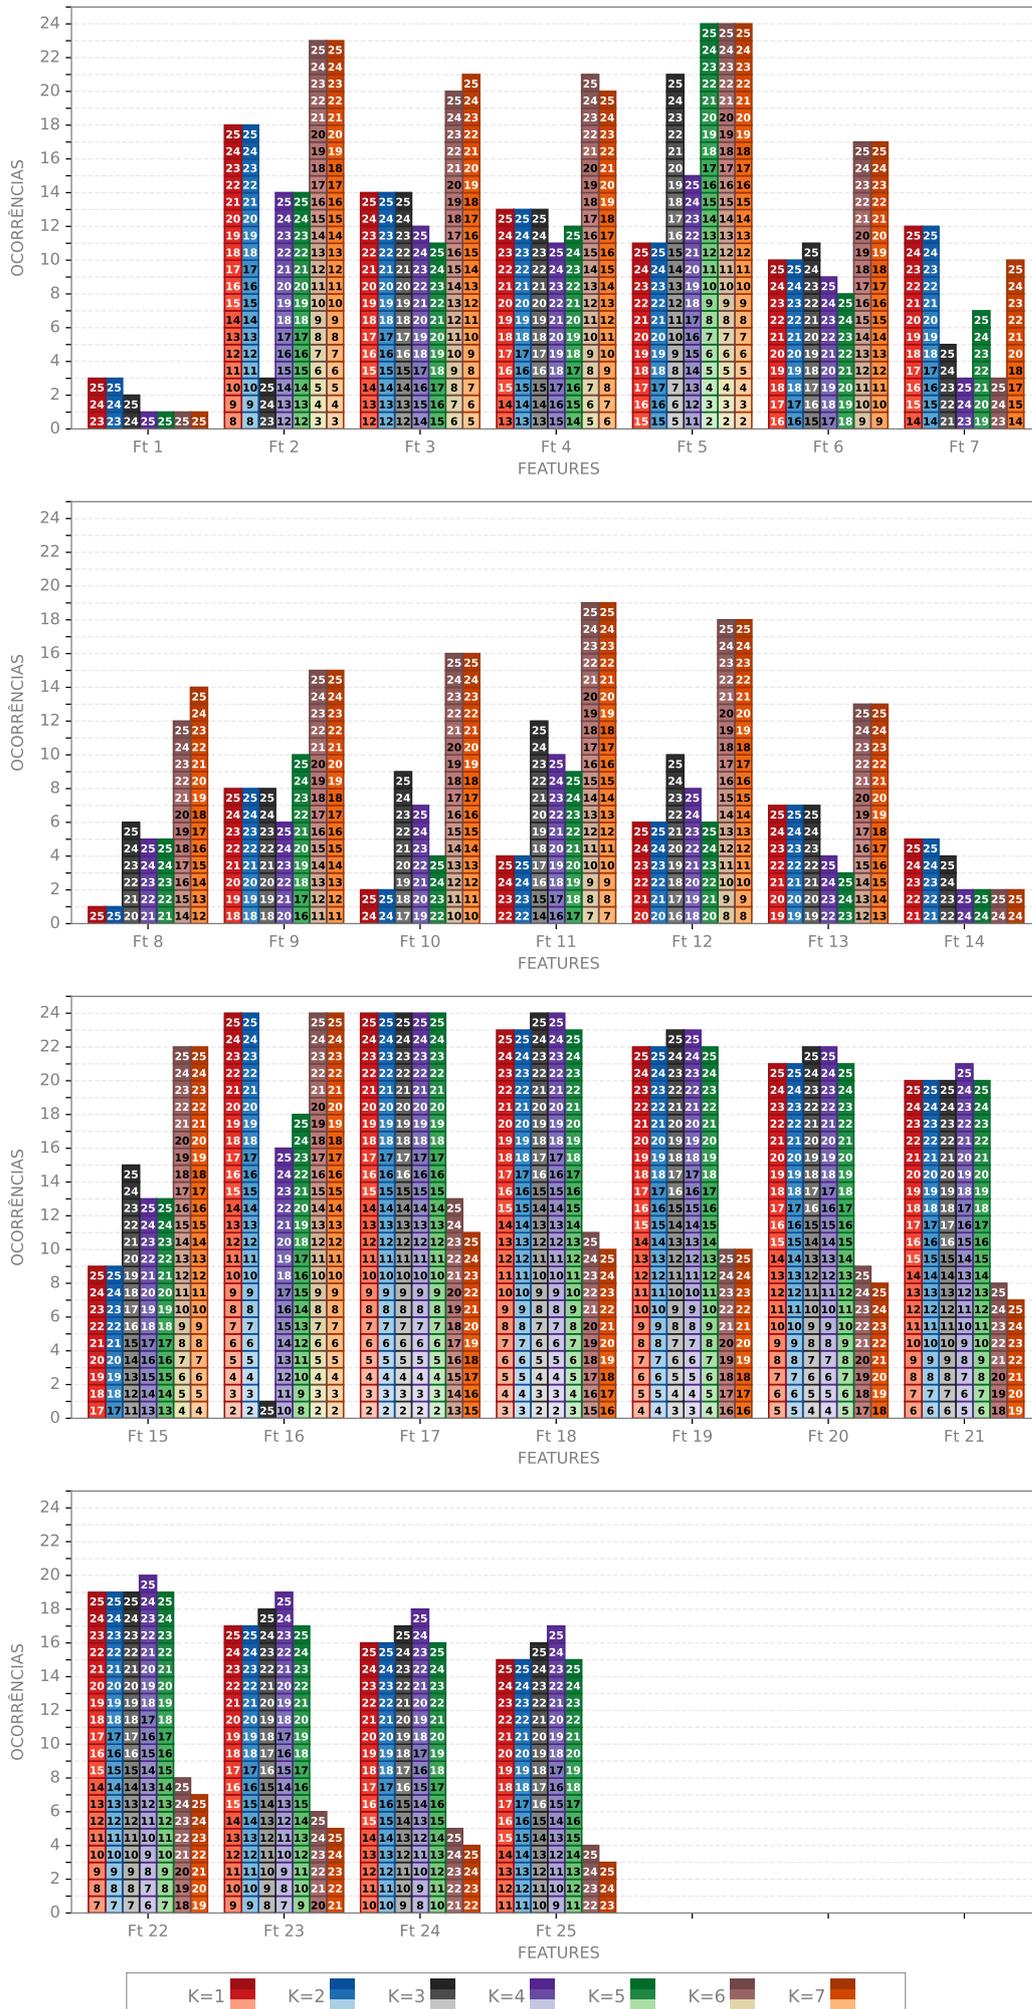
Dando sequência à avaliação dos vetores, todos os conjuntos derivados das possíveis combinações de *features* foram submetidos ao módulo MPFE. Especificamente, consideraram-se as 25 *features* combinadas de k em k , com k inteiro variando entre 2 e 25, abrangendo todas as configurações. Para cada configuração indicada na Tabela 33 foram examinadas 33 554 406 combinações, somando um total de 1 879 046 736 combinações avaliadas. Novamente, a métrica para determinação dos melhores resultados foi a distância mínima entre o ponto P, que representa o conjunto avaliado, e o VO.

As disposições dos pontos nos PP são consistentes com as descritas no ensaio E7-G2. Portanto, dentre os resultados do módulo MPFE, optou-se por destacar somente as combinações ótimas de *features*, conforme Figuras Figura 163 à Figura 170. Esta

concordância entre os resultados é embasada na mesma fundamentação apresentada sobre os resultados do módulo MEF deste ensaio.

De forma análoga ao observado em E7-G2, nota-se pela variação no número de ocorrências em cada grupo de barras, correspondente a cada *feature*, a influência das técnicas de normalização sobre a importância de cada *feature*. Para SD-E8-G3, por exemplo, a décima sexta *feature* constitui todos os melhores conjuntos de vetores, segundo a PFE, para as técnicas MN, MMN, LS(10), LS(100) enquanto LS(0.01), LS(0.1) e LS(1) influenciam esta mesma *feature* a constituir no máximo 18 das 24 variações com as melhores combinações. Esta mesma *feature* constitui apenas uma ocorrência ao considerar-se a técnica LS(0.01). Um comportamento semelhante pode ser observado para todas as configurações avaliadas.

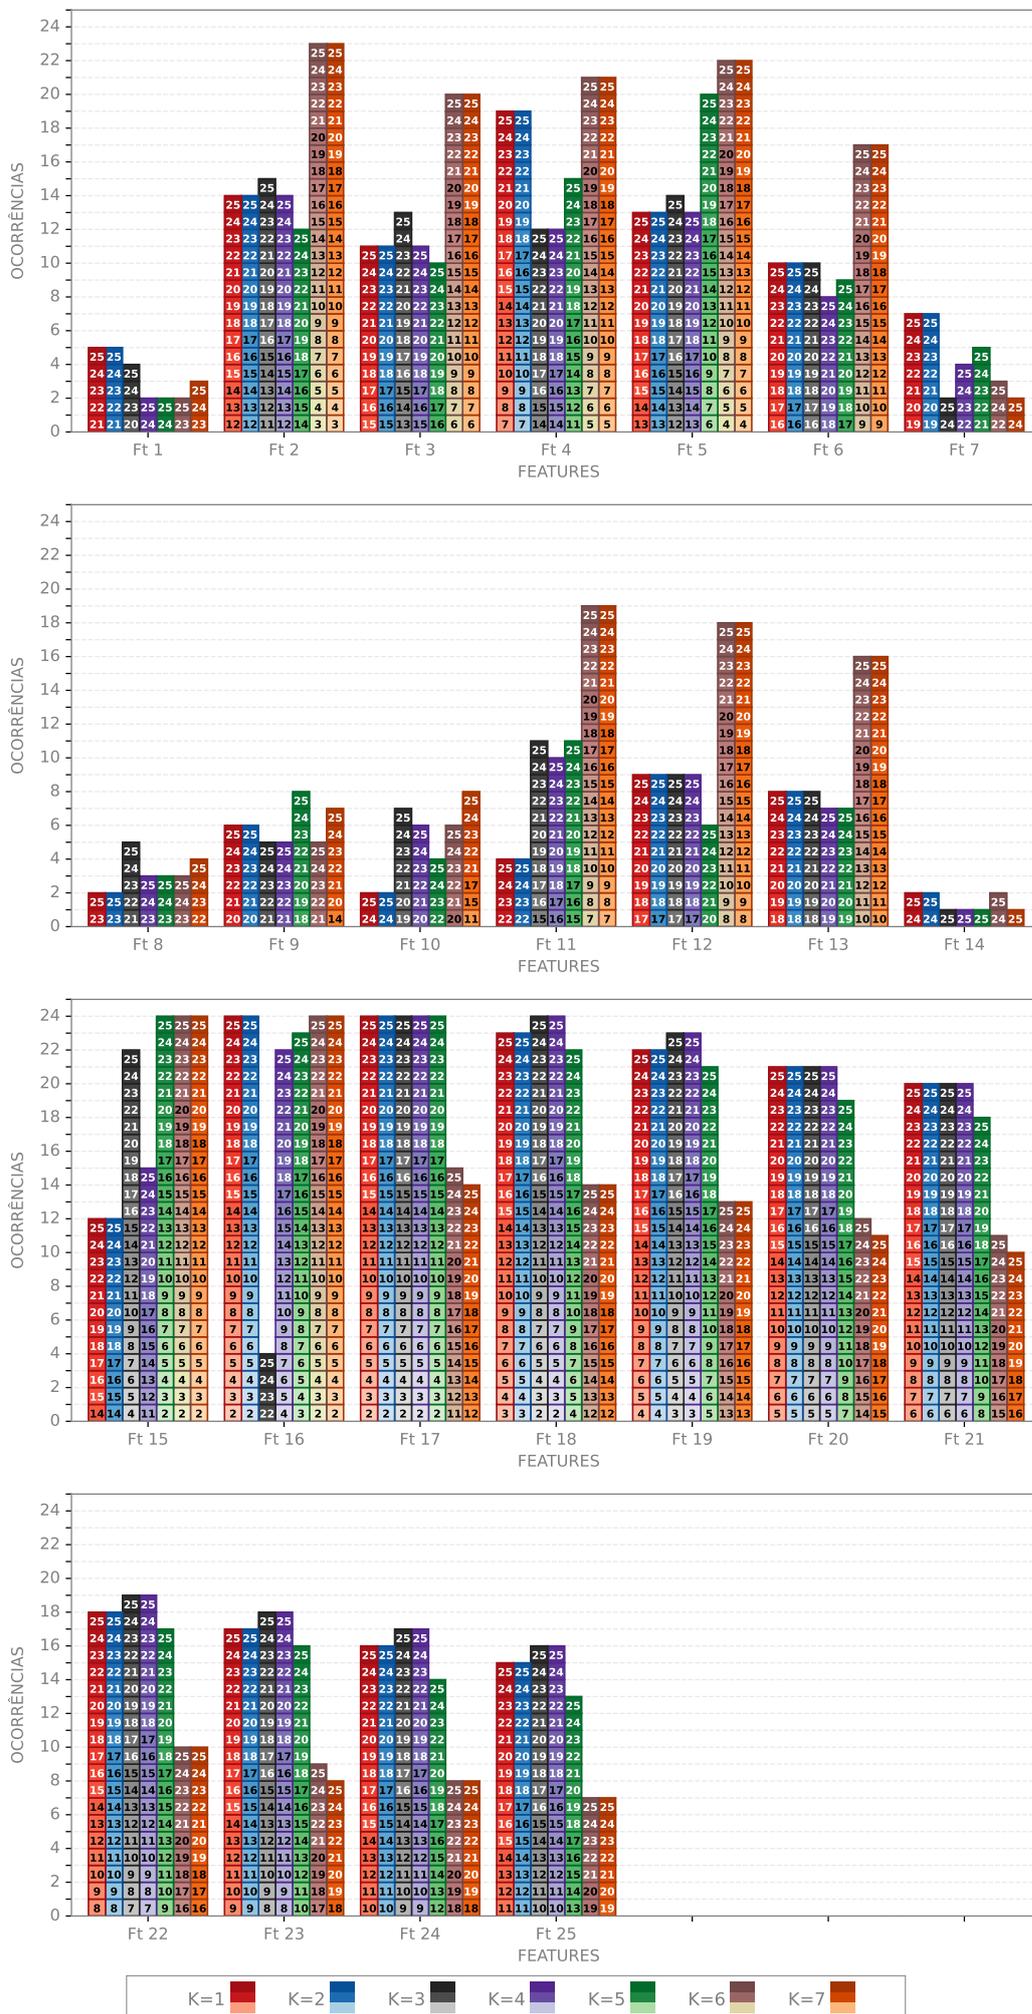
Figura 163 – Melhores combinações de *features* em SD-E8-G3-K.



K=1 K=2 K=3 K=4 K=5 K=6 K=7

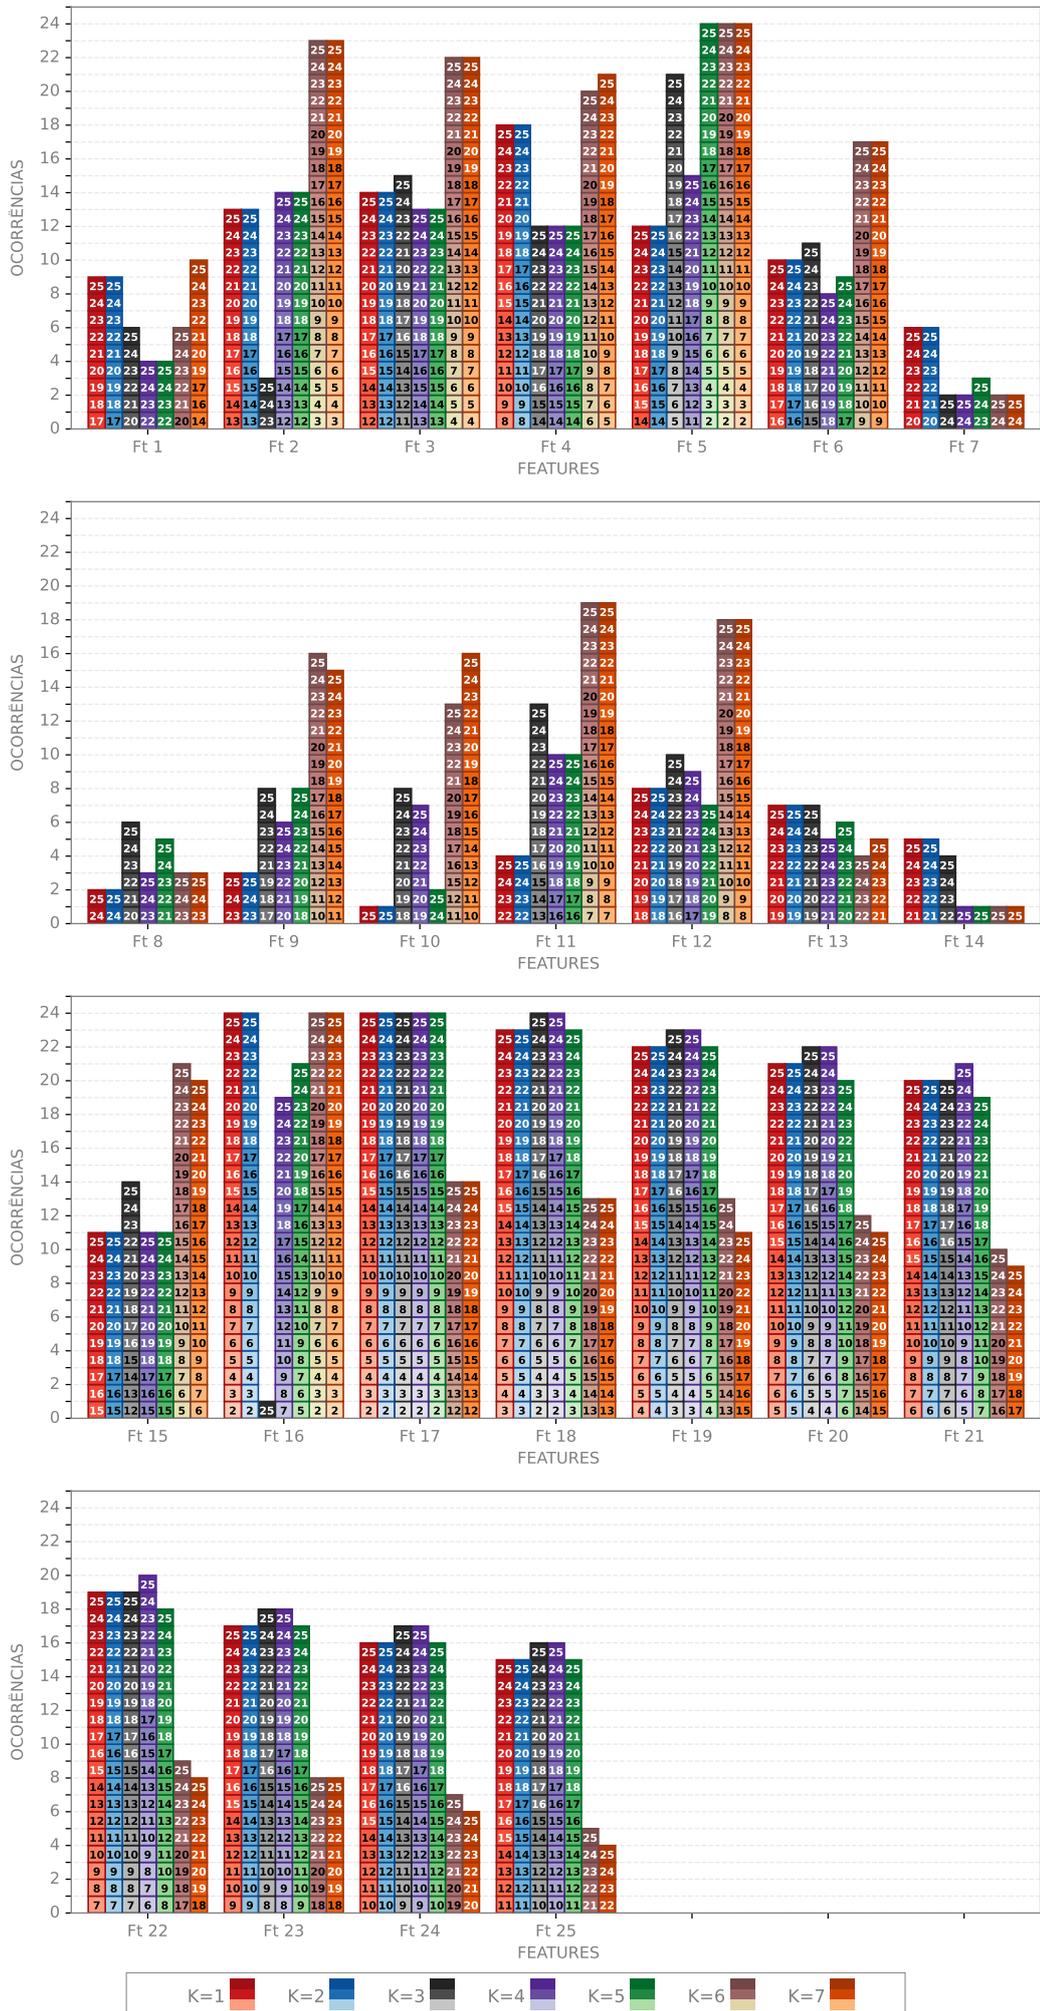
Fonte: Produzido pelo autor.

Figura 165 – Melhores combinações de *features* em TTC-E8-G3-K.



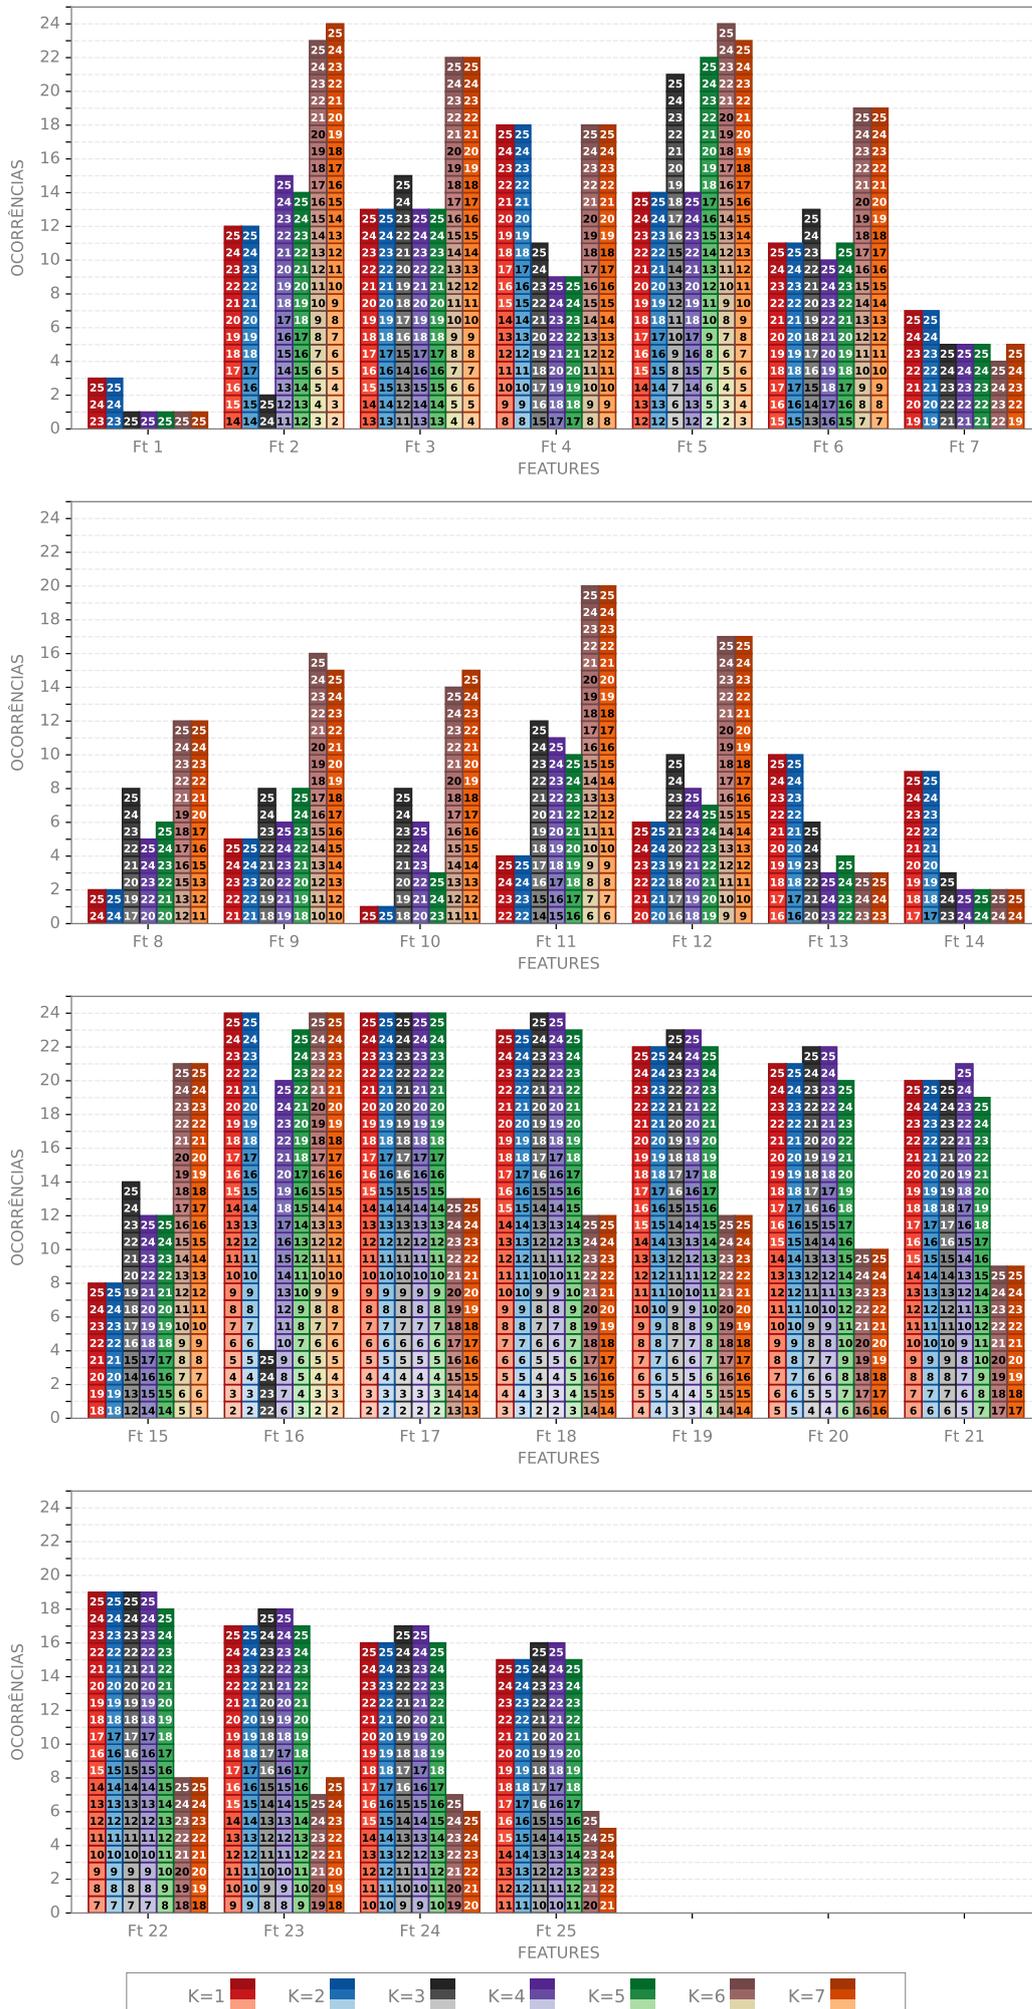
Fonte: Produzido pelo autor.

Figura 166 – Melhores combinações de *features* em EDT-E8-G3-K.



Fonte: Produzido pelo autor.

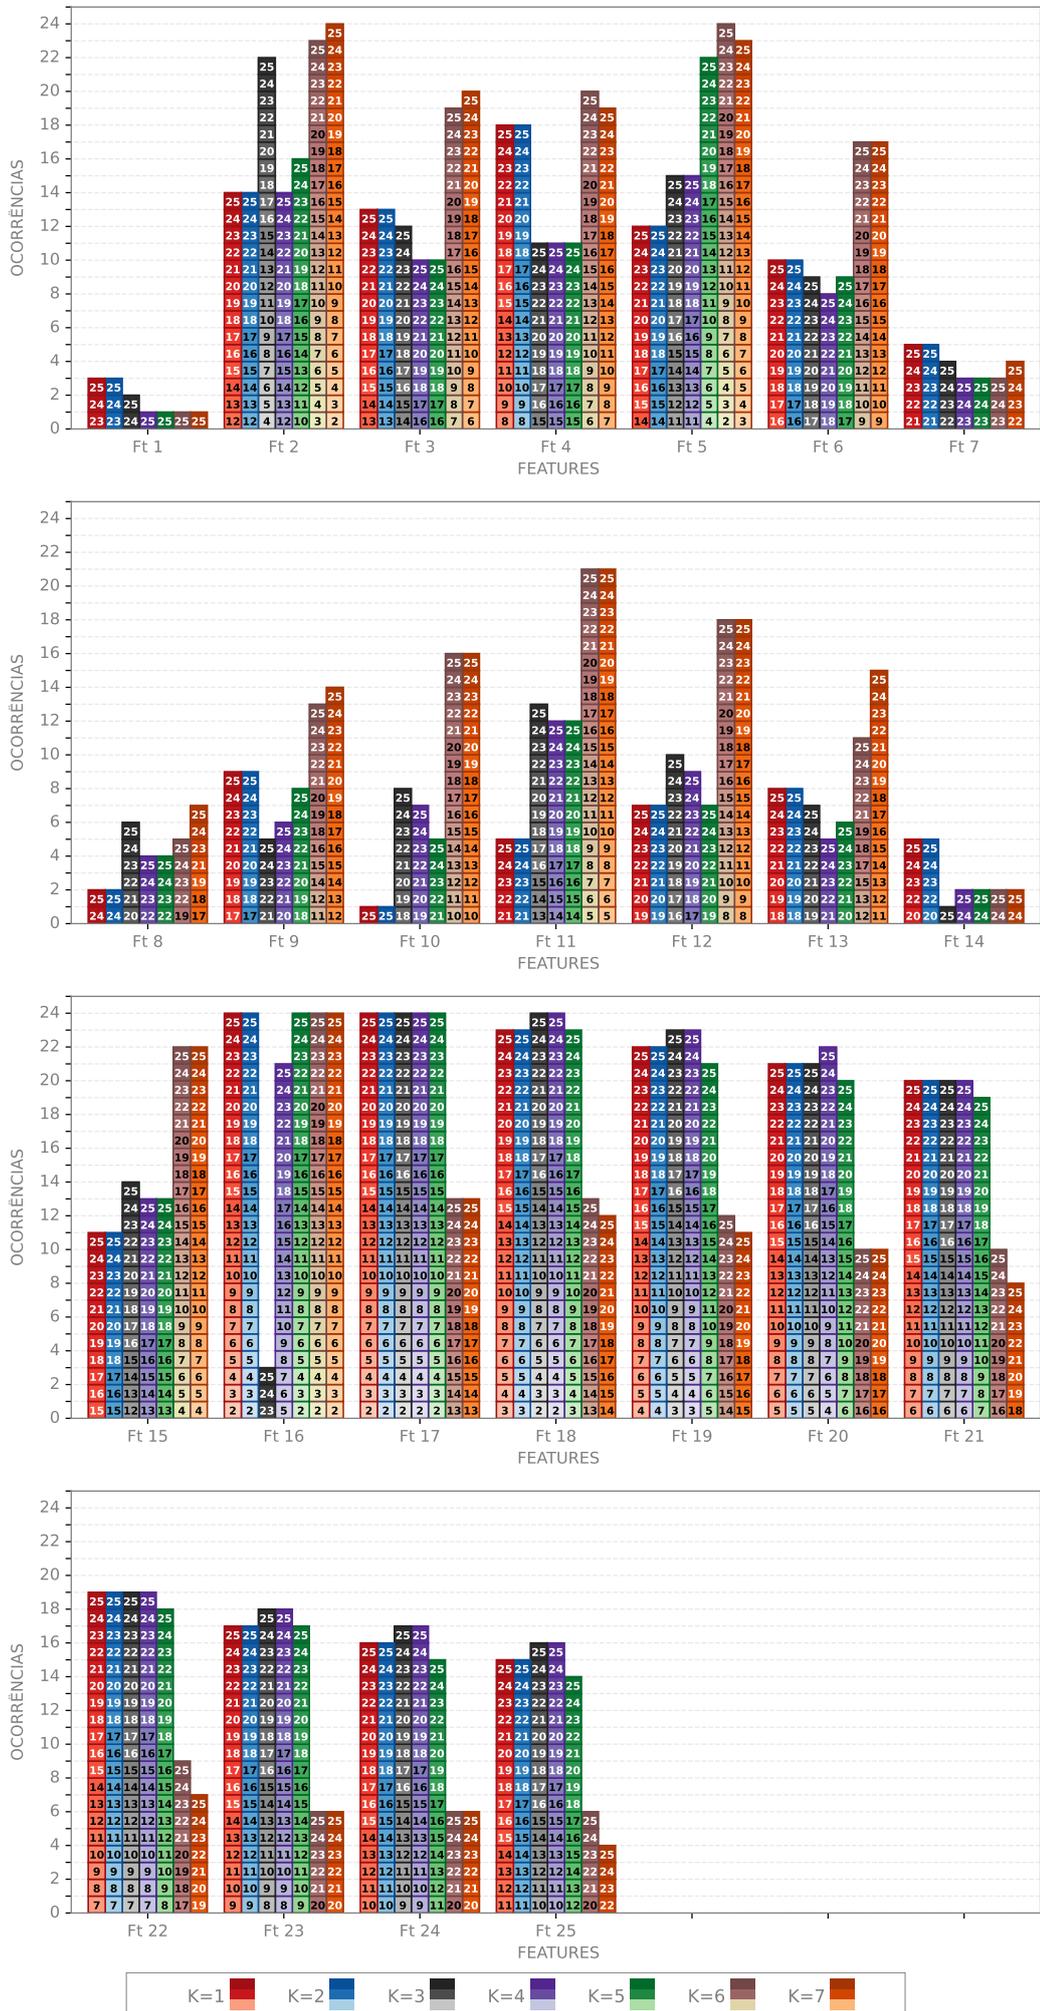
Figura 167 – Melhores combinações de *features* em RFC-E8-G3-K.



K=1 K=2 K=3 K=4 K=5 K=6 K=7

Fonte: Produzido pelo autor.

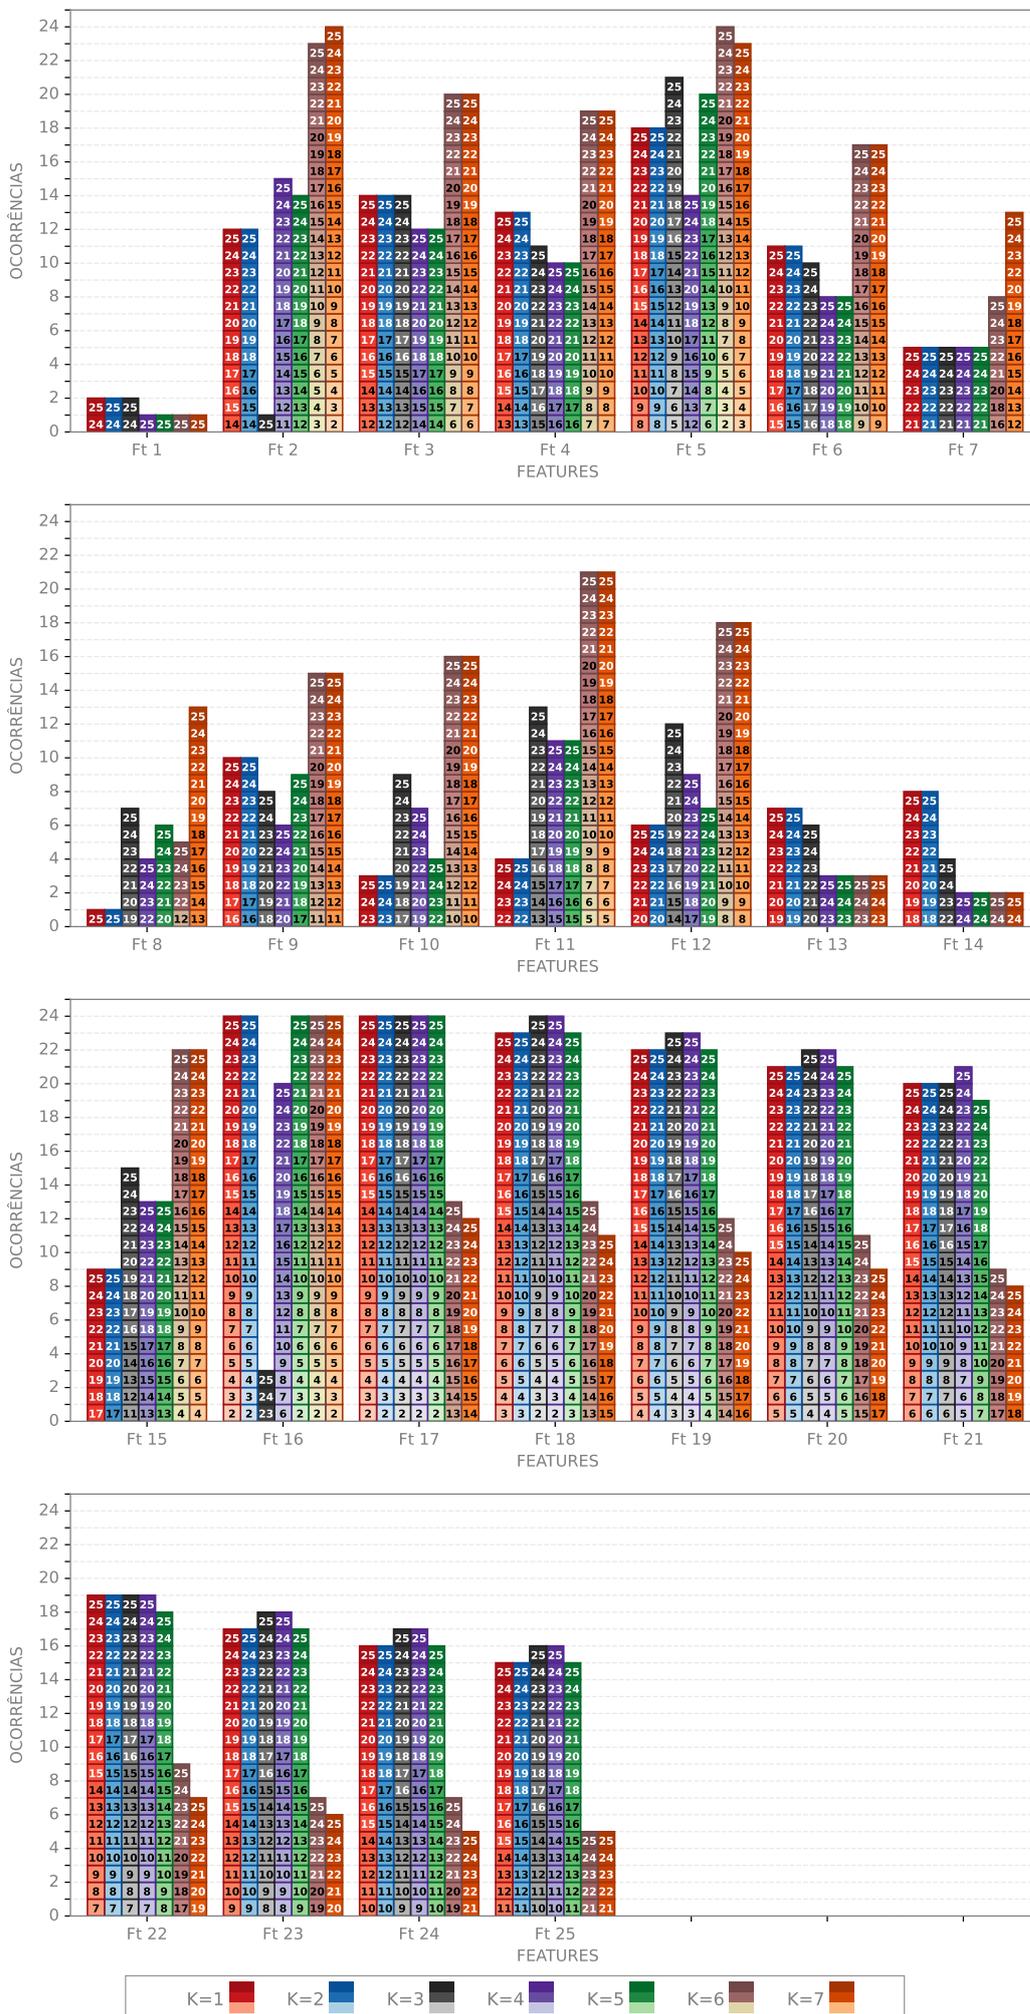
Figura 168 – Melhores combinações de *features* em OC-E8-G3-K.



K=1 K=2 K=3 K=4 K=5 K=6 K=7

Fonte: Produzido pelo autor.

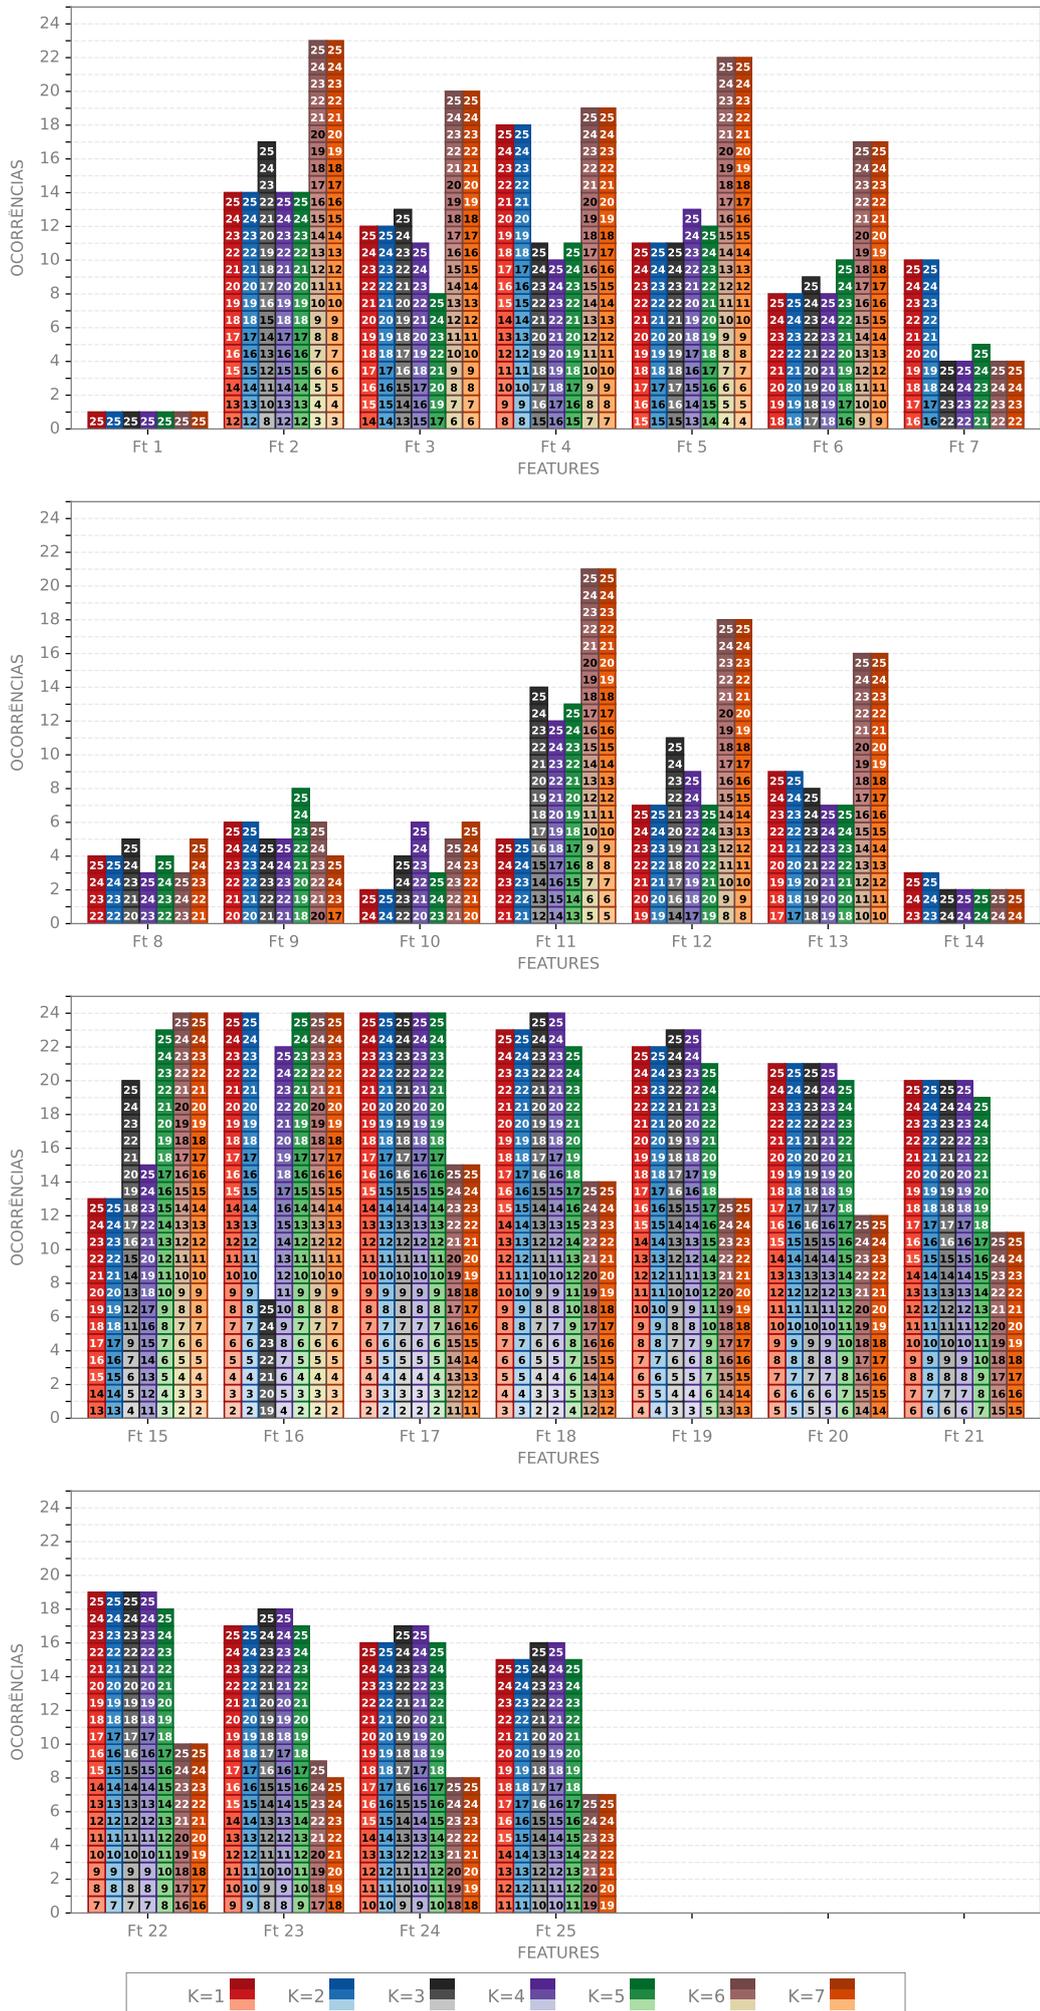
Figura 169 – Melhores combinações de *features* em VDS-E8-G3-K.



K=1 K=2 K=3 K=4 K=5 K=6 K=7

Fonte: Produzido pelo autor.

Figura 170 – Melhores combinações de *features* em BWC-E8-G3-K.



K=1 K=2 K=3 K=4 K=5 K=6 K=7

Fonte: Produzido pelo autor.

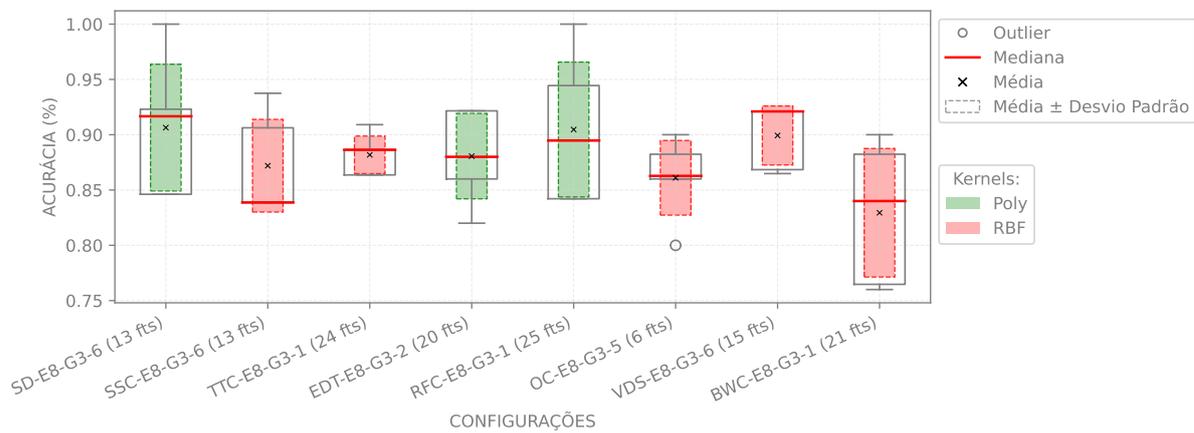
E8-G3: Resultados do módulo MTT

Prosseguindo com a análise de desempenho dos modelos SVM, todos os conjuntos de vetores derivados das combinações ótimas de *features* foram avaliados pelo módulo MTT. Os parâmetros atribuídos para os treinamentos dos classificadores mantêm-se consistentes com os previamente estabelecidos, conforme detalhado na Tabela 6. O limiar de treinamento foi estipulado em múltiplos de 10, variando no intervalo de 20 a 80.

Foram realizados um total de 10 348 800 treinamentos distintos para todas as configurações, especificadas na Tabela 33, assim como nos ensaios E6 e E7 do grupo G2. Ao final deste processo, os modelos que exibiram maiores médias de acurácias no processo de validação cruzada foram eleitos para os testes definitivos, utilizando o conjunto de dados especificamente reservado para essa finalidade.

Após o processamento de todos os conjuntos de vetores, considerando a variação do número de *features*, os resultados obtidos nos treinamentos com validação cruzada para os modelos que exibiram maior eficácia nos testes subsequentes, abrangendo todas as configurações, foram ilustrados na Figura 171.

Figura 171 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E8-G3. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.



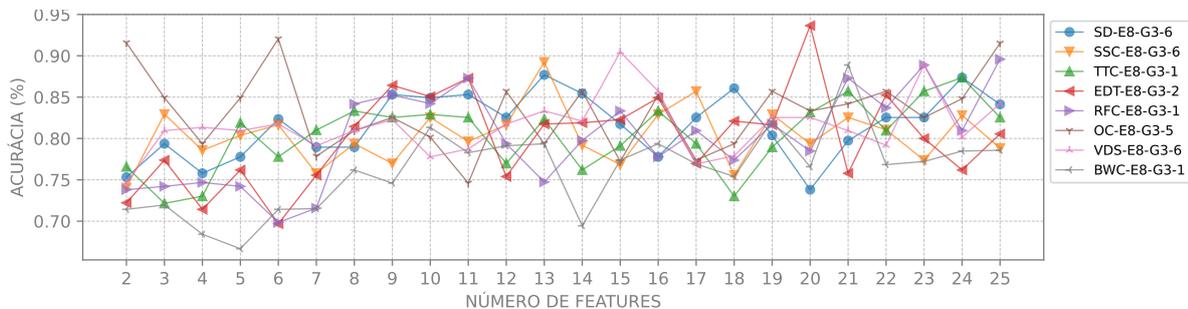
Fonte: Produzido pelo autor.

Nos resultados correspondentes às configurações avaliadas neste experimento, observa-se que nos treinamentos, os modelos de melhor desempenho nos testes exibiram acurácias inferiores às esperadas, tendo em vista os desempenhos alcançados em E7-G2. Apesar de algumas configurações, como SD-E8-G3-6 (13 fts) e RFC-E8-G2-1 (25 fts), atingirem acurácia máxima de 100%, mas com mínimas em torno de 85%. De modo geral, as acurácias médias permaneceram abaixo de 90%.

No que se refere aos *kernels*, o RBF mostrou-se novamente predominante entre os melhores hiperparâmetros, com uma ocorrência de 62.5%, seguido pelo *kernel* polinomial, com 37.5%. Embora o *kernel* polinomial geralmente tenha uma ligeira vantagem em termos de acurácia média, é importante notar que os desempenhos dos dois não é satisfatório. Por fim, as faixas de confiança (médias \pm desvios padrão) de todas as configurações reforçam a ideia de que os modelos não foram, de modo geral, consistentes em seus desempenhos.

Quanto à avaliação dos modelos, a Figura 172 ilustra os resultados referentes às configurações que se destacaram em termos de desempenhos em pelo menos um dos cenários avaliados para cada critério de parada da EMD.

Figura 172 – Resultados dos testes para as configurações que exibiram os melhores resultados em pelo menos um dos cenários avaliados, para cada critério de parada da EMD, em E8-G3. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.



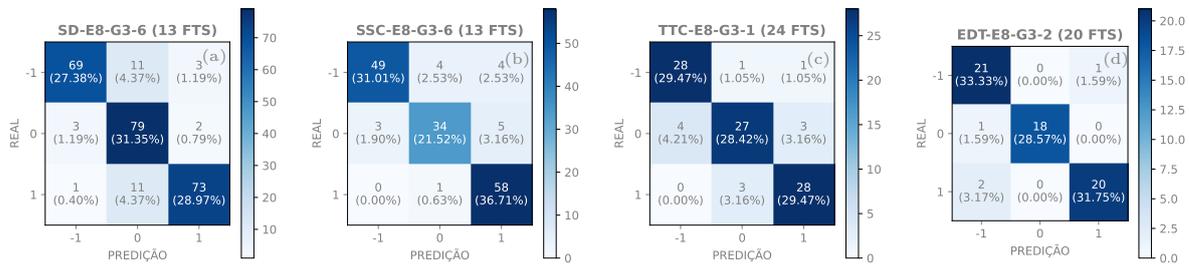
Fonte: Produzido pelo autor.

Constatam-se oscilações marcantes e os desempenhos dos modelos são insatisfatórios, não ultrapassando a faixa de 95%. As melhores configurações de E8-G3 resultaram em acurácias mínima de 87.36% e máxima de 93.65% para TTC-E8-G3-1 (24 fts) e EDT-E7-G3-2 (20 fts), respectivamente. É fato que em certas situações, como no caso de OC-E8-G3-5 (2 fts), a normalização potencializou a estrutura inerente dos dados, propiciando uma classificação mais acertada (acurácia de 92% para o caso mencionado). No entanto, em outros contextos, como observado em BWC-E8-G2-1 (5 fts), as conexões essenciais entre as *features* foram possivelmente obscurecidas, levando a uma péssima performance (inferior a 68% para o caso mencionado). Assim como nos ensaios anteriores, estas diferenças reforçam a premissa de que a escolha criteriosa da técnica de normalização é vital para maximizar as performances dos modelos classificadores.

Nas Figuras 173 e 174, são apresentadas as MCs referentes aos resultados dos modelos que exibiram melhores desempenhos nos testes para cada critério de parada. Observa-se que a configuração EDT-E8-G3-2 (20 fts) obteve o melhor desempenho neste ensaio, classificando erroneamente apenas quatro instâncias de 63 avaliadas.

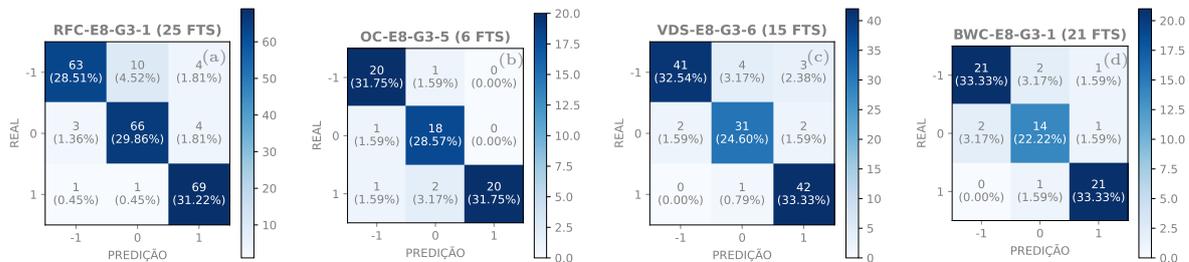
Os hiperparâmetros determinados para os modelos de melhor desempenho, bem

Figura 173 – MCs para as configurações SD-E8-G3, SSC-E8-G3, TTC-E8-G3 e EDT-E8-G3. Os escalares 1, 0 e -1 representam, respectivamente, as classes “alta”, “ruído” e “baixa”.



Fonte: Produzido pelo autor.

Figura 174 – MCs para as configurações RFC-E8-G3, OC-E8-G3, VDS-E8-G3 e BWC-E8-G3. Os escalares 1, 0 e -1 representam, respectivamente, as classes “alta”, “ruído” e “baixa”.



Fonte: Produzido pelo autor.

como as métricas acurácia, precisão, *recall*, *F1-score* e AUC, estão detalhados na Tabela 38. As configurações que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada estão destacadas na Tabela 38. Priorizou-se novamente o *F1-score* máximo, conforme descrito anteriormente.

Com base nas análises realizadas e considerando os resultados elencados na Tabela 38, conclui-se que os conjuntos de vetores definidos no formato F2, constituídos pelas combinações ótimas de *features* segundo a análise PFE, não replicaram o alto desempenho do sistema constatado no ensaio E7-G2, contrariando a hipótese levantada. Tal constatação pode ser atribuída à taxa de amostragem adotada, uma vez que a taxa de amostragem reduzida impacta diretamente na resolução espectral dos sinais (UNSER, 2000). Ressalta-se que a limitação dada pela baixa quantidade de amostras utilizadas pode ser contornada com o emprego da validação cruzada, que foi utilizada em todos os experimentos desenvolvidos nesta tese. É relevante mencionar que, no contexto do grupo G3, duas classes possuem atributos análogos (ambas contêm cigarras) e determinadas frequências não detectadas podem interferir na distinção das classes, possivelmente sendo ofuscadas pela taxa de amostragem adotada. Na Figura 175 são apresentadas representações médias dos vetores, em gráficos de radar, com taxas de amostragem de 6 kHz e 13 kHz. Observa-se que a

Tabela 38 – Melhores resultados em E8-G3. As configurações destacadas são as que proporcionaram o melhor desempenho, em termos de acurácia e $F1$ -score, para cada critério de parada. O termo “Poly” refere-se ao *kernel* Polinomial.

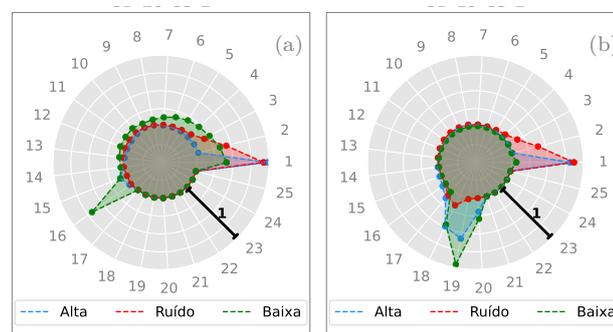
Configuração	Num. features	Amostras treino (%)	C	γ	Kernel	Acurácia	Precisão	Recall	F1-score
SD-ES-G3-1	24	50	100.0	10.0	Poly	0.84810	0.85062	0.85094	0.84667
SSC-ES-G3-1	19	80	1000.0	1	RBF	0.87302	0.87366	0.87000	0.87147
TTC-ES-G3-1	24	70	1000.0	1	RBF	0.87368	0.87366	0.87689	0.87429
EDT-ES-G3-1	10	70	1000.0	1000.0	RBF	0.90526	0.91016	0.90402	0.90649
RFC-ES-G3-1	25	30	0.001	1000.0	Poly	0.89593	0.89785	0.89804	0.89581
OC-ES-G3-1	9	40	1000.0	1000.0	RBF	0.86243	0.86263	0.86331	0.86228
VDS-ES-G3-1	19	70	1000.0	1	RBF	0.85263	0.85972	0.83767	0.84274
BWC-ES-G3-1	21	80	1000.0	0.1	RBF	0.88889	0.88321	0.88436	0.88349
SD-ES-G3-2	12	80	1000.0	100.0	RBF	0.87302	0.84679	0.84822	0.84727
SSC-ES-G3-2	16	70	1000.0	10.0	RBF	0.85263	0.86592	0.85151	0.85236
TTC-ES-G3-2	11	70	1000.0	1000.0	RBF	0.86316	0.86558	0.86118	0.86146
EDT-ES-G3-2	20	80	1000.0	10.0	Poly	0.93651	0.94246	0.93700	0.93875
RFC-ES-G3-2	10	80	1000.0	1000.0	RBF	0.87302	0.87383	0.87778	0.87357
OC-ES-G3-2	23	60	1000.0	10.0	RBF	0.84921	0.85644	0.85813	0.84849
VDS-ES-G3-2	8	80	100.0	1000.0	RBF	0.88889	0.88647	0.88047	0.88223
BWC-ES-G3-2	9	70	100.0	1000.0	RBF	0.81053	0.80573	0.81481	0.80861
SD-ES-G3-3	25	30	100.0	0.01	RBF	0.77376	0.79573	0.76813	0.76920
SSC-ES-G3-3	25	80	1	1	RBF	0.79365	0.81120	0.80230	0.79107
TTC-ES-G3-3	23	40	0.001	1000.0	Poly	0.78836	0.80163	0.78603	0.78901
EDT-ES-G3-3	25	40	1	1	RBF	0.74603	0.76494	0.75239	0.74197
RFC-ES-G3-3	25	20	100.0	0.1	SIGMOID	0.77381	0.79071	0.77723	0.77183
OC-ES-G3-3	23	40	100.0	0.1	RBF	0.75661	0.80225	0.75529	0.75551
VDS-ES-G3-3	25	70	1000.0	0.1	RBF	0.77895	0.79793	0.76322	0.76601
BWC-ES-G3-3	23	80	100.0	0.1	RBF	0.77778	0.81569	0.77965	0.78386
SD-ES-G3-4	10	50	1000.0	100.0	RBF	0.84177	0.84200	0.84189	0.84179
SSC-ES-G3-4	9	80	100.0	100.0	RBF	0.88889	0.89136	0.90079	0.88979
TTC-ES-G3-4	4	70	100.0	1000.0	RBF	0.84211	0.84422	0.84190	0.84141
EDT-ES-G3-4	7	30	1000.0	100.0	RBF	0.84615	0.85404	0.84938	0.84567
RFC-ES-G3-4	7	60	100.0	100.0	RBF	0.82540	0.83296	0.82518	0.82573
OC-ES-G3-4	24	80	1000.0	0.1	RBF	0.87302	0.88843	0.86977	0.87244
VDS-ES-G3-4	9	50	1000.0	10.0	RBF	0.83544	0.84006	0.83311	0.83574
BWC-ES-G3-4	4	40	100.0	1000.0	RBF	0.82540	0.82603	0.82852	0.82508
SD-ES-G3-5	21	20	0.001	100.0	Poly	0.86905	0.86916	0.86825	0.86817
SSC-ES-G3-5	22	50	0.001	1000.0	Poly	0.86709	0.86867	0.86510	0.86561
TTC-ES-G3-5	15	30	1	100.0	Poly	0.85068	0.86292	0.85096	0.85336
EDT-ES-G3-5	22	80	1000.0	10.0	RBF	0.90476	0.90837	0.91304	0.90371
RFC-ES-G3-5	21	70	0.01	100.0	Poly	0.88421	0.88529	0.88730	0.88575
OC-ES-G3-5	6	80	1000.0	1000.0	RBF	0.92063	0.92208	0.92310	0.92016
VDS-ES-G3-5	18	80	0.01	100.0	Poly	0.85714	0.86124	0.86213	0.85948
BWC-ES-G3-5	10	70	100.0	10.0	RBF	0.83158	0.82991	0.83016	0.82964
SD-ES-G3-6	13	20	100.0	10.0	Poly	0.87698	0.88776	0.87688	0.87812
SSC-ES-G3-6	13	50	1000.0	1000.0	RBF	0.89241	0.89326	0.88407	0.88641
TTC-ES-G3-6	25	80	100.0	100.0	RBF	0.85714	0.90323	0.84541	0.85347
EDT-ES-G3-6	24	80	100.0	10.0	Poly	0.87302	0.89638	0.84520	0.84994
RFC-ES-G3-6	16	80	1000.0	1000.0	RBF	0.88889	0.88198	0.89546	0.88349
OC-ES-G3-6	7	80	1000.0	1000.0	RBF	0.90476	0.92381	0.89927	0.90566
VDS-ES-G3-6	15	60	1000.0	1000.0	RBF	0.90476	0.90274	0.90554	0.90256
BWC-ES-G3-6	25	60	1000.0	100.0	RBF	0.81746	0.82041	0.82566	0.81520
SD-ES-G3-7	10	70	1000.0	1000.0	Poly	0.85263	0.86462	0.84494	0.84815
SSC-ES-G3-7	12	50	1000.0	10.0	Poly	0.83544	0.88444	0.83783	0.83518
TTC-ES-G3-7	14	50	1000.0	1000.0	RBF	0.85443	0.86569	0.84592	0.84786
EDT-ES-G3-7	14	60	1000.0	1000.0	RBF	0.86508	0.88829	0.86234	0.86549
RFC-ES-G3-7	11	80	0.001	1000.0	Poly	0.87302	0.88143	0.86393	0.86624
OC-ES-G3-7	13	60	0.001	1000.0	Poly	0.84921	0.84796	0.85119	0.84677
VDS-ES-G3-7	11	30	0.001	1000.0	Poly	0.85068	0.86300	0.85008	0.85190
BWC-ES-G3-7	6	40	1000.0	10.0	Poly	0.82011	0.84274	0.82011	0.81288

Fonte: Elaborada pelo autor.

variação na taxa de amostragem influencia diferentes *features*, tal como constatado no ensaio E3-G1.

Nesse sentido, no próximo ensaio a taxa de amostragem foi alterada para 13 kHz. Espera-se que esta alteração possa fornecer resultados satisfatórios, assim como nos experimentos de identificação.

Figura 175 – Comparação entre *features*, em média, extraídas a partir de sinais acústicos com taxas de amostragem de (a) 6 kHz e (b) 13 kHz.



Fonte: Produzido pelo autor.

4.2.3.2 Experimento E9

No experimento anterior constatou-se que o sistema proposto configurado com os parâmetros adotados em E7-G2 não apresentou o alto desempenho para a estimativa de densidade conforme apresentado para detecção. Dessa forma, a hipótese neste experimento é que a elevação na taxa de amostragem dos sinais possibilite uma melhor performance dos modelos, como mencionado no final da subseção anterior.

Os sinais empregado são os mesmos de E8-G3, derivados dos sinais originais e catalogados nas três classes investigadas. Foram consideradas duração e taxa de amostragem de 1 segundo e 13 kHz, respectivamente, para cada sinal. No tratamento via EMD, aplicaram-se os 8 critérios de parada e estipulou-se um máximo de 700 iterações por IMF. Assim como no ensaio E7-G2, os vetores continuam sendo estabelecidos no formato F2, e as 25 *features* combinadas de k em k , com k variando de 2 a 25. Quanto a normalização dos vetores, foram utilizadas as técnicas MN, MMN e LS, descritas na seção 2.5. Para a técnica MMN, realizou-se o reescalonamento das *features* para o intervalo $[0, 1]$, definindo $a = 0$ e $b = 1$. Por outro lado, para a técnica LS, exploraram-se cinco variações do coeficiente v , sendo $v \in \{0.01, 0.1, 1, 10, 100\}$. Os parâmetros específicos, associados a cada critério de parada, seguem os mais flexíveis adotados nos ensaios E4 e E5 do grupo G1. A única exceção é para o critério BWC, cuja configuração é derivada de E3-G1-3. As configurações investigadas neste experimento estão elencadas na Tabela 39.

E9-G3: Resultados do Módulo MEF

Os parâmetros empregados neste experimento requerem baixo custo computacional, conforme abordado anteriormente e listado na Tabela 40. Aliado a este aspecto, constatou-se uma qualitativa decomposição dos sinais, visto que as distribuições dos IOs, em média, estão na ordem de 10^{-1} ou abaixo, com exceção de BWC-G9-G3. Esta reduzida magnitude

Tabela 39 – Configurações para o experimento E9 do grupo G3.

Rótulos	Amostragem (kHz)	Tempo (s)	Configurações da EMD		Norma	It. Max.
			Critério de parada	Parâmetros		
SD-E9-G3-1	13	1	SD	$\varepsilon = 0.3$	MN	700
SSC-E9-G3-1			SSC	$S = 2$		
TTC-E9-G3-1			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E9-G3-1			EDT	$\varepsilon = 0.1$		
RFC-E9-G3-1			RFC	$R = 30$		
OC-E9-G3-1			OC	$\varepsilon = 0.2$		
VDS-E9-G3-1			VDS	95% de $m(t) < 0.05$		
BWC-E9-G3-1			BWC	mínimo de B_f^2 encontrado		
SD-E9-G3-2	13	1	SD	$\varepsilon = 0.3$	MMN	700
SSC-E9-G3-2			SSC	$S = 2$		
TTC-E9-G3-2			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E9-G3-2			EDT	$\varepsilon = 0.1$		
RFC-E9-G3-2			RFC	$R = 30$		
OC-E9-G3-2			OC	$\varepsilon = 0.2$		
VDS-E9-G3-2			VDS	95% de $m(t) < 0.05$		
BWC-E9-G3-2			BWC	mínimo de B_f^2 encontrado		
SD-E9-G3-3	13	1	SD	$\varepsilon = 0.3$	LS(0.01)	700
SSC-E9-G3-3			SSC	$S = 2$		
TTC-E9-G3-3			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E9-G3-3			EDT	$\varepsilon = 0.1$		
RFC-E9-G3-3			RFC	$R = 30$		
OC-E9-G3-3			OC	$\varepsilon = 0.2$		
VDS-E9-G3-3			VDS	95% de $m(t) < 0.05$		
BWC-E9-G3-3			BWC	mínimo de B_f^2 encontrado		
SD-E9-G3-4	13	1	SD	$\varepsilon = 0.3$	LS(0.1)	700
SSC-E9-G3-4			SSC	$S = 2$		
TTC-E9-G3-4			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E9-G3-4			EDT	$\varepsilon = 0.1$		
RFC-E9-G3-4			RFC	$R = 30$		
OC-E9-G3-4			OC	$\varepsilon = 0.2$		
VDS-E9-G3-4			VDS	95% de $m(t) < 0.05$		
BWC-E9-G3-4			BWC	mínimo de B_f^2 encontrado		
SD-E9-G3-5	13	1	SD	$\varepsilon = 0.3$	LS(1)	700
SSC-E9-G3-5			SSC	$S = 2$		
TTC-E9-G3-5			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E9-G3-5			EDT	$\varepsilon = 0.1$		
RFC-E9-G3-5			RFC	$R = 30$		
OC-E9-G3-5			OC	$\varepsilon = 0.2$		
VDS-E9-G3-5			VDS	95% de $m(t) < 0.05$		
BWC-E9-G3-5			BWC	mínimo de B_f^2 encontrado		
SD-E9-G3-6	13	1	SD	$\varepsilon = 0.3$	LS(10)	700
SSC-E9-G3-6			SSC	$S = 2$		
TTC-E9-G3-6			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E9-G3-6			EDT	$\varepsilon = 0.1$		
RFC-E9-G3-6			RFC	$R = 30$		
OC-E9-G3-6			OC	$\varepsilon = 0.2$		
VDS-E9-G3-6			VDS	95% de $m(t) < 0.05$		
BWC-E9-G3-6			BWC	mínimo de B_f^2 encontrado		
SD-E9-G3-7	13	1	SD	$\varepsilon = 0.3$	LS(100)	700
SSC-E9-G3-7			SSC	$S = 2$		
TTC-E9-G3-7			TTC	$\alpha = 0.1, \theta_1 = 0.1, \theta_2 = 0.5$		
EDT-E9-G3-7			EDT	$\varepsilon = 0.1$		
RFC-E9-G3-7			RFC	$R = 30$		
OC-E9-G3-7			OC	$\varepsilon = 0.2$		
VDS-E9-G3-7			VDS	95% de $m(t) < 0.05$		
BWC-E9-G3-7			BWC	mínimo de B_f^2 encontrado		

Fonte: Elaborada pelo autor.

dos IOs indica uma elevada ortogonalidade entre as IMFs, o que favorece a precisão e a clareza dos resultados derivados da EMD.

Observa-se um baixo número de *outliers* com valores superiores a 1. Como a energia mínima registrada é igual a 1, conclui-se que a EMD não foi eficaz na decomposição de alguns sinais em componentes ortogonais. Portanto, as IMFs associadas a essas decomposições são categorizadas como de qualidade inferior. Em relação a esse aspecto, é notório que

Tabela 40 – Detalhes sobre a distribuição dos IOs e o Tempo Médio de Decomposição (TMD), expresso em segundos, para todas as configurações. O termo “Lim. sup.” refere-se a $Q3 + 1.5 \cdot IIQ$, sendo $Q3$ o terceiro quartil e IIQ o intervalo interquartil.

Configuração	min(E)	min(IO)	Lim. sup. (IO)	Média (IO)	Outliers > 1	TMD (s)
SD-E9-G3		$2.27 \cdot 10^{-2}$	0.16829	$8.26 \cdot 10^{-2}$	0	0.20
SSC-E9-G3		$1.94 \cdot 10^{-2}$	0.22976	$2.27 \cdot 10^{-1}$	5	2.59
TTC-E9-G3		$1.61 \cdot 10^{-2}$	0.29201	$3.40 \cdot 10^{-1}$	17	4.31
EDT-E9-G3		$3.48 \cdot 10^{-2}$	0.20775	$1.50 \cdot 10^{-1}$	7	1.06
RFC-E9-G3	1	$1.31 \cdot 10^{-2}$	0.21400	$2.25 \cdot 10^{-1}$	10	0.85
OC-E9-G3		$2.33 \cdot 10^{-2}$	0.22958	$3.84 \cdot 10^{-1}$	10	1.29
VDS-E9-G3		$1.35 \cdot 10^{-2}$	0.15685	$4.40 \cdot 10^{-1}$	4	2.05
BWC-E9-G3		$2.35 \cdot 10^{-2}$	1.6978	7.15	51	81.57

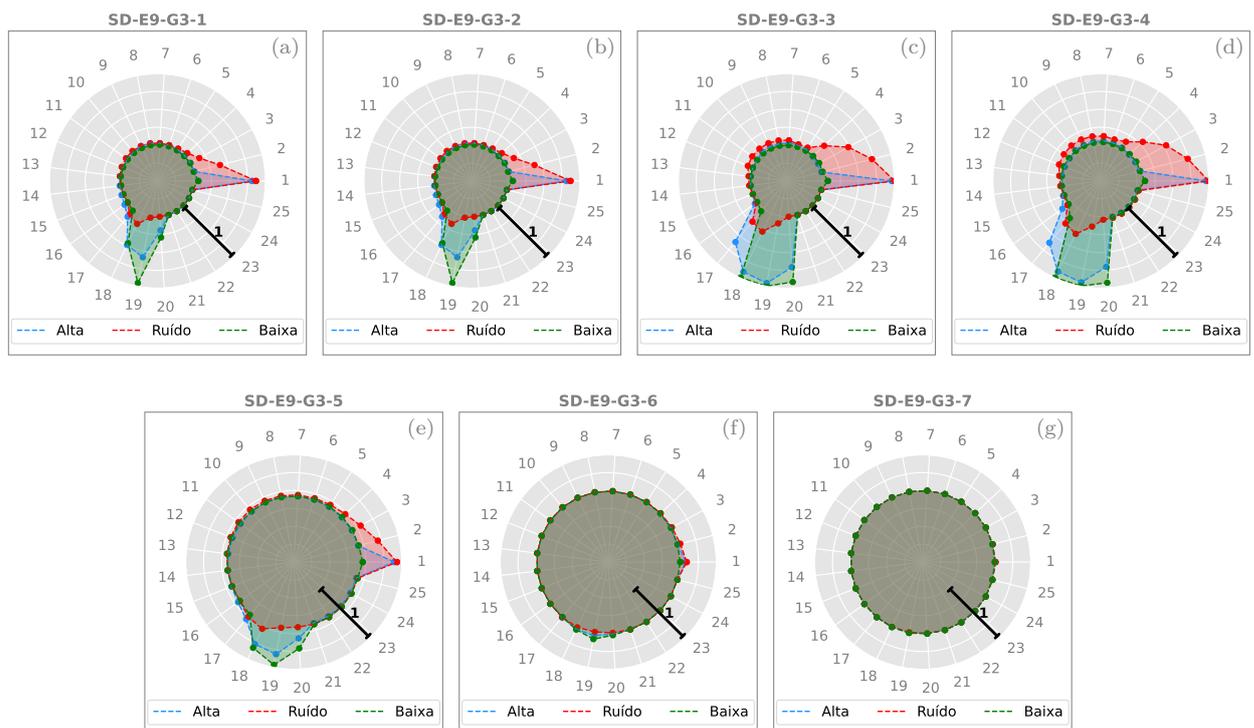
Fonte: Elaborada pelo autor.

as configurações que envolvem os critérios de parada SD, SSC, EDT e VDS apresentam uma menor quantidade de *outliers*.

E9-G3: Resultados do Módulo MNF

Prosseguindo, o módulo MNF é empregado para a normalização dos vetores. Neste ensaio, adotaram-se as três técnicas de normalização (MN, MMN e LS), em consonância com os ensaios anteriores. Na Figura 176, são exibidos os gráficos de radar que ilustram as médias dos vetores associados a cada classe. Analogamente ao que foi observado nos demais experimentos, as classes são visualmente distinguíveis.

Figura 176 – Gráficos de radar das *features*, em média, para as classes “alta”, “baixa” e “ruído” das configurações SD-E9-G3.



Fonte: Produzido pelo autor.

Para a classe “ruído”, as energias são distribuídas principalmente, em média, nas quatro primeiras *features*, decrescendo progressivamente, com um pico proeminente na primeira. Em contraste com as médias apresentadas em E8-G3, nota-se ainda uma leve distribuição de energias nas *features* de número 17 a 19. Os vetores associados à classe “baixa” evidenciam, em média, uma baixa distribuição de energia na primeira *feature*, concentrando nas *features* de número 18 a 20, com pico na décima nona. Em contrapartida, os vetores da classe “alta” direcionam as energias, em média, para as *features* de número 1, 17, 18, 19 e 20, com ápice nas de número 1 e 19. As características observadas nos gráficos de distribuições das *features*, reescaladas e transformadas, são também identificadas nas demais configurações exploradas. Assim, visando evitar redundâncias, optou-se por apresentar somente os gráficos pertinentes às configurações SD-E9-G3.

Os gráficos reforçam, em média, as diferenças notáveis entre os vetores das classes. No entanto, semelhante ao que foi constatado nos experimentos anteriores, as distinções entre os vetores tornam-se visualmente imperceptíveis em SD-E9-G3-7, uma vez que convergem significativamente em direção à média. Apesar deste comportamento, ensaios precedentes evidenciaram a capacidade dos modelos SVM de alcançar performances satisfatórias, o que também se espera neste ensaio.

E9-G3: Resultados do Módulo MPFE

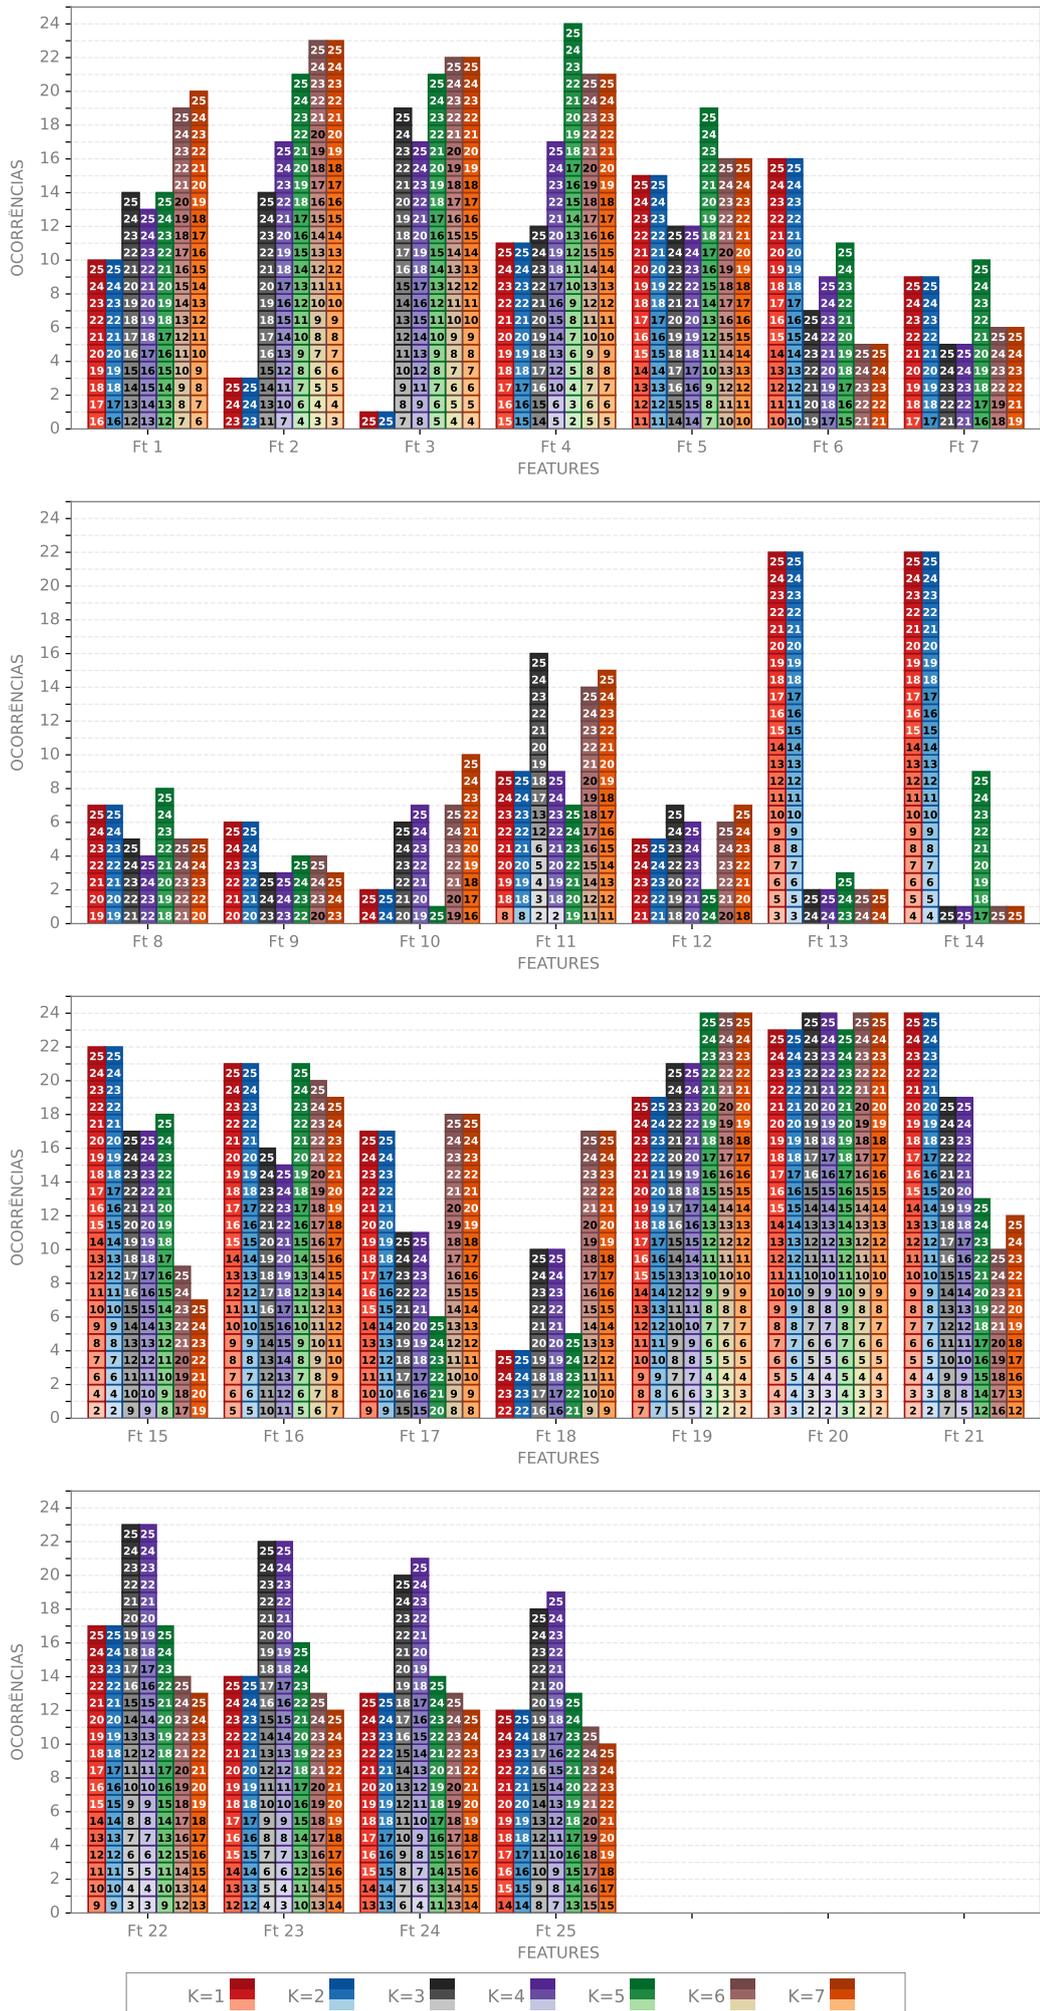
Dando sequência à avaliação dos vetores, todos os conjuntos derivados das possíveis combinações de *features* foram submetidos ao módulo MPFE. Especificamente, consideraram-se as 25 *features* combinadas de k em k , com k inteiro variando de 2 a 25, abrangendo todas as configurações. Para cada configuração indicada na [Tabela 39](#) foram examinadas 33 554 406 combinações, somando um total de 1 879 046 736 combinações avaliadas. Novamente, a métrica para determinação dos melhores resultados foi a distância mínima entre o ponto P , que representa o conjunto avaliado, e o VO.

Assim como em E8-G3, disposições dos pontos nos PP são consistentes com as descritas no ensaio E7-G2. Portanto, dentre os resultados do módulo MPFE, optou-se por destacar somente as combinações ótimas de *features*, conforme Figuras [Figura 177](#) à [Figura 184](#). Esta concordância entre os resultados é embasada no fato de que os 315 sinais acústicos utilizados nos experimentos desse grupo também pertencerem ao grupo de 1526 sinais empregados nos ensaios dos dois primeiros grupos, com o diferencial de que foram rotulados em três classes.

De forma análoga ao observado nos experimentos anteriores, nota-se pela variação no número de ocorrências em cada grupo de barras, correspondente a cada *feature*, a influência das técnicas de normalização sobre a importância de cada *feature*. Para SD-E9-G3, por exemplo, a quarta *feature* constitui todos os vetores dados pelas melhores

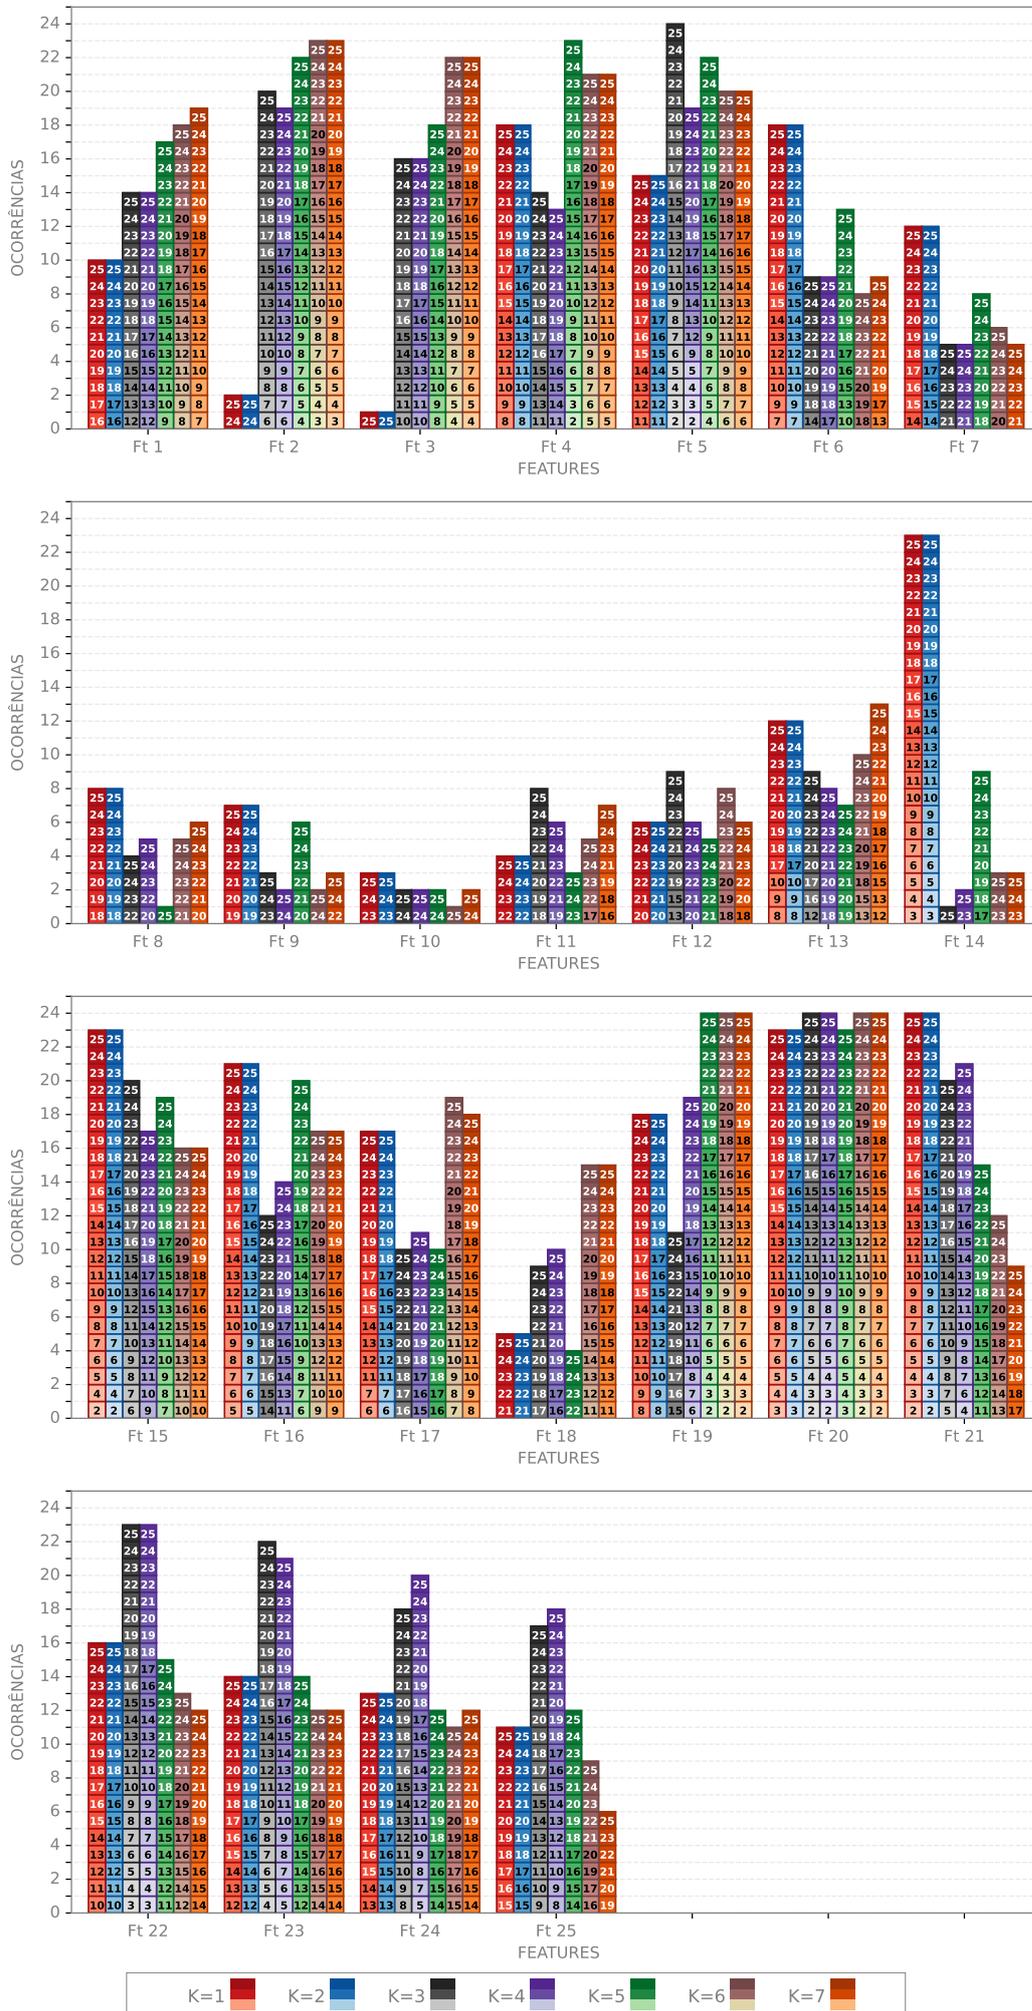
combinações, segundo a PFE, para a técnica LS(1) enquanto as outras influenciam esta mesma *feature* a um menor número de ocorrências. Um comportamento semelhante pode ser observado para todas as configurações avaliadas.

Figura 177 – Melhores combinações de *features* em SD-E9-G3-K.



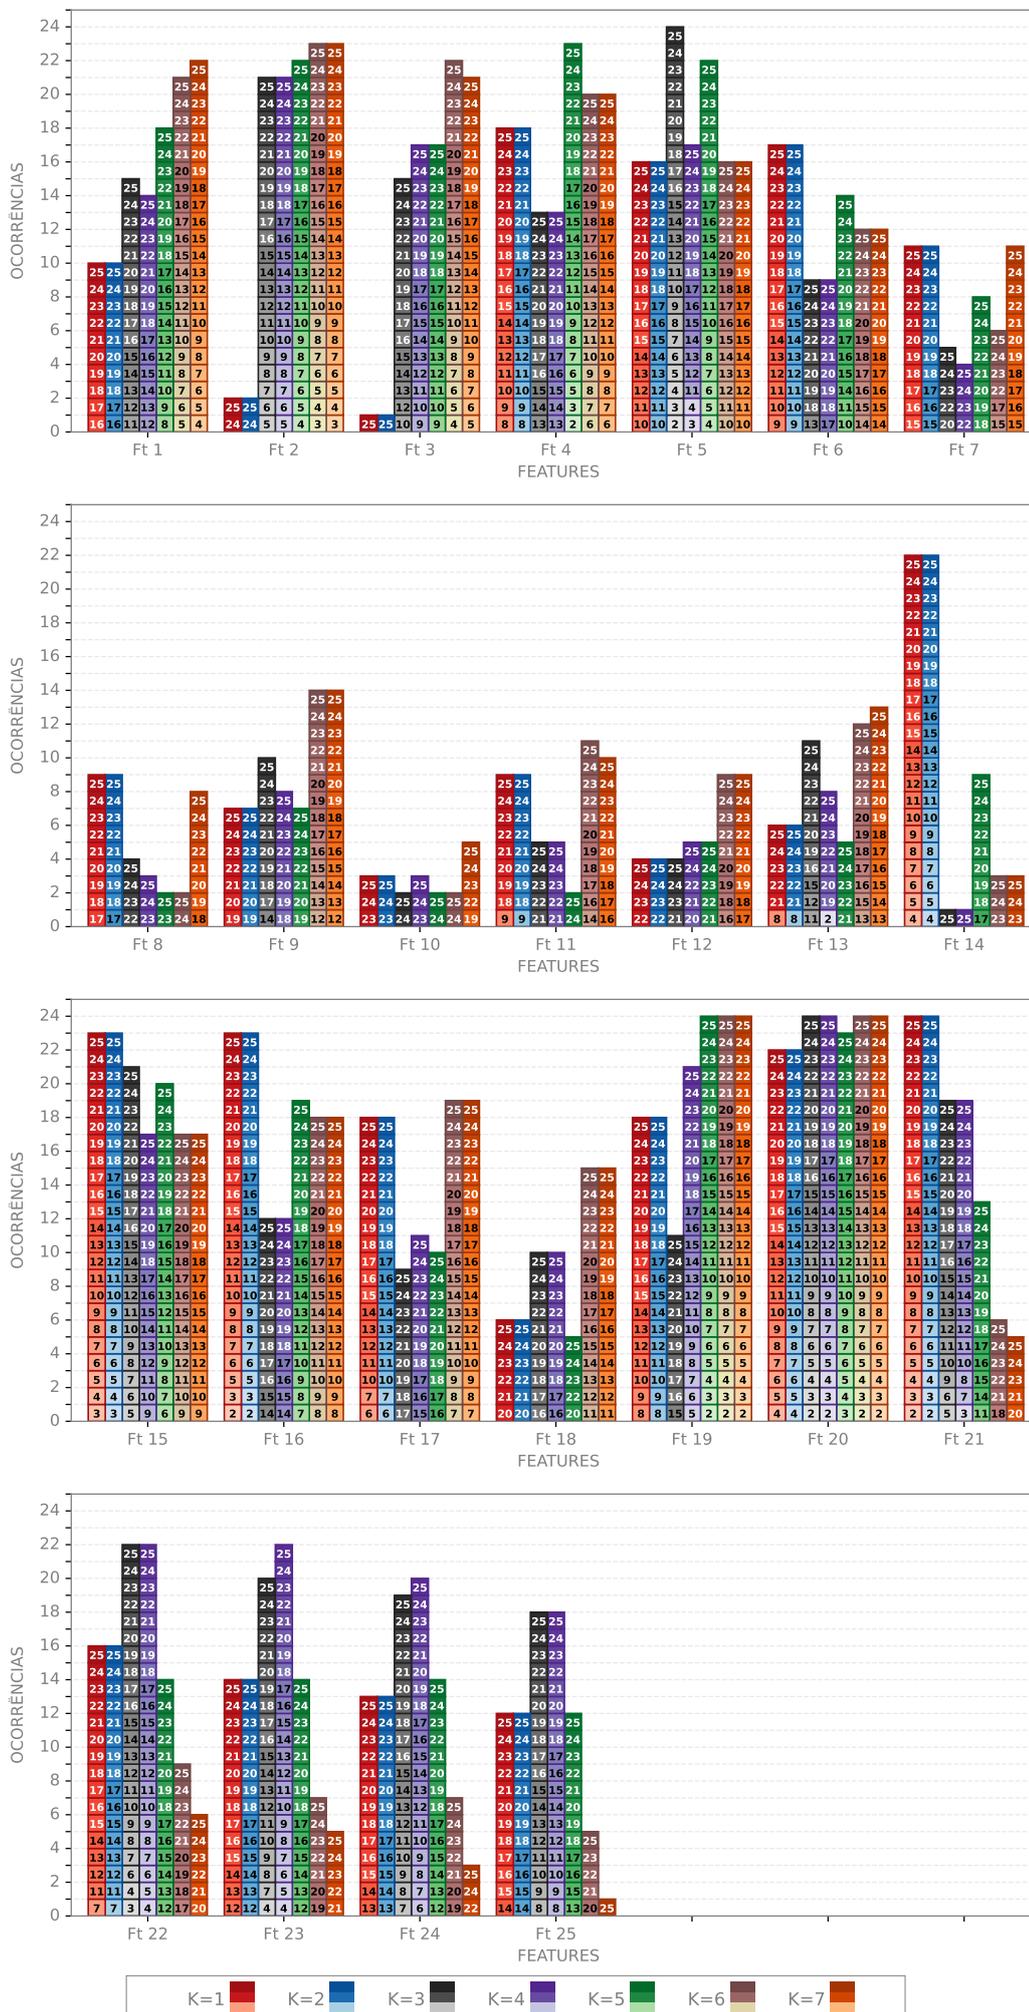
Fonte: Produzido pelo autor.

Figura 178 – Melhores combinações de *features* em SSC-E9-G3-K.



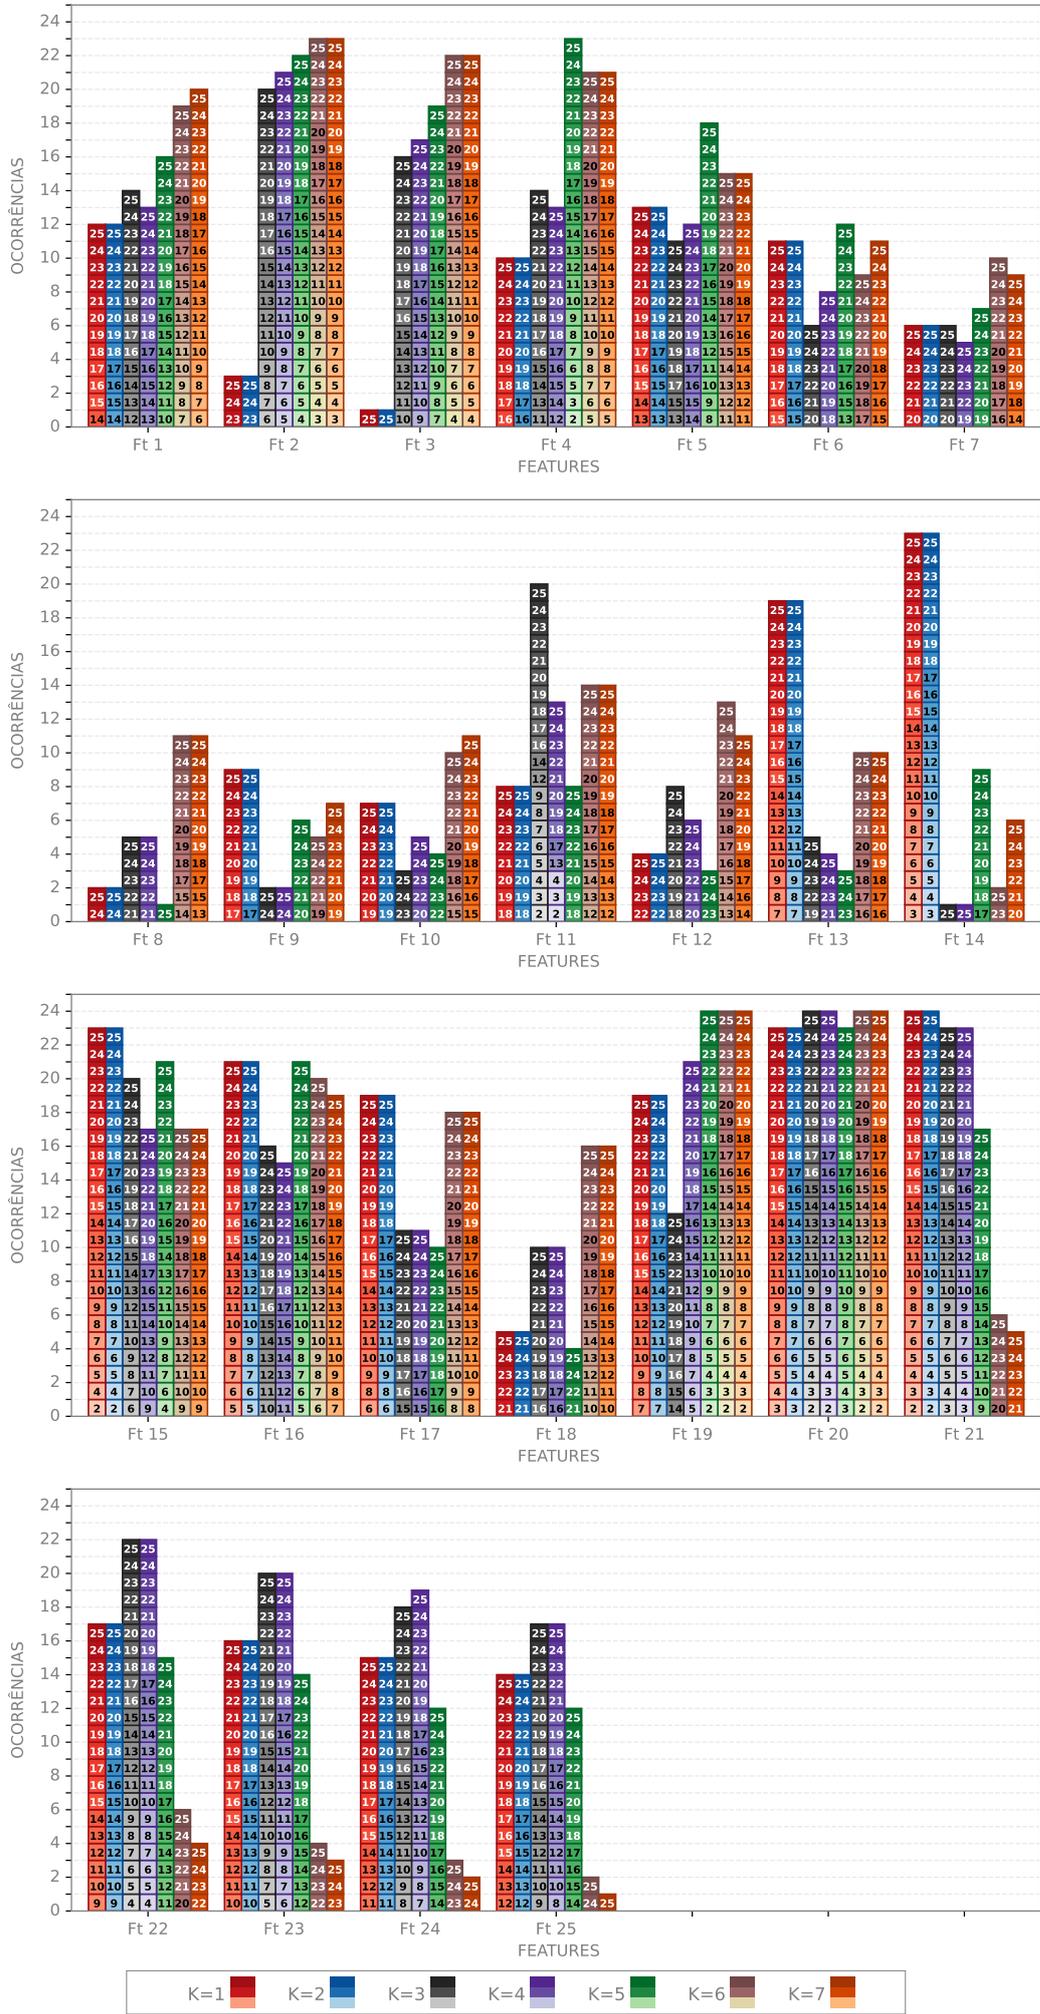
Fonte: Produzido pelo autor.

Figura 179 – Melhores combinações de *features* em TTC-E9-G3-K.



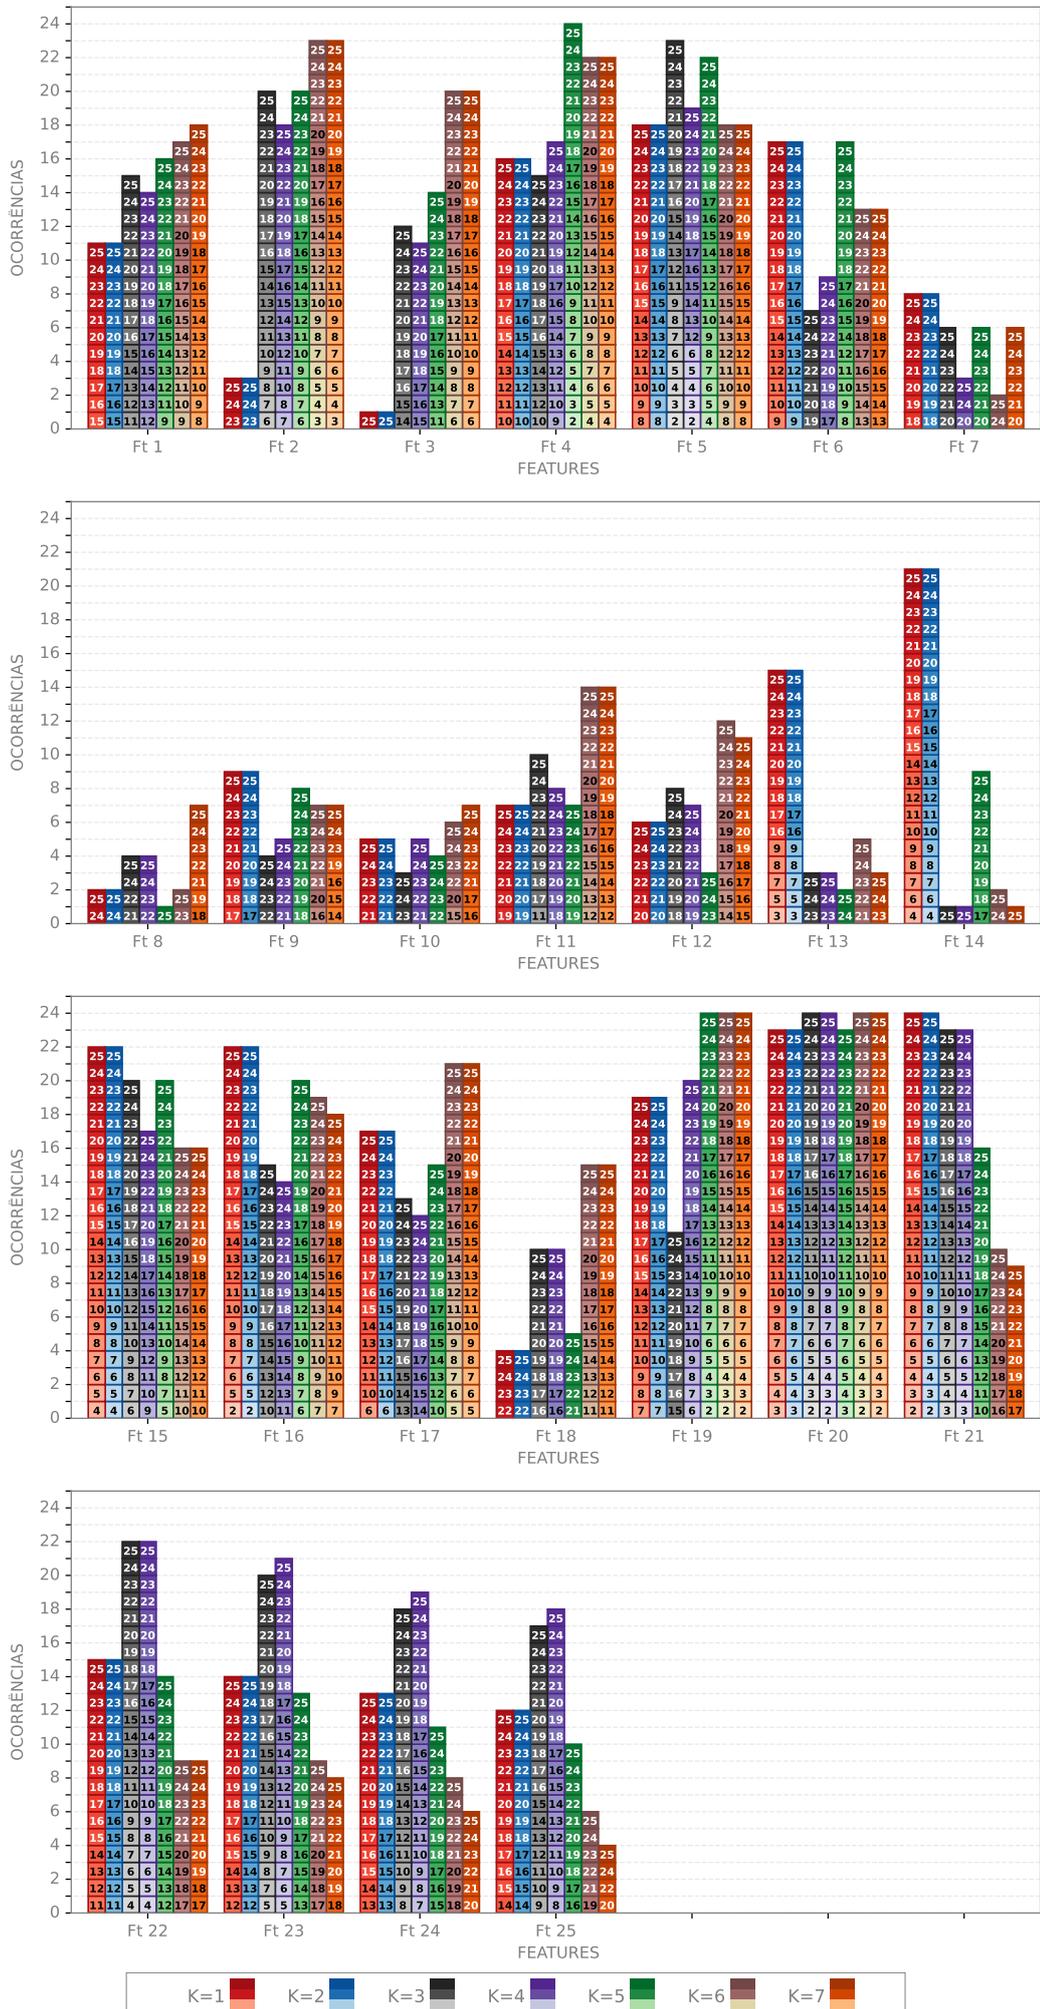
Fonte: Produzido pelo autor.

Figura 180 – Melhores combinações de *features* em EDT-E9-G3-K.



Fonte: Produzido pelo autor.

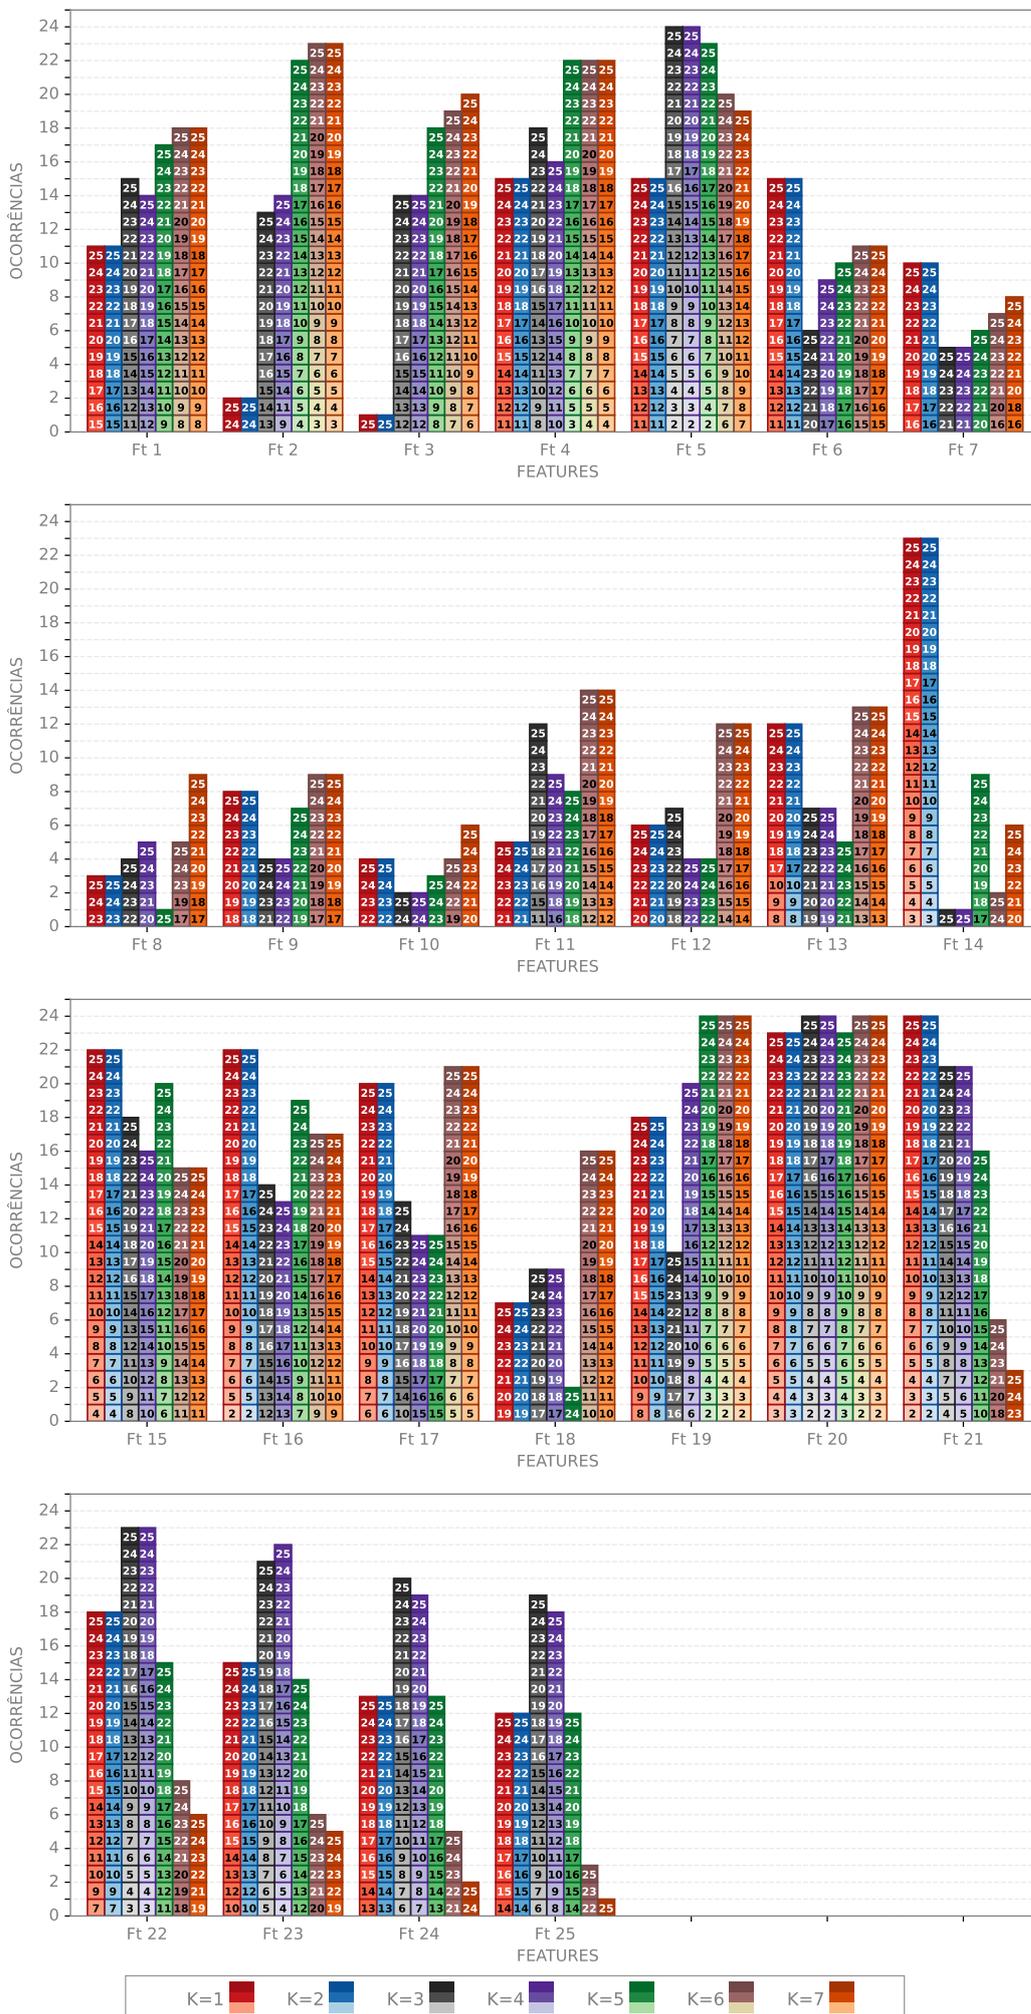
Figura 181 – Melhores combinações de *features* em RFC-E9-G3-K.



K=1 K=2 K=3 K=4 K=5 K=6 K=7

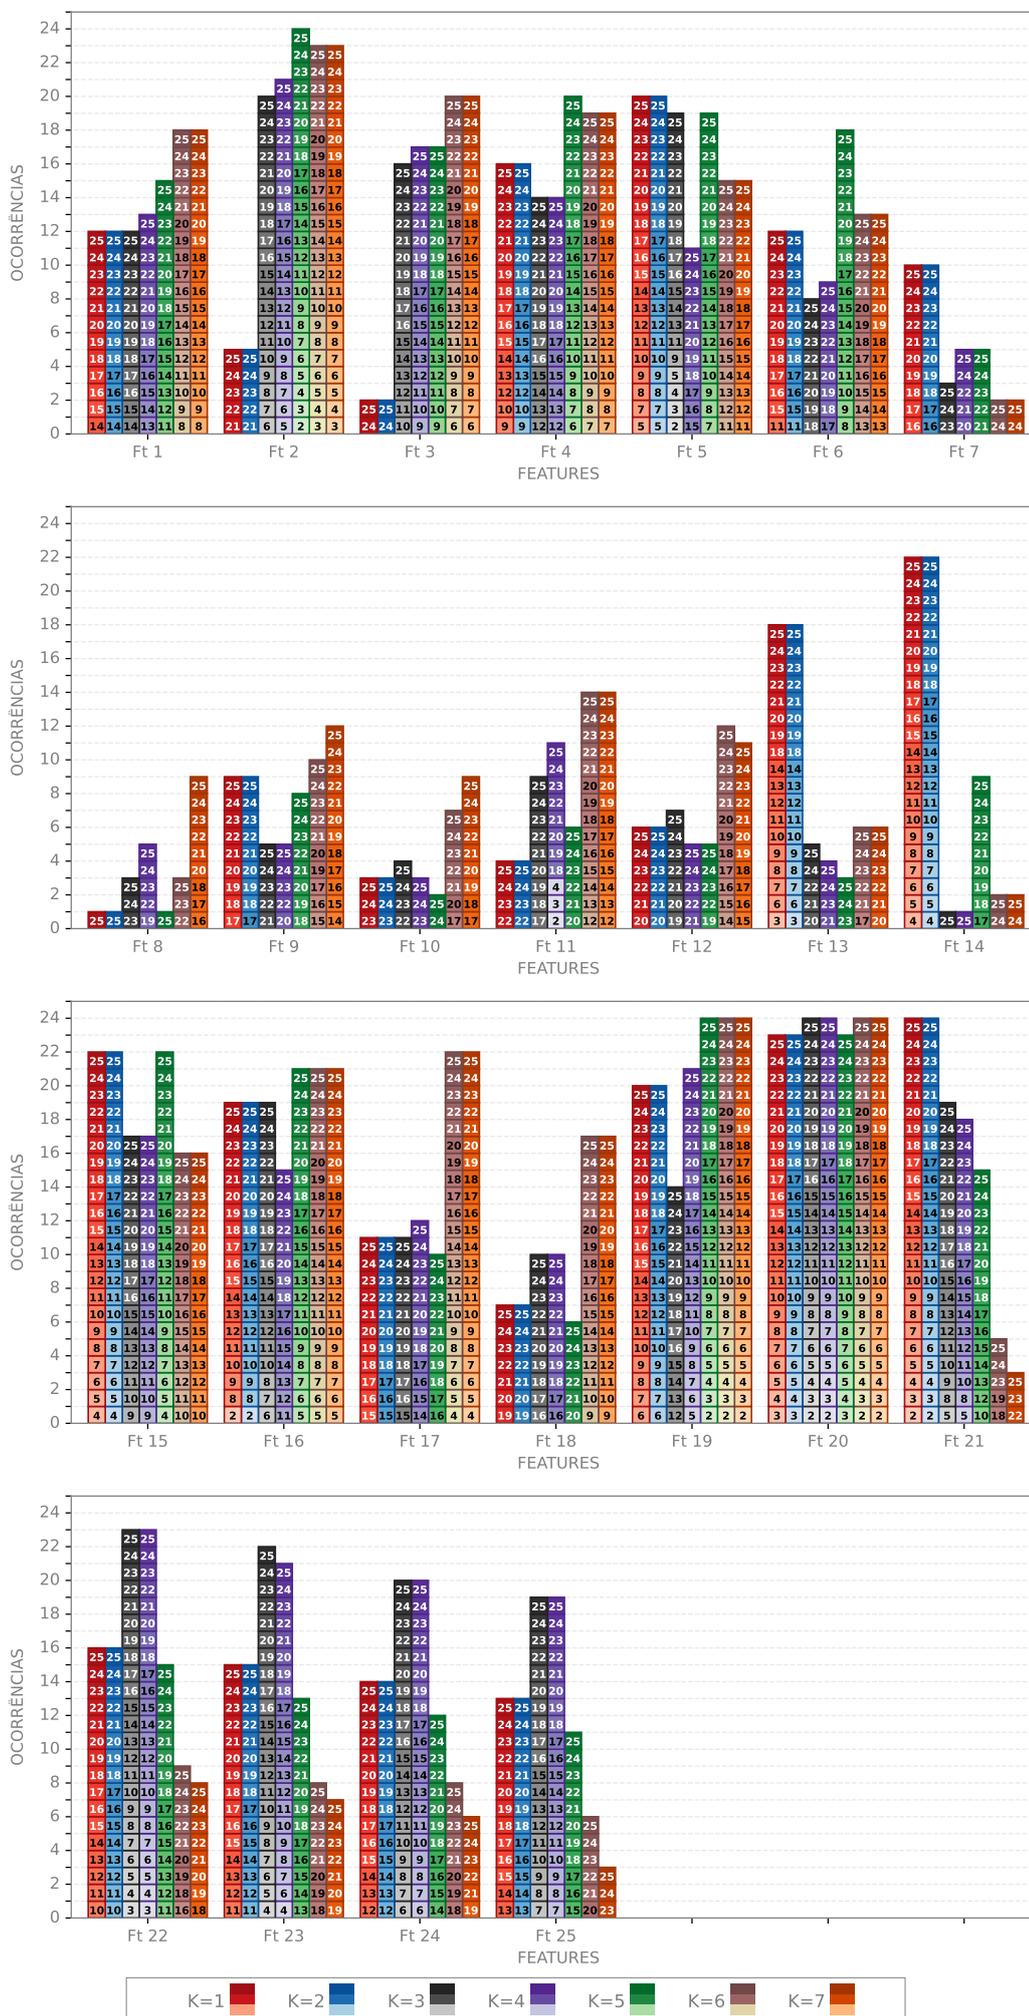
Fonte: Produzido pelo autor.

Figura 182 – Melhores combinações de *features* em OC-E9-G3-K.



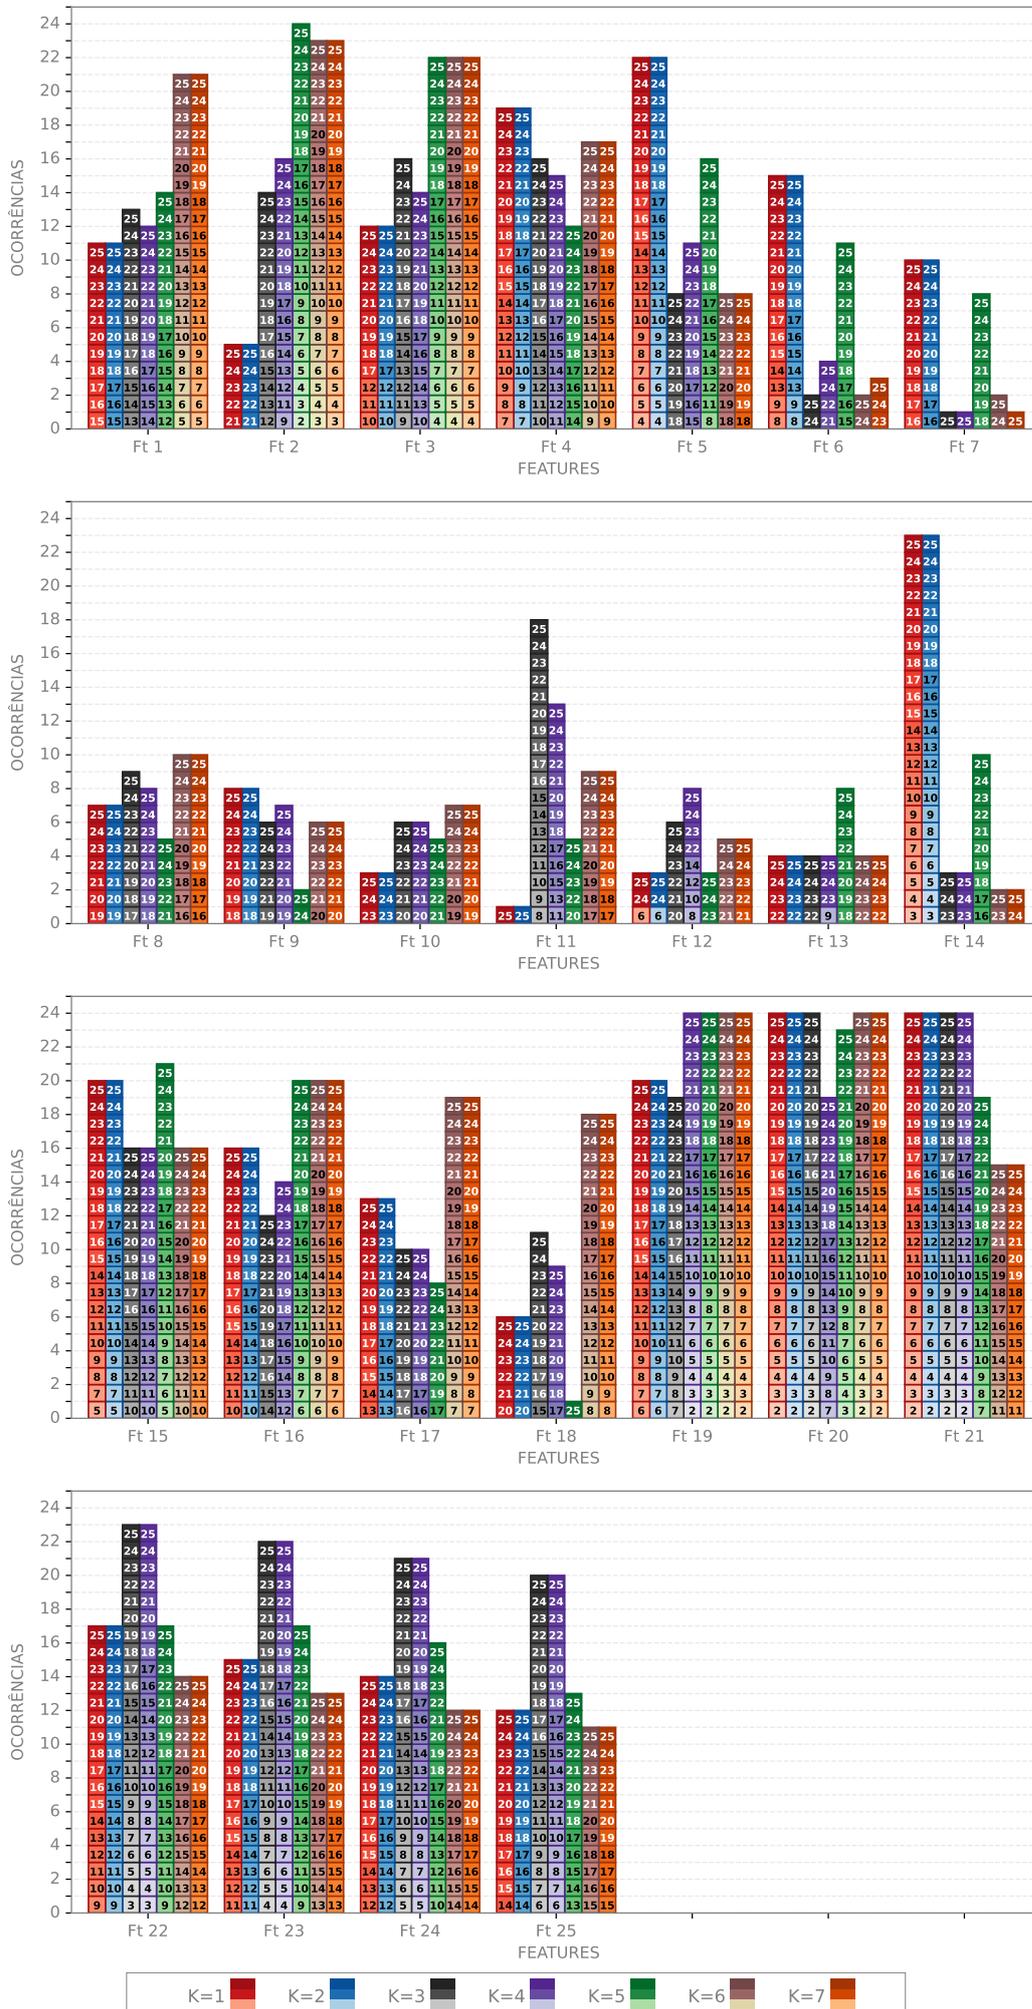
K=1 K=2 K=3 K=4 K=5 K=6 K=7

Figura 183 – Melhores combinações de *features* em VDS-E9-G3-K.



Fonte: Produzido pelo autor.

Figura 184 – Melhores combinações de *features* em BWC-E9-G3-K.



Fonte: Produzido pelo autor.

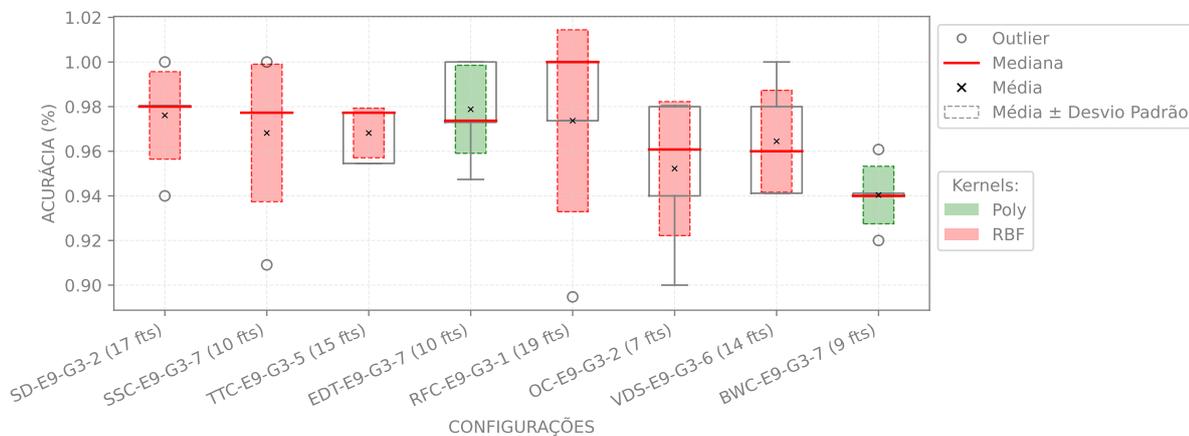
E9-G3: Resultados do módulo MTT

Prosseguindo com a análise de desempenho dos modelos SVM, todos os conjuntos de vetores derivados das combinações ótimas de *features* foram avaliados pelo módulo MTT. Os parâmetros atribuídos para os treinamentos dos classificadores mantêm-se consistentes com os previamente estabelecidos, conforme detalhado na Tabela 6. O limiar de treinamento foi estipulado em múltiplos de 10, variando no intervalo de 20 a 80.

Foram realizados um total de 10 348 800 treinamentos distintos para todas as configurações, especificadas na Tabela 39. Ao final deste processo, os modelos que exibiram maiores médias de acurácias no processo de validação cruzada foram eleitos para os testes definitivos, utilizando o conjunto de dados especificamente reservado para essa finalidade.

Após o processamento de todos os conjuntos de vetores, considerando a variação do número de *features*, os resultados obtidos nos treinamentos com validação cruzada para os modelos que exibiram maior eficácia nos testes subsequentes, abrangendo todas as configurações, foram ilustrados na Figura 185.

Figura 185 – Resultados obtidos nos treinamentos com validação cruzada para os modelos que apresentaram maior eficácia nos testes subsequentes, abrangendo todas as configurações avaliadas em E9-G3. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.



Fonte: Produzido pelo autor.

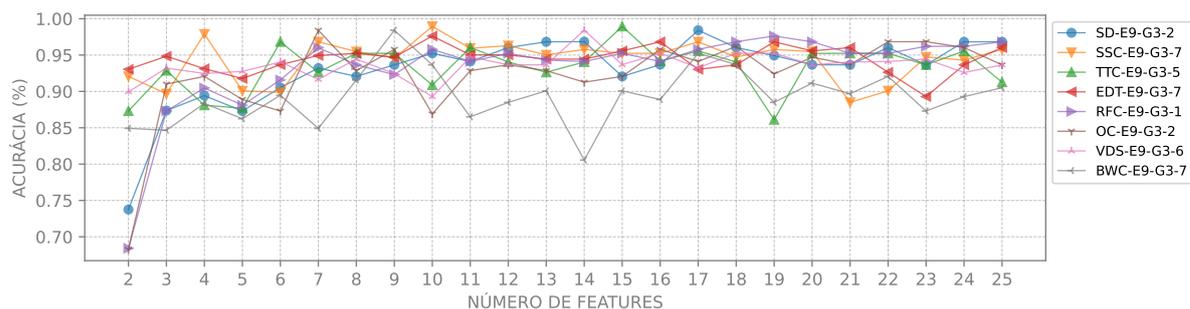
Nos resultados correspondentes às configurações avaliadas neste experimento, observa-se que nos treinamentos, os modelos de melhor desempenho nos testes exibiram performances superiores às observadas em E8-G3, atingindo a acurácia máxima de 100% em alguns casos e com médias superiores a 94%.

No que se refere aos *kernels*, o RBF mostrou-se novamente predominante entre os melhores hiperparâmetros, com uma ocorrência de 75%, seguido pelo *kernel* polinomial, com 25%. O *kernel* polinomial apresentou uma ligeira vantagem em termos de acurácia média para a configuração EDT-E9-G3-7 (10 fts). Por fim, as faixas de confiança (médias

\pm desvios padrão) de todas as configurações reforçam a ideia de que os modelos foram, de modo geral, consistentes em seus desempenhos.

Quanto à avaliação dos modelos, a [Figura 186](#) ilustra os resultados referentes às configurações que se destacaram em termos de desempenhos em pelo menos um dos cenários avaliados para cada critério de parada da EMD.

Figura 186 – Resultados dos testes para as configurações que exibiram os melhores resultados em todos os cenários avaliados em E9-G3. O número de *features* é dado pelas melhores combinações segundo o módulo MPFE.

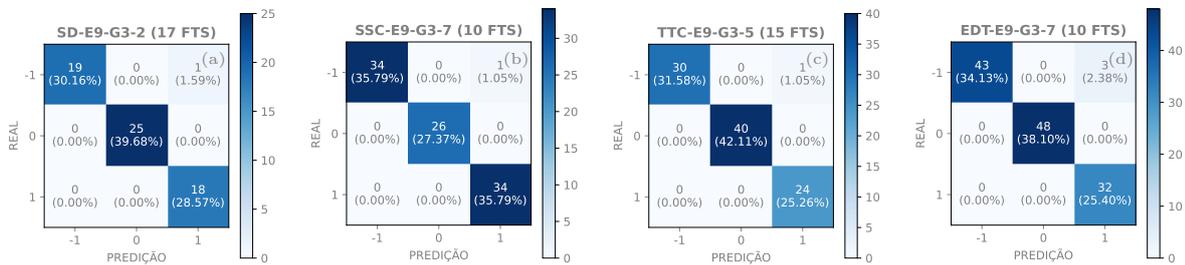


Fonte: Produzido pelo autor.

Constatam-se oscilações marcantes e os desempenhos dos modelos são satisfatórios, ultrapassando a faixa de 95%. As melhores configurações de E9-G3 resultaram em acurácias mínima de 87.30% e máxima de 98.94% para BWC-E9-G3-3 (24 fts) e TTC-E9-G3-5 (15 fts), respectivamente. Ressalta-se que SSC-E9-G3-7 (10 fts) também atingiu 98.94%. É fato que em certas situações, como no caso de SSC-E9-G3-7 (4 fts), a normalização potencializou a estrutura inerente dos dados, propiciando uma classificação mais acertada (acurácia de 98.41% para o caso mencionado). No entanto, em outros contextos, como observado em RFC-E9-G3-1 (2 fts), as conexões essenciais entre as *features* foram possivelmente obscurecidas, levando a uma péssima performance (inferior a 69% para o caso mencionado). Assim como nos ensaios anteriores, estas diferenças reforçam a premissa de que a escolha criteriosa da técnica de normalização é vital para maximizar as performances dos modelos classificadores.

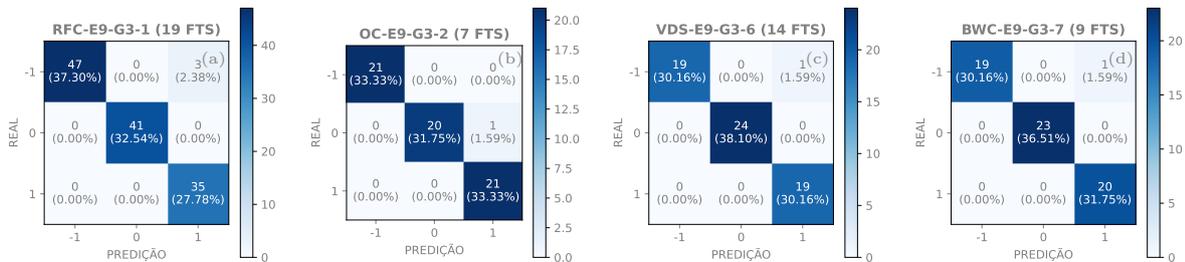
Nas Figuras 187 e 188, são apresentadas as MCs referentes aos resultados dos modelos que exibiram melhores desempenhos nos testes para cada critério de parada. Dentre estas, observa-se que, com exceção das configurações EDT-E9-G3-5 (15 fts) e RFC-E9-G3-1 (19 fts), todas as outras classificaram erroneamente apenas uma instância do total avaliado por cada modelo.

Figura 187 – MCs para as configurações SD-E9-G3, SSC-E9-G3, TTC-E9-G3 e EDT-E9-G3. Os escalares 1, 0 e -1 representam, respectivamente, as classes “alta”, “ruído” e “baixa”.



Fonte: Produzido pelo autor.

Figura 188 – MCs para as configurações RFC-E9-G3, OC-E9-G3, VDS-E9-G3 e BWC-E9-G3. Os escalares 1, 0 e -1 representam, respectivamente, as classes “alta”, “ruído” e “baixa”.



Fonte: Produzido pelo autor.

Os hiperparâmetros determinados para os modelos de melhor desempenho, bem como as métricas acurácia, precisão, *recall*, *F1-score* e AUC, estão detalhados na Tabela 41. As configurações que proporcionaram o melhor desempenho, em termos de acurácia e *F1-score*, para cada critério de parada estão realçadas na Tabela 41. Priorizou-se novamente o *F1-score* máximo, conforme descrito anteriormente.

Os modelos alcançaram um AUC mínimo de 0,97, atingindo 1,00 em vários casos. Embora as curvas ROC sejam geralmente usadas para problemas de classificação binária, é importante observar que, em problemas de classificação multiclasse, como é o caso deste experimento, existem definições de curvas ROC na literatura. Uma dessas abordagens é a curva ROC média, obtida calculando a média das curvas ROC de cada classe em relação às outras (*one-versus-rest*) (AGUILAR-RUIZ; MICHALAK, 2022). Essa abordagem é denominada por *macro-average* e foi utilizada para calcular os resultados listados na Tabela 41 e para gerar os gráficos apresentados nas Figuras 187 e 188.

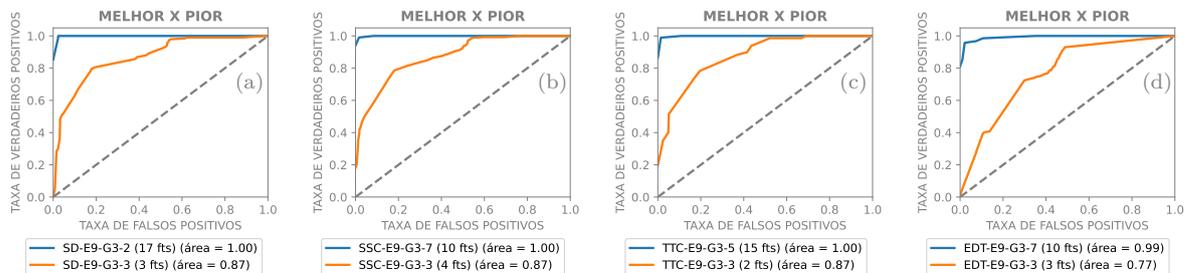
Com base nas análises e tendo em vista os resultados apresentados nas Tabelas 40 e 41, conclui-se que a abordagem empregando os conjuntos de vetores definidos no formato F2, constituídos pelas melhores combinações de *features* conforme análise PFE, favorecem o bom desempenho do sistema proposto considerando a taxa de amostragem dos sinais de

Tabela 41 – Melhores resultados em E9-G3. O termo “Poly” refere-se ao *kernel* Polinomial.

Configuração	Num. features	Amostras treino (%)	C	γ	Kernel	Acurácia	Precisão	Recall	F1-score	AUC
SD-E9-G3-1	18	60	1000.0	-	LINEAR	0.96825	0.96925	0.96603	0.96690	0.99
SSC-E9-G3-1	20	80	1000.0	1	RBF	0.96825	0.96286	0.96286	0.96286	1.00
TTC-E9-G3-1	24	70	1000.0	-	LINEAR	0.97895	0.97980	0.97701	0.97768	0.99
EDT-E9-G3-1	10	80	1000.0	1	RBF	0.96825	0.96944	0.96944	0.96944	1.00
RFC-E9-G3-1	19	60	1000.0	1	RBF	0.97619	0.97368	0.98000	0.97599	1.00
OC-E9-G3-1	14	80	1000.0	1	RBF	0.96825	0.97531	0.96296	0.96757	0.99
VDS-E9-G3-1	19	60	1000.0	1	RBF	0.95238	0.95451	0.95040	0.95096	0.99
BWC-E9-G3-1	20	70	1000.0	1	RBF	0.94737	0.94916	0.94589	0.94623	0.99
SD-E9-G3-2	17	80	100.0	10.0	RBF	0.98413	0.98246	0.98333	0.98244	1.00
SSC-E9-G3-2	18	40	100.0	10.0	RBF	0.97354	0.97204	0.97433	0.97264	0.99
TTC-E9-G3-2	8	80	1000.0	1	RBF	0.96825	0.97329	0.95556	0.96256	1.00
EDT-E9-G3-2	25	40	100.0	1	RBF	0.96296	0.96273	0.96325	0.96222	1.00
RFC-E9-G3-2	12	60	1000.0	-	LINEAR	0.97619	0.97778	0.97619	0.97616	1.00
OC-E9-G3-2	7	80	1000.0	10.0	RBF	0.98413	0.98485	0.98413	0.98412	1.00
VDS-E9-G3-2	18	80	100.0	10.0	RBF	0.95238	0.95579	0.95000	0.95192	0.99
BWC-E9-G3-2	18	80	0.01	100.0	Poly	0.95238	0.94907	0.95833	0.95108	1.00
SD-E9-G3-3	13	20	1	0.1	SIGMOID	0.91667	0.92060	0.91652	0.91756	0.97
SSC-E9-G3-3	19	20	100.0	-	LINEAR	0.90476	0.91120	0.90568	0.90506	0.97
TTC-E9-G3-3	21	80	1	-	LINEAR	0.92063	0.91208	0.91281	0.91016	0.99
EDT-E9-G3-3	18	70	0.001	100.0	Poly	0.92632	0.92790	0.92965	0.92686	0.98
RFC-E9-G3-3	15	70	0.001	1000.0	Poly	0.93684	0.94046	0.94122	0.93892	0.99
OC-E9-G3-3	23	30	100.0	-	LINEAR	0.90950	0.91123	0.90979	0.90901	0.98
VDS-E9-G3-3	18	50	1000.0	0.1	RBF	0.90506	0.90245	0.90356	0.90252	0.97
BWC-E9-G3-3	24	80	1	-	LINEAR	0.87302	0.89993	0.87271	0.87741	0.98
SD-E9-G3-4	15	30	100.0	-	LINEAR	0.96380	0.96407	0.96482	0.96385	0.99
SSC-E9-G3-4	25	60	100.0	-	LINEAR	0.96032	0.96032	0.96048	0.96031	0.99
TTC-E9-G3-4	22	40	100.0	0.1	RBF	0.96825	0.96848	0.96808	0.96799	1.00
EDT-E9-G3-4	16	50	100.0	-	LINEAR	0.96203	0.96124	0.96078	0.96077	0.99
RFC-E9-G3-4	21	80	1000.0	-	LINEAR	0.96825	0.96481	0.96481	0.96481	1.00
OC-E9-G3-4	16	50	1000.0	0.1	SIGMOID	0.96203	0.96667	0.96552	0.96427	0.99
VDS-E9-G3-4	21	70	0.01	10.0	Poly	0.95789	0.95666	0.95402	0.95480	0.99
BWC-E9-G3-4	24	80	100.0	1	RBF	0.93651	0.94079	0.93723	0.93768	0.98
SD-E9-G3-5	13	70	100.0	10.0	RBF	0.96842	0.96154	0.97297	0.96551	1.00
SSC-E9-G3-5	10	60	100.0	1	Poly	0.96825	0.96825	0.97123	0.96858	1.00
TTC-E9-G3-5	15	70	100.0	10.0	RBF	0.98947	0.98667	0.98925	0.98773	1.00
EDT-E9-G3-5	21	50	1000.0	-	LINEAR	0.96835	0.97126	0.96855	0.96848	0.99
RFC-E9-G3-5	4	70	1000.0	10.0	RBF	0.96842	0.96774	0.97500	0.97006	1.00
OC-E9-G3-5	25	20	1000.0	-	LINEAR	0.96032	0.96080	0.96040	0.96044	0.99
VDS-E9-G3-5	5	50	1000.0	10.0	RBF	0.94304	0.94341	0.94372	0.94248	0.98
BWC-E9-G3-5	9	60	1000.0	10.0	RBF	0.92857	0.92910	0.93492	0.93122	0.98
SD-E9-G3-6	14	50	100.0	100.0	RBF	0.96835	0.96861	0.96756	0.96727	1.00
SSC-E9-G3-6	25	30	100.0	100.0	RBF	0.96380	0.96502	0.96346	0.96387	0.99
TTC-E9-G3-6	5	80	100.0	1000.0	RBF	0.98413	0.98148	0.98889	0.98483	1.00
EDT-E9-G3-6	7	70	100.0	100.0	RBF	0.96842	0.97106	0.96659	0.96815	1.00
RFC-E9-G3-6	16	60	100.0	100.0	RBF	0.97619	0.97561	0.97619	0.97500	1.00
OC-E9-G3-6	16	60	1000.0	100.0	RBF	0.97619	0.97580	0.97685	0.97606	1.00
VDS-E9-G3-6	14	80	100.0	100.0	RBF	0.98413	0.98333	0.98333	0.98291	0.99
BWC-E9-G3-6	21	70	1000.0	100.0	RBF	0.92632	0.92359	0.92282	0.92273	0.99
SD-E9-G3-7	14	70	1000.0	1000.0	RBF	0.96842	0.96875	0.96774	0.96666	0.99
SSC-E9-G3-7	10	70	1000.0	1000.0	RBF	0.98947	0.99048	0.99048	0.99034	1.00
TTC-E9-G3-7	20	50	100.0	10.0	Poly	0.97468	0.98039	0.97037	0.97440	0.99
EDT-E9-G3-7	10	60	0.01	1000.0	Poly	0.97619	0.97143	0.97826	0.97384	0.99
RFC-E9-G3-7	11	60	1000.0	1000.0	RBF	0.96825	0.96677	0.96677	0.96677	1.00
OC-E9-G3-7	25	40	1000.0	1000.0	RBF	0.97354	0.97354	0.97512	0.97331	0.99
VDS-E9-G3-7	8	80	1	100.0	Poly	0.96825	0.96250	0.96250	0.96250	0.99
BWC-E9-G3-7	9	80	1000.0	10.0	Poly	0.98413	0.98413	0.98333	0.98332	0.99

Fonte: Elaborada pelo autor.

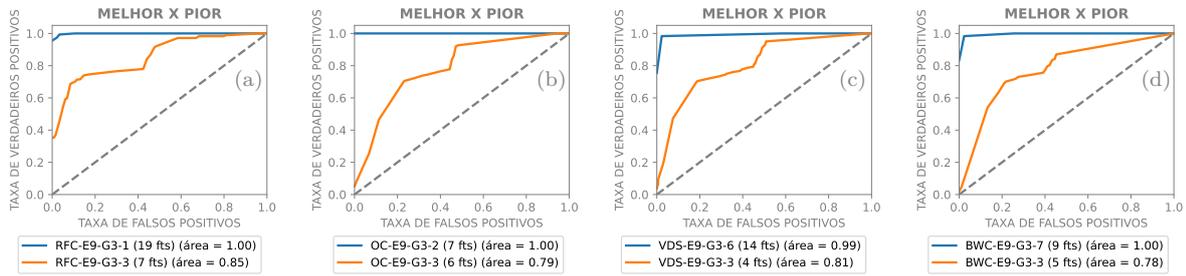
Figura 189 – Curvas ROC das melhores e piores configurações em E9-G3 para os critérios de parada SD, SSC, TTC e EDT.



Fonte: Produzido pelo autor.

13 kHz. A obtenção de acurácias e *F1-scores* que superaram 98% indica que as melhores configurações exibiram desempenhos tão bons quanto os observados nos ensaios dos grupos

Figura 190 – Curvas ROC das melhores e piores configurações em E9-G3 para os critérios de parada RFC, OC, VDS e BWC.



Fonte: Produzido pelo autor.

G1 e G2, confirmando a hipótese inicialmente proposta nesta subseção.

4.3 Comentários Gerais

Os resultados obtidos a partir dos experimentos conduzidos evidenciam a viabilidade do sistema proposto, considerando o desempenho apurado tanto na identificação quanto na estimativa de densidade.

Ao longo dos experimentos, foram investigados oito critérios de parada para a EMD, bem como seus respectivos parâmetros, a variação temporal e amostral dos sinais, além de conjuntos de vetores definidos em dois formatos (F1 e F2) e suas variações dimensionais. Tais análises possibilitaram a determinação de configurações que demandam menor dispêndio computacional.

Nos grupos de testes destinados ao sistema de detecção de cigarras (G1 e G2), foram empregados 1526 registros acústicos com 10 segundos de duração, capturados no formato WAV com uma taxa de amostragem de 44.1 kHz. Estas características foram ajustadas para 5, 2 e 1 segundo e 22, 13 e 6 kHz, respectivamente. Por sua vez, no grupo G3, foram realizados testes voltados ao sistema de estimativa de densidade de cigarras, utilizando-se 315 registros acústicos de 1 segundo de duração. Estes foram extraídos dos 1526 sinais mencionados, com a particularidade de terem sido categorizados em três classes, conforme descrito na Tabela 4. A redução no número de registros neste último conjunto é justificada pela complexidade inerente à separação dos sinais obtidos, que, em sua grande maioria, apresentam um desbalanceamento, predominando as classes “ruído” e “alta”.

Os experimentos relacionados ao módulo MPFE focaram na análise da relevância de cada *feature* antes da submissão dos vetores ao classificador, considerando diferentes técnicas de normalização dos vetores de *features*. Foram exploradas variações para as primeiras k *features* (para vetores nos formatos F1 e F2), bem como as k melhores *features* determinadas pelas combinações ideais, com k sendo um valor inteiro no intervalo de 2 até M . Para os vetores formatados em F1, M varia conforme o número máximo de

IMFs. Para vetores no formato F2, M mantém-se constante, equivalendo a 25, aludindo às bandas críticas da EB. Em relação às combinações ideais, estas foram eleitas após avaliação através da métrica estabelecida (menor distância ao VO) de todas as 33 554 406 combinações possíveis, variando de 25 combinadas de duas em duas (300 possíveis) à 25 em 25 (1 possível), conforme [Tabela 35](#).

O processo envolvendo os cálculos para todas as combinações apresentou um considerável custo computacional devido à grande quantidade de conjuntos possíveis a serem analisados. Esse cenário demandou um processamento prolongado do código desenvolvido em *Python*, durando vários dias. Para contornar esse problema, recorreu-se ao uso de bibliotecas destinadas à execução de processos em paralelo (*multiprocessing*), e à aceleração por meio de GPU (*numba*), conseguindo assim uma notável redução no tempo de processamento.

Em relação ao classificador adotado, foram realizadas buscas exaustivas sobre os hiperparâmetros específicos investigados (*kernel*, suavização, γ e percentual de amostras para treinamento). Tal busca foi realizada através da função *GridSearchCV* da biblioteca *scikit-learn*, utilizando a técnica de validação cruzada por *k*-partes. Os resultados preliminares obtidos para o sistema de identificação (E1-G1) foram condizentes com as expectativas baseadas nos estudos iniciais publicados como artigo científico ([SOUZA et al., 2022](#)), bem como com a literatura existente ([ESCOLA et al., 2020b](#)), alcançando acurácias e *F1-scores* superiores a 97% ([Tabela 14](#)). Nos experimentos subsequentes, foram concentrados esforços visando o refinamento sob as perspectivas de custo computacional e performance. Dessa forma, foram explorados sinais com durações e taxas de amostragem reduzidas, variações nos parâmetros da EMD, forma de definição dos vetores de *features*, técnicas de normalização e alteração de dimensionalidade. Tais ajustes resultaram em acurácias e *F1-scores* superiores a: 97% em E5-G1 ([Tabela 32](#)) para vetores definidos no formato F1 e variação das *features* em ordem crescente; 99% em E6-G2 ([Tabela 34](#)) para vetores definidos no formato F2 e variação das *features* em ordem crescente; e 99% em E7-G2 ([Tabela 37](#)) para vetores definidos no formato F2 e variação das *features* definida pelas combinações ótimas de acordo com a análise PFE. Contudo, para o sistema de estimativa de densidade, ao se aplicar as configurações de (E7-G2), os resultados, embora consistentes, revelaram-se abaixo das expectativas, com acurácias e *F1-scores* inferiores a 94% em E8-G3 ([Tabela 38](#)). Posto isto, no experimento subsequente, a taxa de amostragem foi ajustada para 13 kHz, proporcionando uma melhoria significativa nos resultados, que excederam 98% em E9-G3 ([Tabela 41](#)) para vetores no formato F2 e sequência das *features* estabelecida pelas combinações ótimas, conforme a análise PFE.

No contexto de IoT, apesar da crescente disponibilidade de microcontroladores e módulos de baixo custo, os preços e formatos associados à implantação sistemas de reconhecimento automatizado de sons ambientais impõem limitações ao poder computaci-

onal disponível (ESCOLA et al., 2022a). Nesse contexto, esta tese se dedicou a identificar configurações para o sistema proposto que equilibrem adequadamente a precisão na classificação dos sinais acústicos com o custo computacional, otimizando assim o aproveitamento do poder computacional dos referidos dispositivos. Ao analisar os tempos médios requeridos para as decomposições com as configurações iniciais em E1-G1 em comparação com as configurações menos rigorosas em E5-G1, E6-G2 e E7-G2, observou-se uma redução superior à 97% no tempo necessário para a decomposição dos sinais, conforme indicado na Tabela 42. É importante ressaltar que os ensaios E8 e E9 do grupo G3 apresentaram resultados equivalentes. Esse aspecto é crucial para confirmar a viabilidade da aplicação do sistema proposto em dispositivos a serem implantados em lavouras, uma vez que permitirá análises com alta acurácia e baixo consumo de energia, tendo em vista que este último está intrinsecamente ligado ao custo computacional (SIGTIA et al., 2016).

Tabela 42 – Comparação entre os tempos médios demandados para as decomposições nos experimentos iniciais e finais.

Crit. de Parada	G1-E1 (s)	{E5, E6, E7}-G1 (s)	Redução (%)
SD	4,39	0,09	97,95
SSC	465,26	1,13	99,76
TTC	699,09	1,46	99,79
EDT	30,73	0,46	98,50
RFC	146,88	0,39	99,73
OC	152,06	0,5	99,67
VDS	136,09	0,16	99,88
BWC	4006,91	28,51	99,29

Fonte: Elaborada pelo autor.

Adicionalmente, foi conduzido um estudo para avaliar o desempenho de diversas linguagens de programação comumente empregadas em investigações científicas. Os resultados desta análise foram publicados em um artigo científico intitulado “*Discrete wavelet transform in digital audio signal processing: A case study of programming languages performance analysis*” (ESCOLA; SOUZA; BRITO, 2022). A análise revelou que, das 8 linguagens de programação examinadas, C e C++ exibiram os mais destacados desempenhos ao implementar a transformada *Wavelet* discreta para a decomposição de sinais. Dessa forma, ressalta-se a relevância de realizar uma seleção criteriosa da linguagem de programação, especialmente durante a fase de treinamento dos modelos. Tal escolha pode ter um impacto considerável no tempo de processamento dos dados. O que poderia ser processado em minutos com uma linguagem otimizada pode levar dias se utilizada uma linguagem menos eficaz.

4.3.1 Dispositivos IoT

Existem diversos dispositivos comerciais destinados à detecção e ao monitoramento automatizado de insetos reconhecidos como pragas disponíveis no mercado (LIMA et al., 2020). Dentro do escopo desta pesquisa, a aplicação prática do sistema proposto em campo pode ser desenvolvida por meio de protótipos em IoT. Os algoritmos empregados nos experimentos (módulo MAP) podem ser adaptados à linguagem de programação específica do dispositivo, conforme discutido no estudo vinculado a esta pesquisa e publicado no artigo científico intitulado “*Macoffee: Sistema de monitoramento IoT para dispositivos over-the-air*” (ESCOLA et al., 2022b). O sistema de monitoramento sugerido é composto por um microcontrolador ESP8266 (SCHWARTZ, 2016), alimentado por uma bateria de 6V 2.8Ah, e um Web Service desenvolvido em linguagem PHP. Foram realizados estudos complementares para comparar o desempenho do sistema em outros dois microcontroladores, Arduino Mega 2560 (ISMAILOV; JO‘RAYEV et al., 2022) e ESP32 (BABIUCH; FOLTÝNEK; SMUTNÝ, 2019). Esses estudos também foram divulgados em formato de artigo científico sob o título “*The haar wavelet transform in IoT digital audio signal processing*” (ESCOLA et al., 2022a).

A interação entre um conjunto de dispositivos distribuídos em uma área designada para aplicação da estratégia pode ser estruturada como uma rede *Mesh* (BENYAMINA; HAFID; GENDREAU, 2012). Nessa configuração, os dados são transmitidos entre os dispositivos até que um *Gateway* seja identificado, permitindo que o conjunto de dados seja encaminhado e armazenado na Internet. Este processo se alinha ao conceito de *Edge Computing* (CAO et al., 2020), facilitando a integração de dados coletados em dispositivos IoT com servidores em nuvem. Um protocolo específico foi desenvolvido para viabilizar a comunicação e implementação de redes *mesh*, particularmente para aplicações de PDS em *Smart Farm*, gerenciando a transmissão e recepção de dados entre dispositivos. Essa pesquisa foi publicada no formato de artigo científico, sob o título “*A mesh network case study for digital audio signal processing in smart farm*” (ESCOLA et al., 2022c).

Como previamente destacado, o estudo elaborado e descrito nesta tese integra uma ampla pesquisa envolvendo sistemas de reconhecimento automatizado de sons ambientais. As publicações citadas nesta seção concentram-se nas análises de sinais via WT. Dessa forma, pretende-se em trabalhos futuros a implementação do sistema aqui proposto em dispositivos físicos implantados em lavouras.

Dado que plantações de café se estendem por vastas áreas, chegando a milhares de hectares (CUSTÓDIO et al., 2023), é evidente que a disposição dos dispositivos deverá ser realizada por amostragem. Nesse cenário, pretende-se conduzir um estudo sobre a estimativa do raio de alcance de cada aparelho, tendo em vista que a determinação precisa deste alcance é decisiva para a eficácia do sistema proposto e para a projeção de custos por hectare.

4.3.2 Protótipo de Aplicativo para Celulares

Um protótipo de aplicativo para celulares foi desenvolvido usando a linguagem de programação Java com a finalidade de ser uma proposta alternativa ao uso de microcontroladores. A versão inicial implementada do módulo MAP foi configurada com os parâmetros e modelo treinado, definidos no experimento E7-G2, que maximizaram a acurácia e o $F1$ -score, especificamente VDS-E7-G2-2. A interface da versão 1.0 apresenta opções simples, visando testes iniciais de desempenho, conforme ilustra a [Figura 191a](#). A cada rodada são efetuadas 10 verificações, em sinais capturados pelo microfone do *smartphone*, espaçadas por intervalos de 20 segundos. As verificações que indicam a classe “cigarra” são representadas por 1 e as que indicam a classe “ruído” por 0. Dessa forma, a primeira verificação nos testes apresentados na [Figura 191a](#) indica que o som capturado foi classificado como “cigarra” (1/1), por outro lado o som capturado na segunda verificação foi classificado como “ruído” (2/0). Após os 10 testes executados, dois botões indicados por “play” e “upload” possibilitam que o usuário escute o som avaliado ou faça *upload* do arquivo gravado para um servidor previamente configurado, respectivamente. Nesta primeira versão, a única opção disponível ao usuário é para uma nova rodada de testes através do menu “Novo”, conforme [Figura 191b](#).

Em estudos preliminares, avaliaram-se três modelos de *smartphones* de diferentes marcas. Para esta análise, utilizou-se uma pequena caixa de som para reproduzir sons categorizados em duas classes: “cigarra” e “ruído”. Esta caixa foi posicionada a quatro diferentes distâncias do dispositivo captador: 1, 5, 10 e 15 metros, em um ambiente ao ar livre. Foram preparados dois arquivos de áudio, representando cada classe, para serem reproduzidos de maneira contínua, assegurando a constância da emissão sonora. Em cada distância especificada, realizaram-se 10 rodadas de testes (somando um total de 400 testes por modelo de *smartphone*), intercalando os sons entre as classes, de forma que cada uma fosse reproduzida cinco vezes. Os resultados mostraram que, para todos os três modelos de *smartphones* testados, a acurácia obtida foi superior a 92% em todas as distâncias avaliadas, conforme ilustrado na [Tabela 43](#).

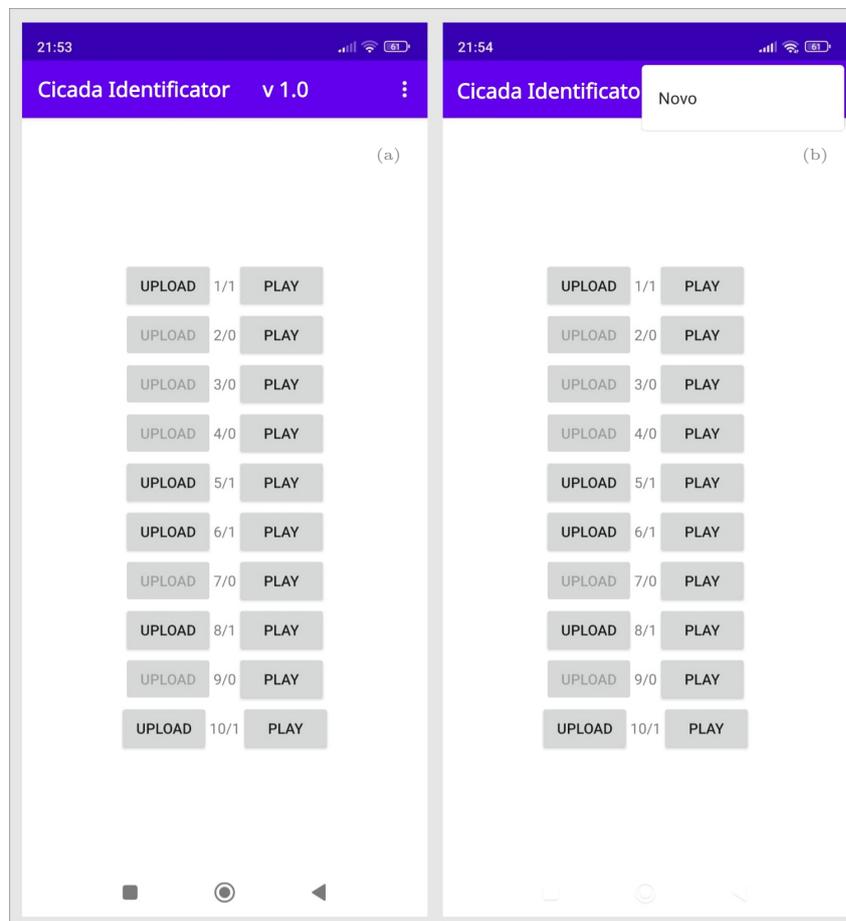
Tabela 43 – Acurácias obtidas nos testes do aplicativo em três modelos de marcas distintas de *smartphones*, variando as distâncias de emissão.

	1 m	5 m	10 m	20 m
Modelo 1	100%	100%	99%	96%
Modelo 2	100%	99%	94%	92%
Modelo 3	100%	100%	99%	98%

Fonte: Elaborada pelo autor.

O desempenho máximo obtido nesta etapa indicou que a SVM está adequadamente treinada para o propósito estabelecido no projeto, que é o monitoramento da *Quesada gigas*. Dos três modelos avaliados, apenas um apresentou resultados abaixo de 95%. Tais

Figura 191 – Interface do protótipo de aplicativo desenvolvido. Em (a) as opções disponíveis após uma rodada de testes e em (b) a opção para nova leitura.



Fonte: Produzido pelo autor.

resultados podem ser atribuídos à capacidade do dispositivo de detectar sinais de baixa amplitude, especialmente considerando que esses resultados foram observados em distâncias superiores a 10 metros.

A compatibilidade abrangente com diversos modelos de *smartphones* alinha-se com o conceito de *e-waste* (PERKINS et al., 2014; SHAHABUDDIN et al., 2023), que preconiza o reuso de equipamentos eletrônicos que foram descartados ou considerados obsoletos. Esta abordagem pode inspirar iniciativas que promovam a reutilização de *smartphones* antigos. Em vez de serem descartados, estes dispositivos poderiam ser reconfigurados para apoiar a implementação do sistema proposto, favorecendo práticas mais sustentáveis e economicamente vantajosas. Adicionalmente, a opção de usar a rede móvel, quando disponível na área em questão, apresenta-se como uma vantagem significativa, pois possibilitaria a transmissão de dados em tempo real para um servidor central. Combinados, esses fatores têm o potencial de tornar o sistema adaptável às diferentes realidades agrícolas.

5 Conclusões

Após apresentar os objetivos deste trabalho, analisar trabalhos correlatos e a devida revisão dos conceitos, foi apresentado um sistema de detecção e monitoramento de densidade de cigarras para implantação em lavouras de café, o qual auxilia no manejo de cigarras por permitir o mapeamento da incidência dos insetos em uma determinada área. Foram avaliados sinais acústicos coletados em campo nos estados de São Paulo e Minas Gerais. Para viabilizar o sistema, as características dos vetores que representam os sinais foram extraídas de duas maneiras distintas (F1 e F2), as quais se mostraram eficientes. Na primeira, os vetores foram definidos pelas energias das IMFs em ordem de extração, metodologia que permite a interrupção do SP da EMD assim que obtido um número específico de IMFs, por exemplo, para o modelo definido pela configuração VDS-E5-G1-4 foram necessárias apenas 7 *features*, ou seja, 7 IMFs. Já na segunda, para a formação dos vetores, as energias das IMFs foram distribuídas de acordo com as 25 faixas de frequências correspondentes às bandas críticas da EB, permitindo a redução da dimensionalidade através de combinações entre as *features*. Nesse caso, a PFE foi utilizada visando selecionar as mais relevantes, extraídas no domínio HHT-Bark. Nesse caso a redução da dimensionalidade não permite a interrupção da EMD antes que todas as IMFs tenham sido extraídas, já que as frequências de todas devem ser distribuídas na etapa da análise espectral empregando a HT.

Os experimentos variando a dimensionalidade dos vetores e as técnicas de normalização comprovaram que as *features*, não são, em sua totalidade, necessários para um ótimo desempenho do classificador SVM utilizado. Há casos em que obteve-se acurácias acima de 90% empregando-se apenas duas *features*, como as configuração VDS-E6-G2-6 e OC-E8-G3-5 que resultaram em modelos que atingiram 92.5% e 92%, respectivamente, nos testes. Esta última demonstra a relevância da PFE para a tarefa em questão.

Discutiu-se uma aplicação prática do sistema proposto para implantação em campo, que pode ser desenvolvida por meio de protótipos em IoT, o qual poderia capturar e processar o som em determinado ponto da lavoura e enviar os dados para um servidor remoto. Informações como posição geográfica, umidade, temperatura e outras poderiam ser coletadas no momento da leitura, além da análise indicando a presença ou a densidade de cigarras no local. Estudos futuros nesse sentido e outras possibilidades sugeridas na [subseção 4.3.1](#) serão desenvolvidos em pesquisas subsequentes.

Em complemento, apresentou-se um protótipo de aplicativo que se encontra em versão inicial, desenvolvido na linguagem de programação Java, para celulares com sistema operacional *Android*. Seu desenvolvimento mostra que buscou-se uma real aplicação, em-

pregando uma solução de baixo custo que possa tornar o sistema adaptável às diferentes realidades agrícolas. Esta abordagem pode inspirar iniciativas que promovam a reutilização de *smartphones* antigos, favorecendo práticas mais sustentáveis e economicamente vantajosas, remetendo ao conceito *e-waste*. Os testes realizados apresentaram acurácias superiores a 92%, chegando a 100% em vários casos.

Para futuras versões, pretende-se automatizar o processo de *upload* dos sinais capturados. Essa funcionalidade, destinada à coleta de dados, oferecerá ao usuário a escolha de ativá-la ou desativá-la. Pretende-se, ainda, adicionar recursos que permitam o agendamento de horários específicos para coletas e a personalização dos intervalos entre verificações, de modo que o sistema realize checagens periódicas conforme a demanda do agricultor. Adicionalmente, será disponibilizada a opção de editar configurações para a utilização de outros modelos classificadores previamente treinados. Para estudos futuros, vários aspectos são relevantes na busca pelo aperfeiçoamento do sistema e do aplicativo propostos. Primeiramente, é essencial conduzir um estudo sobre as frequências que os aparelhos podem captar, identificando, assim, suas limitações. Isso assegura uma detecção mais acurada e reforça a eficiência do monitoramento. Em testes subsequentes, é importante considerar a utilização de um decibelímetro para avaliar os níveis de potência dos sinais recebidos, fornecendo parâmetros valiosos sobre a intensidade com que o dispositivo recebe o sinal. Paralelamente, a exploração de fontes de energia sustentáveis e duradouras torna-se fundamental, sobretudo para sistemas implantados em regiões remotas onde o acesso a eletricidade convencional pode ser um desafio. Pesquisas focadas na utilização de energia solar, por exemplo, podem oferecer soluções apropriadas.

Ademais, a revisão bibliográfica desenvolvida em relação à HHT possibilitou *insights* significantes, resultando em várias ideias para trabalhos futuros envolvendo o método no PDS. Dessa forma, pretende-se desenvolver um estudo aprofundado com intuito de contribuir com a base matemática do método, além de inúmeras possíveis aplicações. Como exemplo, um artigo científico intitulado “*Bidirectional EMD-RLS: performance analysis for denoising in speech signal*” foi desenvolvido, em paralelo à pesquisa apresentada nesta tese, e publicado em uma revista arbitrada (SOUZA et al., 2023). O trabalho aborda a filtragem de sinais de fala pelo método híbrido EMD-RLS bidirecional proposto.

Em trabalhos futuros, também se deseja ampliar o número de sinais acústicos para novos treinamentos, variando as taxas de amostragem diretamente na captura. Isso permitirá uma reanálise da resposta do sistema, considerando que, nos experimentos desta tese, os sinais foram reamostrados utilizando a biblioteca “*scipy*” da linguagem *Python*. Outras técnicas para formação dos vetores de *features* também podem ser investigadas no sentido de melhorar a performance da análise PFE, como feito por Caobianco, Guido e Silva (2021). Por fim, deseja-se aplicar as técnicas para monitoramento de *Quesada gigas* em outros ambientes como Cerrado *Stricto-Sensu* (FERREIRA et al., 2007) e Mata

de Galeria (DUARTE; DIAS; MACCAGNAN, 2018), no município de Iporá, Goiás, em parceria com o pesquisador Douglas H. B. Maccagnan, Doutor em Biologia especializado em Entomologia Geral e Bioacústica, com foco em Cicadoidea. Segundo o pesquisador, acredita-se que a região seja uma zona de transição, uma vez que a *Quesada gigas* emite sinais acústicos em duas frequências (1705 Hz e 2437 Hz) nessa região.

Por fim, destaca-se a contribuição deste trabalho. Conforme identificado em um extenso levantamento bibliográfico, não há registros de estudos que combinem a PFE e a HHT para a análise de sinais acústicos, seja utilizando vetores de *features* definidos pelas energias, seja por vetores definidos pelas frequências instantâneas dispostas conforme a EB, para a finalidade proposta. Ademais, até a data de submissão desta tese à banca examinadora, foram registradas 38 citações (excluindo as autocitações) aos artigos publicados (listados na seção 1.5), conforme verificado na plataforma *ResearchGate*. Esse número corrobora a relevância e as contribuições desta pesquisa com a área.

Referências

- ADHIKARI, B. et al. Application of wavelet for seismic wave analysis in kathmandu valley after the 2015 gorkha earthquake, nepal. *Geoenvironmental Disasters*, v. 7, n. 1, p. 2, 2020. ISSN 2197-8670.
- AGUILAR-RUIZ, J. S.; MICHALAK, M. Multiclass classification performance curve. *IEEE Access*, v. 10, p. 68915–68921, 2022.
- AIDE, T. M. et al. Real-time bioacoustics monitoring and automated species identification. *PeerJ*, PeerJ Inc., v. 1, p. e103, 2013.
- AL-BADDAI, S. et al. Optimizing approach for sifting process to solve a common type of empirical mode decomposition mode mixing. *International Journal of Electrical and Computer Engineering*, World Academy of Science, Engineering and Technology, v. 11, n. 6, p. 717 – 725, 2017. ISSN eISSN: 1307-6892.
- ALMEIDA, J. E. M. de. Controle biológico de cigarras-do-cafeeiro. *X Reunião Itinerante de Fitossanidade do Instituto Biológico Café*, p. 101, 2004.
- ALONSO, R. S. et al. An intelligent edge-iot platform for monitoring livestock and crops in a dairy farming scenario. *Ad Hoc Networks*, Elsevier, v. 98, p. 102047, 2020.
- ALPAYDIN, E. *Introduction to Machine Learning*. third edition. [S.l.]: The MIT Press, 2014. (Adaptive Computation and Machine Learning series). ISBN 0262028182; 9780262028189.
- ALVES, L. et al. A mesh sensor network based on bluetooth: Comparing topologies to crop monitoring. In: SBC. *Anais Estendidos do IX Simpósio Brasileiro de Engenharia de Sistemas Computacionais*. [S.l.], 2019. p. 125–130.
- AMR, T. *Hands-On Machine Learning with scikit-learn and Scientific Python Toolkits: A practical guide to implementing supervised and unsupervised machine learning algorithms in Python*. [S.l.]: Packt Publishing, 2020. ISBN 9781838823580.
- ANTAO, T. *Fast Python: High Performance Techniques for Large Datasets*. [S.l.]: Manning, 2023. ISBN 9781617297939.
- AQAMOHAMMADI, A. R. et al. Deep neural network with hilbert–huang transform for smart fault detection in microgrid. *Electronics*, MDPI, v. 12, n. 3, p. 499, 2023.
- ARFKEN, G.; WEBER, H. *Física matemática: métodos matemáticos para engenharia e física*. 6. ed. [S.l.]: Elsevier, 2007. ISBN 9788535220506.
- AYYADEVARA, V. et al. *SciPy Recipes: A cookbook with over 110 proven recipes for performing mathematical and scientific computations*. [S.l.]: Packt Publishing, 2017. ISBN 9781788295819.
- BABIUCH, M.; FOLTÝNEK, P.; SMUTNÝ, P. Using the esp32 microcontroller for data processing. In: *2019 20th International Carpathian Control Conference (ICCC)*. [S.l.: s.n.], 2019. p. 1–6.

- BABU, N. R.; MOHAN, B. J. Fault classification in power systems using emd and svm. *Ain Shams Engineering Journal*, v. 8, n. 2, p. 103 – 111, 2017. ISSN 2090-4479.
- BARDELI, R.; WOLFF, D.; CLAUSEN, M. Bird song recognition in complex audio scenes. In: CITESEER. *Computational bioacoustics for assessing biodiversity. Proc. International expert meeting on IT-based detection of bioacoustical patterns*. [S.l.], 2007. p. 93–102.
- BEAZLEY, D. *Python Essential Reference*. [S.l.]: Pearson Education, 2009. (Developer's Library). ISBN 9780768687026.
- BENYAMINA, D.; HAFID, A.; GENDREAU, M. Wireless mesh networks design — a survey. *IEEE Communications Surveys Tutorials*, v. 14, n. 2, p. 299–310, 2012.
- BENZEGHIBA, M. et al. Automatic speech recognition and speech variability: A review. *Speech Communication*, v. 49, n. 10, p. 763–786, 2007. ISSN 0167-6393. Intrinsic Speech Variations.
- BERRAR, D. Cross-validation. In: RANGANATHAN, S. et al. (Ed.). *Encyclopedia of Bioinformatics and Computational Biology*. Oxford: Academic Press, 2019. p. 542–545. ISBN 978-0-12-811432-2.
- BI, F. et al. Knock detection based on the optimized variational mode decomposition. *Measurement*, v. 140, p. 1–13, 2019. ISSN 0263-2241.
- BISHOP, C. M. *Neural Networks for Pattern Recognition*. New York, NY, USA: Oxford University Press, Inc., 1995. ISBN 0198538642.
- BLOCK, H.-D. The perceptron: A model for brain functioning. i. *Reviews of Modern Physics*, APS, v. 34, n. 1, p. 123, 1962.
- BOSI, M.; GOLDBERG, R. E. *Introduction to digital audio coding and standards*. [S.l.]: Springer Science & Business Media, 2002. v. 721.
- BOUCHIKHI, A. et al. Empirical mode decomposition and some operators to estimate instantaneous frequency: A comparative study. In: *2008 3rd International Symposium on Communications, Control and Signal Processing*. [S.l.: s.n.], 2008. p. 608–613.
- BOUDRAA, A.; CEXUS, J. Emd-based signal filtering. *IEEE Transactions on Instrumentation and Measurement*, v. 56, n. 6, p. 2196–2202, Dec 2007.
- BOULARD, M. Postures de cymbalisation, cymbalisations et cartes d'identité acoustique des cigales. 2. espèces forestières afro-et néotropicales (cicadoidea, cicadidae et tibicinidae). *Ecole Pratique Des Hautes Etudes, Biologie et Evolution Des Insectes*, v. 9, p. 113–158, 1996.
- BRO, R.; SMILDE, A. K. Principal component analysis. *Anal. Methods*, The Royal Society of Chemistry, v. 6, p. 2812–2831, 2014.
- CAMERON, N. *Electronics Projects with the ESP8266 and ESP32: Building Web Pages, Applications, and WiFi Enabled Devices*. [S.l.]: Apress, 2020. ISBN 9781484263358.
- CAO, K. et al. An overview on edge computing research. *IEEE Access*, v. 8, p. 85714–85728, 2020.

- CAOBIANCO, L. G.; GUIDO, R. C.; SILVA, I. N. da. Wavelet-based features selected with paraconsistent feature engineering successfully classify events in low-voltage grids. *Measurement*, v. 170, p. 108711, 2021. ISSN 0263-2241.
- CARMO, M. P. do. *Differential Geometry of Curves and Surfaces*. 2nd. ed. [S.l.]: Dover Publications, 2017.
- CARNIELLI, W. A.; CONIGLIO, M. E. *Paraconsistent logic: Consistency, contradiction and negation*. [S.l.]: Springer, 2016. v. 40.
- CHANDRASHEKAR, G.; SAHIN, F. A survey on feature selection methods. *Computers Electrical Engineering*, v. 40, n. 1, p. 16–28, 2014. ISSN 0045-7906. 40th-year commemorative issue.
- CHEN, C.-H.; SHIAO, S.-F. Two new species of the genus euterpnosia matsumura (hemiptera: Cicadidae) from taiwan. *The Pan-Pacific Entomologist*, BioOne, v. 84, n. 2, p. 81–91, 2008.
- CHEN, L. et al. Voice disorder identification by using hilbert-huang transform (hht) and k nearest neighbor (knn). *Journal of Voice*, v. 35, n. 6, p. 932.e1–932.e11, 2021. ISSN 0892-1997.
- CHEN, Z. et al. An improved signal processing approach based on analysis mode decomposition and empirical mode decomposition. *Energies*, v. 12, n. 16, 2019. ISSN 1996-1073.
- CHIAVACCI, S. J.; BEDNARZ, J. C.; MCKAY, T. The emergence densities of annual cicadas (hemiptera: Cicadidae) increase with sapling density and are greater near edges in a bottomland hardwood forest. *Environmental entomology*, Oxford University Press Oxford, UK, v. 43, n. 4, p. 859–867, 2014.
- CHU, P. C.; FAN, C.; HUANG, N. Derivative-optimized empirical mode decomposition for the hilbert–huang transform. *Journal of Computational and Applied Mathematics*, v. 259, p. 57 – 64, 2014. ISSN 0377-0427. Proceedings of the Sixteenth International Congress on Computational and Applied Mathematics (ICCAM-2012), Ghent, Belgium, 9-13 July, 2012.
- CHURCHILL, J. W. B. R. V. *Complex variables and applications*. 9th edition. ed. [S.l.]: McGraw-Hill Education, 2014. ISBN 9780073383170.
- CICHY, R. M.; KAISER, D. Deep neural networks as scientific models. *Trends in cognitive sciences*, Elsevier, v. 23, n. 4, p. 305–317, 2019.
- CLARIDGE, M. F. Acoustic signals in the homoptera: Behavior, taxonomy, and evolution. *Annual Review of Entomology*, v. 30, n. 1, p. 297–317, 1985.
- COHEN, L. Time-frequency distributions-a review. *Proceedings of the IEEE*, v. 77, n. 7, p. 941–981, 1989.
- COLE, J. A. A new cryptic species of cicada resembling tibicen dorsatus revealed by calling song (hemiptera: Auchenorrhyncha: Cicadidae). *Annals of the Entomological Society of America*, Oxford University Press, v. 101, n. 5, p. 815–823, 2008.

- CORMEN, T. H. et al. *Introduction to algorithms*. [S.l.]: MIT press, 2022.
- CUOMO, S.; BOCCACCIO, M.; MEO, M. Damage identification during an impact event using the hilbert-huang transform of decomposed propagation modes. *Mechanical Systems and Signal Processing*, v. 191, p. 110126, 2023. ISSN 0888-3270.
- CUSTÓDIO, F. V. et al. Análise dos custos de produção do café arábica nas regiões polos do brasil. *Revista de Contabilidade do Mestrado em Ciências Contábeis da UERJ*, v. 26, n. 1, p. 121–136, 2023.
- DARDAR, M. A.; BELAL, H. M.; BASHEER, A. M. The occurrence of the cicada cicadatra persica on apple trees, malus domestica, in erneh, syria. *Journal of Insect Science*, Oxford University Press Oxford, UK, v. 13, n. 1, p. 42, 2013.
- DEKKING, F. et al. *A Modern Introduction to Probability and Statistics: Understanding Why and How*. [S.l.]: Springer London, 2006. (Springer Texts in Statistics). ISBN 9781846281686.
- DIOP, E. H. S.; ALEXANDRE, R.; BOUDRAA, A. O. Analysis of intrinsic mode functions: A pde approach. *IEEE Signal Processing Letters*, v. 17, n. 4, p. 398–401, April 2010. ISSN 1070-9908.
- DOBKIN, D. et al. Induction of shallow decision trees. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Citeseer, 1997.
- DORRAN, D.; LAWLOR, R. Time-scale modification of music using a subband approach based on the bark scale. In: *2003 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (IEEE Cat. No.03TH8684)*. [S.l.: s.n.], 2003. p. 173–176.
- DUARTE, M. O.; DIAS, H. C.; MACCAGNAN, D. H. B. Cigarras (cicadidae) coletadas por armadilha luminosa em mata da galeria no município de israelândia, goiás. In: *Anais do IV Congresso de Ensino, Pesquisa e Extensão da Universidade Estadual de Goiás*. Pirenópolis, Goiás, Brasil: [s.n.], 2018.
- D'UTRA, G. Cicadas in coffee plantations (in portuguese). *Agriculture Bulletin*, v. 9, n. 5, p. 350–365, 1908.
- EGAMBARAM, A. et al. Comparison of envelope interpolation techniques in empirical mode decomposition (emd) for eyeblink artifact removal from eeg. In: *2016 IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES)*. [S.l.: s.n.], 2016. p. 590–595.
- ESCOLA, J. P. L. et al. Estado da arte no monitoramento acústico de Cicadidae em lavouras de café: State of the art in acoustic monitoring of Cicadidae in coffee crops. *Revista Macambira*, v. 5, n. 1, p. e051007, jun. 2021. ISSN 2594-4754.
- ESCOLA, J. P. L. et al. A case study of wavelets and svm application in coffee agriculture: Detecting cicadas based on their acoustic and image patterns. In: SILVA, I. N. da; FLAUZINO, R. A. (Ed.). *Application of Expert Systems*. Rijeka: IntechOpen, 2020. cap. 1.
- ESCOLA, J. P. L. et al. Automated acoustic detection of a cicadid pest in coffee plantations. *Computers and Electronics in Agriculture*, v. 169, p. 105215, 2020. ISSN 0168-1699.

- ESCOLA, J. P. L. et al. Wavelet transform applied to coffee entomology. In: *2021 Signal Processing Symposium (SPSymposium)*. [S.l.: s.n.], 2021. p. 58–64.
- ESCOLA, J. P. L.; SOUZA, U. B. d.; BRITO, L. d. C. Discrete wavelet transform in digital audio signal processing: A case study of programming languages performance analysis. *Computers and Electrical Engineering*, v. 104, p. 108439, 2022. ISSN 0045-7906.
- ESCOLA, J. P. L. et al. The haar wavelet transform in iot digital audio signal processing. *Circuits, Systems, and Signal Processing*, Feb 2022. ISSN 1531-5878.
- ESCOLA, J. P. L. et al. Macoffee: Sistema de monitoramento iot para dispositivos over-the-air. *Revista de Tecnologia Aplicada*, v. 10, n. 3, p. 33–47, 2022. ISSN 2237-3713.
- ESCOLA, J. P. L. et al. A mesh network case study for digital audio signal processing in smart farm. *Internet of Things*, v. 17, p. 100488, 2022. ISSN 2542-6605.
- FAWCETT, T. An introduction to ROC analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006. ISSN 0167-8655. ROC Analysis in Pattern Recognition.
- FERREIRA, M. F. M. et al. Comparação da incidência de galhas em duas formações florestais do bioma cerrado: Cerrado stricto sensu e mata seca. *Revista Brasileira de Biociências*, v. 5, n. S1, p. 36–38, 2007.
- FLANDRIN, P.; GONÇALVÈS, P. Empirical mode decompositions as data-driven wavelet-like expansions. *International Journal of Wavelets, Multiresolution and Information Processing*, v. 02, n. 04, p. 477–496, 2004.
- FLANDRIN, P.; GONÇALVÈS, P.; RILLING, G. Emd equivalent filter banks, from interpretation to applications. In: _____. *Hilbert-Huang Transform and Its Applications*. [S.l.: s.n.], 2005. p. 57–74.
- FORNAZIER, M. J.; ROCHA, A. C. d. Control of the coffee cicada in sloping areas in the state of espírito santo (in portuguese). In: SYMPOSIUM ON RESEARCH OF BRAZILIAN COFFEES. Poços de Caldas, MG, Brazil: Brasília: EMBRAPA Café, 2000. v. 1, p. 1167–1170.
- FRANCIS, G. *Home recording for beginners*. [S.l.]: Cengage Learning, 2009.
- FRIEDMAN, J. H. An overview of predictive learning and function approximation. In: CHERKASSKY, V.; FRIEDMAN, J. H.; WECHSLER, H. (Ed.). *From Statistics to Neural Networks*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1994. p. 1–61. ISBN 978-3-642-79119-2.
- GANCHEV, T.; POTAMITIS, I. Automatic acoustic identification of singing insects. *Bioacoustics*, Taylor Francis, v. 16, n. 3, p. 281–328, 2007.
- GE, H. et al. Theoretical analysis of empirical mode decomposition. *Symmetry*, v. 10, n. 11, 2018. ISSN 2073-8994.
- GE, Y.-Z. et al. Geological mapping of basalt using stream sediment geochemical data: Case study of covered areas in jining, inner mongolia, china. *Journal of Geochemical Exploration*, v. 232, p. 106888, 2022. ISSN 0375-6742.

- GONÇALVES, W.; FARIA, A. M. Granular systemic insecticides for cicada mobile nymphs and their effects on coffee yield (in portuguese). *Bragantia*, scielo, v. 48, p. 95 – 108, 1989. ISSN 0006-8705.
- GRAHAM, R.; KNUTH, D.; PATASHNIK, O. *Concrete Mathematics: A Foundation for Computer Science*. [S.l.]: Addison-Wesley, 1994. (A @foundation for computer science). ISBN 9780201558029.
- GRAPS, A. An introduction to wavelets. *IEEE Computational Science and Engineering*, v. 2, n. 2, p. 50–61, 1995.
- GRAVENA, S. Controle biológico no manejo integrado de pragas. *Pesquisa Agropecuária Brasileira*, v. 27, n. 3, p. 281–300, 1992.
- GRIGG, S. et al. Acoustic sensing and noise identification of a heating, ventilation and air conditioning unit: Industrial case study. *Applied Sciences*, v. 11, n. 21, 2021. ISSN 2076-3417.
- GUIDO, R. C. A tutorial on signal energy and its applications. *Neurocomputing*, v. 179, p. 264–282, 2016. ISSN 0925-2312.
- GUIDO, R. C. Paraconsistent feature engineering [lecture notes]. *IEEE Signal Processing Magazine*, v. 36, n. 1, p. 154–158, 2019.
- GUPTA, M. et al. Security and privacy in smart farming: Challenges and opportunities. *IEEE Access*, IEEE, v. 8, p. 34564–34584, 2020.
- GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. *J. Mach. Learn. Res.*, JMLR.org, v. 3, n. null, p. 1157–1182, mar 2003. ISSN 1532-4435.
- HAN, J.; PEI, J.; KAMBER, M. *Data mining: concepts and techniques*. [S.l.]: Elsevier, 2011.
- HAYKIN, S. *Redes Neurais: Princípios e Prática*. [S.l.]: Bookman Editora, 2001. ISBN 9788577800865.
- HERRE, J.; DICK, S. Psychoacoustic models for perceptual audio coding—a tutorial review. *Applied Sciences*, v. 9, n. 14, 2019. ISSN 2076-3417.
- HILL, K. B.; MARSHALL, D. C. The song, morphology, habitat, and distribution of the elusive north american cicada okanagana viridis (auchenorrhyncha: Cicadidae). *Annals of the Entomological Society of America*, Oxford University Press, v. 106, n. 5, p. 598–603, 2013.
- HOLLER, J. et al. *Internet of Things*. [S.l.]: Elsevier Science, 2014. ISBN 9780080994017.
- HOU, Z. et al. Ecology of meimuna mongolica (hemiptera: Cicadidae) nymphs: instars, morphological variation, vertical distribution and population density, host-plant selection, and emergence phenology. *Journal of Insect Science*, Entomological Society of America, v. 15, n. 1, p. 42, 2015.
- HUANG, N. E. Computer implicated empirical mode decomposition method, apparatus, and article of manufacture. *U.S. Patent Pending*, 1996.

- HUANG, N. E.; SHEN, Z.; LONG, S. R. A new view of nonlinear water waves: The hilbert spectrum. *Annual Review of Fluid Mechanics*, v. 31, n. 1, p. 417–457, 1999.
- HUANG, N. E. et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, v. 454, n. 1971, p. 903–995, 1998.
- HUANG, N. E. et al. A confidence limit for the empirical mode decomposition and hilbert spectral analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, v. 459, n. 2037, p. 2317–2345, 2003.
- HUANG, N. E.; WU, Z. A review on hilbert-huang transform: Method and its applications to geophysical studies. *Reviews of Geophysics*, v. 46, n. 2, 2008.
- HUNT, J. *A Beginners Guide To Python 3 Programming*. 1st. ed. [S.l.]: Springer International Publishing, 2019. (Undergraduate Topics in Computer Science). ISBN 9783030202903.
- HYVÄRINEN, A. Independent component analysis: recent advances. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, The Royal Society Publishing, v. 371, n. 1984, p. 20110534, 2013.
- IDRIS, I. *NumPy: Beginner's Guide*. [S.l.]: Packt Publishing, 2015. ISBN 9781785288838.
- INSELBERG, A. *Parallel Coordinates: Visual Multidimensional Geometry and Its Applications*. 1. ed. [S.l.]: Springer, 2009. ISBN 0387215077; 9780387215075; 0387686282; 9780387686288.
- ISMAILOV, A. S.; JO'RAYEV, Z. B. et al. Study of arduino microcontroller board. *Science and Education*, v. 3, n. 3, p. 172–179, 2022.
- JO, W. et al. A study on improving sound quality of violin playing robot. In: *2015 6th International Conference on Automation, Robotics and Applications (ICARA)*. [S.l.: s.n.], 2015. p. 185–191.
- JUNIOR, S. T. D. et al. Oviposition of *quesada gigas* (hemiptera: Cicadidae) in coffee plants. *Revista Colombiana de Entomologia*, Sociedad Colombiana de Entomología, v. 38, n. 1, p. 1–5, 2012.
- JUNSHENG, C.; DEJIE, Y.; YU, Y. Research on the intrinsic mode function (imf) criterion in emd method. *Mechanical Systems and Signal Processing*, v. 20, n. 4, p. 817 – 824, 2006. ISSN 0888-3270.
- KAK, S. The discrete hilbert transform. *Proceedings of the IEEE*, v. 58, n. 4, p. 585–586, 1970.
- KHIRADE, S. D.; PATIL, A. Plant disease detection using image processing. In: *2015 International Conference on Computing Communication Control and Automation*. [S.l.: s.n.], 2015. p. 768–771.
- KING, F. W. *Hilbert transforms*. [S.l.]: CUP, 2009. v. 1. (Encyclopedia of Mathematics and its Applications, v. 1). ISBN 9780521887625,0521887623.

- KIZHNER, S. et al. On certain theoretical developments underlying the hilbert-huang transform. In: *2006 IEEE Aerospace Conference*. [S.l.: s.n.], 2006. p. 14 pp.–.
- KODALI, R. K.; YERROJU, S.; SAHU, S. Smart farm monitoring using lora enabled iot. In: IEEE. *2018 second international conference on green computing and internet of things (ICGCIoT)*. [S.l.], 2018. p. 391–394.
- KOLLMEIER, B.; BRAND, T.; MEYER, B. Perception of speech and sound. In: _____. *Springer Handbook of Speech Processing*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 61–82. ISBN 978-3-540-49127-9.
- KRZYWINSKI, M.; ALTMAN, N. Visualizing samples with box plots. *Nature Methods*, v. 11, n. 2, p. 119–120, Feb 2014. ISSN 1548-7105.
- LAMPSON, B. et al. Automatic detection and identification of brown stink bug, *euschistus servus*, and southern green stink bug, *nezara viridula*, (heteroptera: Pentatomidae) using intraspecific substrate-borne vibrational signals. *Computers and electronics in agriculture*, Elsevier, v. 91, p. 154–159, 2013.
- LEE, Y. J. Revised synonymic list of cicadidae (insecta: Hemiptera) from the korean peninsula, with the description of a new species and some taxonomic remarks. *Proceedings of the Biological Society of Washington*, Biological Society of Washington Smithsonian Institution, PO Box 37012, MRC . . . , v. 121, n. 4, p. 445–467, 2008.
- LI, L.; HONGBING, J. Signal feature extraction based on an improved emd method. *Measurement*, v. 42, p. 796–803, 06 2009.
- LIMA, M. C. F. et al. Automatic detection and monitoring of insect pests—a review. *Agriculture*, MDPI AG, v. 10, n. 5, p. 161, 2020.
- LIU, C. et al. Multiscale information transmission between commodity markets: An emd-based transfer entropy network. *Research in International Business and Finance*, v. 55, p. 101318, 2021. ISSN 0275-5319.
- LUNZ, A. M. et al. Método para monitoramento de ninfas de cigarras e controle com inseticidas em reflorestamentos com paricá. *Pesquisa Agropecuária Brasileira*, SciELO Brasil, v. 45, p. 631–637, 2010.
- LUQUE, A. et al. Visualizing classification results: Confusion star and confusion gear. *IEEE Access*, v. 10, p. 1659–1677, 2022.
- MACCAGNAN, D. Divergence in calling song of allopatric populations of *quesada gigas* (olivier) (hemiptera: Cicadidae). In: *XXIV International Bioacoustics Congress*. Pirenópolis, Brazil: [s.n.], 2013.
- MACCAGNAN, D. H. B. *Cicada (Hemiptera: Cicadidae): Emergence, acoustic behavior and sound trap development*. Tese (Doutorado) — University of São Paulo, São Paulo, Brazil, 2008. (in Portuguese).
- MACCAGNAN, D. H. B. et al. Primeiro registro de cigarra em reflorestamentos com paricá no estado de mato grosso, brasil. *Revista de Ciências Agrárias Amazonian Journal of Agricultural and Environmental Sciences*, v. 57, n. 4, p. 451–454, 2014.

- MAJI, S.; BERG, A. C.; MALIK, J. Efficient classification for additive kernel svms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 35, n. 1, p. 66–77, 2013.
- MALLAT, S. *A Wavelet Tour of Signal Processing: The Sparse Way*. [S.l.]: Elsevier Science, 2008. ISBN 9780080922027.
- MARTELLI, A. *Python in a Nutshell*. [S.l.]: O'Reilly, 2003. (In a Nutshell (o'Reilly) Series). ISBN 9780596001889.
- MARTINELLI, N. M.; LUSVARGHI, H. N. Control of coffee cicadas with terbufos in two formulas (in portuguese). In: *Brazilian Coffee Research Congress*. [S.l.: s.n.], 1998. v. 24, p. 115.
- MARTINELLI, N. M. et al. Modo de aplicação e eficiência de inseticidas granulados sistêmicos para o controle de cigarras (hemiptera: Cicadidae) do cafeeiro. *Anais da Sociedade Entomológica do Brasil*, SciELO Brasil, v. 27, p. 133–140, 1998.
- MARTINELLI, N. M.; ZUCCHI, R. A. Cigarras (hemiptera: Cicadidae: Tibicinidae) associadas ao cafeeiro: distribuição, hospedeiros e chave para as espécies. *Anais da Sociedade Entomológica do Brasil*, SciELO Brasil, v. 26, p. 133–143, 1997.
- MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. *Foundations of Machine Learning, second edition*. [S.l.]: MIT Press, 2018. (Adaptive Computation and Machine Learning series). ISBN 9780262039406.
- MOULDS, M. An appraisal of the higher classification of cicadas (Hemiptera: Cicadoidea) with special reference to the australian fauna. *Records of the Australian Museum*, v. 57, n. 3, p. 375–446, 11 2005.
- MURTY, M. N.; RAGHAVA, R. Kernel-based svm. In: _____. *Support Vector Machines and Perceptrons: Learning, Optimization, Classification, and Application to Social Networks*. Cham: Springer International Publishing, 2016. p. 57–67. ISBN 978-3-319-41063-0.
- NANNI, L. et al. Combining visual and acoustic features for bird species classification. In: *2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI)*. [S.l.: s.n.], 2016. p. 396–401.
- NARAYANAN, N. *Statistics*. [S.l.]: PHI Learning, 2015. ISBN 9788120350861.
- NELLI, F. *Parallel and High Performance Programming with Python: Unlock parallel and concurrent programming in Python using multithreading, CUDA, Pytorch and Dask. (English Edition)*. [S.l.]: Orange Education Pvt Limited, 2023. ISBN 9789388590730.
- NIU, X.-d. et al. An improved empirical mode decomposition based on local integral mean and its application in signal processing. *Mathematical Problems in Engineering*, Hindawi, v. 2021, p. 8891217, Feb 2021. ISSN 1024-123X.
- NODA, J. J. et al. Using bioacoustic signals and support vector machine for automatic classification of insects. In: *2016 3rd International Conference on Signal Processing and Integrated Networks (SPIN)*. [S.l.: s.n.], 2016. p. 656–659.

- NOLASCO, I. et al. Audio-based identification of beehive states. In: *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. [S.l.: s.n.], 2019. p. 8256–8260.
- NYQUIST, H. Certain topics in telegraph transmission theory. *Transactions of the American Institute of Electrical Engineers*, v. 47, n. 2, p. 617–644, 1928.
- OHYA, E. Identification of *Tibicen* cicada species by a principal components analysis of their songs. *Anais da Academia Brasileira de Ciências*, v. 76, p. 442–4, 07 2004.
- OPPENHEIM, A.; SCHAFER, R. *Discrete-time Signal Processing*. [S.l.]: Pearson, 2010. (Prentice-Hall signal processing series). ISBN 9780132067096.
- PASCOAL, R.; SOARES, C. G.; VELTCHEVA, A. On the stopping criterion to apply the hilbert huang transform method to sea wave records. v. 2, p. 1113–1121, 01 2005.
- PERKINS, D. N. et al. E-waste: A global hazard. *Annals of Global Health*, v. 80, n. 4, p. 286–295, 2014. ISSN 2214-9996.
- PRIDDY, K. L.; KELLER, P. E. *Artificial neural networks: an introduction*. [S.l.]: SPIE press, 2005. v. 68.
- PRINCE, P. et al. Deploying acoustic detection algorithms on low-cost, open-source acoustic sensors for environmental monitoring. *Sensors*, MDPI, v. 19, n. 3, p. 553, 2019.
- PRINGLE, J. W. S. A Physiological Analysis of Cicada Song. *Journal of Experimental Biology*, v. 31, n. 4, p. 525–560, 12 1954. ISSN 0022-0949.
- PROCHÁZKA, A.; VYŠATA, O. History and biomedical applications of digital signal and image processing. In: *2014 International Workshop on Computational Intelligence for Multimedia Understanding (IWCIM)*. [S.l.: s.n.], 2014. p. 1–5.
- RATO, R.; ORTIGUEIRA, M.; BATISTA, A. On the hht, its problems, and some solutions. *Mechanical Systems and Signal Processing*, v. 22, n. 6, p. 1374 – 1394, 2008. ISSN 0888-3270. Special Issue: Mechatronics.
- REIS, P.; SOUZA, J. d. Cigarras-do-cafeeiro, dano e controle. *Lavras: EPAMIG/CRSM, 5p.(Circular Técnica)*, 1991.
- RICHARDSON, M.; WALLACE, S.; WALLACE, S. *Getting Started with Raspberry Pi*. [S.l.]: O'Reilly Media, Incorporated, 2012. (Make: projects). ISBN 9781449344214.
- RIEDE, K. Acoustic monitoring of Orthoptera and its potential for conservation. *Journal of Insect Conservation*, v. 2, n. 3, p. 217–223, Dec 1998. ISSN 1572-9753.
- RILLING, G.; FLANDRIN, P. on the influence of sampling on the empirical mode decomposition. In: *2006 IEEE International Conference on Acoustics Speech and Signal Processing Proceedings*. [S.l.: s.n.], 2006. v. 3, p. III–III.
- RILLING, G.; FLANDRIN, P.; GONÇALVES, P. On empirical mode decomposition and its algorithms. In: *Proceedings of IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing NSIP-03*. Grado, Italy: [s.n.], 2003.

- RUSSELL, S.; NORVIG, P. *Inteligência Artificial - Uma Abordagem Moderna*. [S.l.]: GEN LTC, 2022. ISBN 9788595158870.
- SAARY, M. J. Radar plots: a useful way for presenting multivariate health care data. *Journal of Clinical Epidemiology*, v. 61, n. 4, p. 311–317, 2008. ISSN 0895-4356.
- SAEYS, Y.; INZA, I.; LARRAÑAGA, P. A review of feature selection techniques in bioinformatics. *Bioinformatics*, v. 23, n. 19, p. 2507–2517, 08 2007. ISSN 1367-4803.
- SAHANI, M. et al. Dsp based online power quality events detection and classification using hilbert huang transform and random forest method. In: IEEE. *2020 International Conference on Computational Intelligence for Smart Power System and Sustainable Energy (CISPSSE)*. [S.l.], 2020. p. 1–6.
- SANBORN, A. F.; HEATH, J. E.; HEATH, M. S. Long-range sound distribution and the calling song of the cicada *beameria venosa* (uhler)(hemiptera: Cicadidae). *The Southwestern Naturalist*, BioOne, v. 54, n. 1, p. 24–30, 2009.
- SANTIS, C. L. D.; URTEAGA, R.; BOLCATTO, P. G. *Cicada's wings as determinant factor for the sound emission: The case of Quesada gigas*. 2006.
- SANTOS, R. S.; MARTINELLI, N. M. Ocorrência de fidicinoides pauliensis bouland & martinelli, 1996 (hemiptera: Cicadidae) em cafeeiro em tapiratiba, sp. *Revista de Agricultura (Piracicaba)*, v. 82, p. 311–314, 2007.
- SATO, Y.; SATO, S. Spring temperature predicts the long-term molting phenology of two cicadas, *cryptotympana facialis* and *graptopsaltria nigrofuscata* (hemiptera: Cicadidae). *Annals of the Entomological Society of America*, Oxford University Press, v. 108, n. 4, p. 494–500, 2015.
- SAZIMA, I. Insect cornucopia: various bird types prey on the season's first giant cicadas in an urban park in southeastern brazil. *Biota Neotropica*, SciELO Brasil, v. 9, p. 259–262, 2009.
- SCHUMAKER, L. *Spline Functions: Basic Theory*. 3. ed. [S.l.]: Cambridge University Press, 2007. (Cambridge Mathematical Library).
- SCHWARTZ, M. *Internet of Things with ESP8266*. [S.l.]: Packt Publishing Ltd, 2016.
- SEABRA, S. G.; QUARTAU, J. A.; BRUFORD, M. W. Spatio-temporal genetic variation in sympatric and allopatric mediterranean cicada species (hemiptera, cicadidae). *Biological Journal of the Linnean Society*, Oxford University Press, v. 96, n. 2, p. 249–265, 2009.
- SHAH, P.; HOEFFNER, J. Review of graph comprehension research: Implications for instruction. *Educational Psychology Review*, v. 14, n. 1, p. 47–69, Mar 2002. ISSN 1573-336X.
- SHAHABUDDIN, M. et al. A review of the recent development, challenges, and opportunities of electronic waste (e-waste). *International Journal of Environmental Science and Technology*, v. 20, n. 4, p. 4513–4520, Apr 2023. ISSN 1735-2630.
- SIGTIA, S. et al. Automatic environmental sound recognition: Performance versus computational cost. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, v. 24, n. 11, p. 2096–2107, 2016.

- SILVA, G.; BATISTA, P.; RODRIGUES, P. M. Covid-19 activity screening by a smart-data-driven multi-band voice analysis. *Journal of Voice*, 2022. ISSN 0892-1997.
- SINGH, D.; SINGH, B. Investigating the impact of data normalization on classification performance. *Applied Soft Computing*, v. 97, p. 105524, 2020. ISSN 1568-4946.
- SINGH, D.; SINGH, B. Feature wise normalization: An effective way of normalizing data. *Pattern Recognition*, v. 122, p. 108307, 2022. ISSN 0031-3203.
- SINGH, S.; MOHANTY, A. Hvac noise control using natural materials to improve vehicle interior sound quality. *Applied Acoustics*, v. 140, p. 100–109, 2018. ISSN 0003-682X.
- SOARES, V. P. et al. Análise espacial da distribuição de cigarras (quesada gigas oliver) em povoamentos de paricá (*schizolobium amazonicum huber ex ducke*) na região de dom eliseu, pa. *Revista Árvore*, SciELO Brasil, v. 32, p. 251–258, 2008.
- SOLA, J.; SEVILLA, J. Importance of input data normalization for the application of neural networks to complex industrial problems. *IEEE Transactions on Nuclear Science*, v. 44, n. 3, p. 1464–1468, 1997.
- SOUZA, J. C. d.; REIS, P. R.; SILVA, R. A. *Cigarras-do-cafeeiro em Minas Gerais: histórico, reconhecimento, biologia, prejuízos e controle*. 2. ed. Belo Horizonte: EPAMIG. Boletim técnico, 2007. 47 p. ISSN 0101-062X.
- SOUZA, U. B. de; ESCOLA, J. P. L.; BRITO, L. da C. A survey on hilbert-huang transform: Evolution, challenges and solutions. *Digital Signal Processing*, v. 120, p. 103292, 2022. ISSN 1051-2004.
- SOUZA, U. B. de et al. Empirical mode decomposition applied to acoustic detection of a cicadid pest. *Computers and Electronics in Agriculture*, v. 199, p. 107181, 2022. ISSN 0168-1699.
- SOUZA, U. B. de et al. Bidirectional EMD-RLS: Performance analysis for denoising in speech signal. *Journal of Computational Science*, v. 74, p. 102181, 2023. ISSN 1877-7503.
- STEIN, E.; SHAKARCHI, R. *Fourier Analysis: An Introduction*. [S.l.]: Princeton University Press, 2011. (Princeton lectures in analysis). ISBN 9781400831234.
- STEVENSON, N.; MESBAH, M.; BOASHASH, B. A sampling limit for the empirical mode decomposition. In: *Proceedings - 8th International Symposium on Signal Processing and its Applications, ISSPA 2005*. [S.l.: s.n.], 2005. v. 2, p. 647–650. ISBN 0780392434.
- SUEUR, J. Audiospectrographical analysis of cicada sound production: A catalogue (Hemiptera, Cicadidae). *Deutsche Entomologische Zeitschrift*, v. 48, p. 33–51, 2001.
- SUEUR, J. Cicada acoustic communication: potential sound partitioning in a multispecies community from Mexico (Hemiptera: Cicadomorpha: Cicadidae). *Biological Journal of the Linnean Society*, v. 75, n. 3, p. 379–394, 10 2008. ISSN 0024-4066.
- SUEUR, J. et al. Rapid acoustic survey for biodiversity appraisal. *PloS one*, Public Library of Science San Francisco, USA, v. 3, n. 12, p. e4065, 2008.

- TABRIZI, A. et al. Influence of stopping criterion for sifting process of empirical mode decomposition (emd) on roller bearing fault diagnosis. In: DALPIAZ, G. et al. (Ed.). *Advances in Condition Monitoring of Machinery in Non-Stationary Operations*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014. p. 389–398. ISBN 978-3-642-39348-8.
- TABRIZI, A. A. et al. Automatic damage identification of roller bearings and effects of sifting stop criterion of imfs. *Measurement*, v. 93, p. 435–441, 2016. ISSN 0263-2241.
- TEY, W. T. et al. Cicada species recognition based on acoustic signals. *Algorithms*, v. 15, n. 10, 2022. ISSN 1999-4893.
- TRAUNMÜLLER, H. Analytical expressions for the tonotopic sensory scale. *The Journal of the Acoustical Society of America*, v. 88, n. 1, p. 97–100, 07 1990. ISSN 0001-4966.
- TRIPLEHORN, C.; JOHNSON, N.; BORROR, D. *Borrer and DeLong's Introduction to the Study of Insects*. [S.l.]: Thompson Brooks/Cole, 2005. (Learn From The Classic Text In Entomology). ISBN 9780030968358.
- TU, G. et al. Iterative nonlinear chirp mode decomposition: A hilbert-huang transform-like method in capturing intra-wave modulations of nonlinear responses. *Journal of Sound and Vibration*, v. 485, p. 115571, 2020. ISSN 0022-460X.
- UMAPATHY, K.; GHORAANI, B.; KRISHNAN, S. Audio signal processing using time-frequency approaches: Coding, classification, fingerprinting, and watermarking. *EURASIP Journal on Advances in Signal Processing*, v. 2010, n. 1, p. 451695, Jun 2010. ISSN 1687-6180.
- UNSER, M. Sampling-50 years after shannon. *Proceedings of the IEEE*, v. 88, n. 4, p. 569–587, 2000.
- ÜRETEN, K.; MARAŞ, H. H. Automated classification of rheumatoid arthritis, osteoarthritis, and normal hand radiographs with deep learning methods. *Journal of Digital Imaging*, Jan 2022. ISSN 1618-727X.
- VILLET, M. Sound pressure levels of some african cicadas (homoptera: Cicadoidea). *Journal of the Entomological Society of Southern Africa*, v. 50, n. 2, p. 269–273, 1987.
- WANG, G. et al. On intrinsic mode function. *Advances in Adaptive Data Analysis*, v. 02, n. 03, p. 277–293, 2010.
- WANG, S.; SEKEY, A.; GERSHO, A. An objective measure for predicting subjective quality of speech coders. *IEEE Journal on Selected Areas in Communications*, v. 10, n. 5, p. 819–829, 1992.
- WEI, L.; RODRÍGUEZ-FORTUÑO, F. J. Far-field and near-field directionality in acoustic scattering. *New Journal of Physics*, IOP Publishing, v. 22, n. 8, p. 083016, aug 2020.
- WILLIAMS, K. S.; SIMON, C. The ecology, behavior, and evolution of periodical cicadas. *Annual Review of Entomology*, v. 40, n. 1, p. 269–295, 1995.
- WU, Z.; HUANG, N. E. A study of the characteristics of white noise using the empirical mode decomposition method. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, v. 460, n. 2046, p. 1597–1611, 2004.

- WU, Z.; HUANG, N. E. Statistical significance test of intrinsic mode functions. In: _____. *Hilbert–Huang Transform and Its Applications*. [S.l.: s.n.], 2005. cap. CHAPTER 7, p. 149–169.
- WU, Z.; HUANG, N. E.; CHEN, X. The multi-dimensional ensemble empirical mode decomposition method. *Advances in Adaptive Data Analysis*, v. 01, n. 03, p. 339–372, 2009.
- XUAN, B.; XIE, Q.; PENG, S. Emd sifting based on bandwidth. *IEEE Signal Processing Letters*, v. 14, n. 8, p. 537–540, Aug 2007. ISSN 1070-9908.
- YANG, L. et al. An improved envelope algorithm for eliminating undershoots. *Digital Signal Processing*, v. 23, n. 1, p. 401 – 411, 2013. ISSN 1051-2004.
- YIM, A.; CHUNG, C.; YU, A. *Matplotlib for Python Developers: Effective techniques for data visualization with Python, 2nd Edition*. [S.l.]: Packt Publishing, 2018. ISBN 9781788628136.
- YOUNG, N. *An Introduction to Hilbert Space*. [S.l.]: Cambridge University Press, 1988.
- ZAMANIAN, H.; POURGHASSEM, H. Insect identification based on bioacoustic signal using spectral and temporal features. In: *2017 Iranian Conference on Electrical Engineering (ICEE)*. [S.l.: s.n.], 2017. p. 1785–1790.
- ZGANK, A. Bee swarm activity acoustic classification for an iot-based farm service. *Sensors, Multidisciplinary Digital Publishing Institute*, v. 20, n. 1, p. 21, 2020.
- ZHANG, H.; GAI, Q. Research on properties of empirical mode decomposition method. In: *2006 6th World Congress on Intelligent Control and Automation*. [S.l.: s.n.], 2006. v. 2, p. 10001–10004.
- ZHANG, Z. et al. Characteristics investigation on shock wave fracture rock based on hilbert-huang transform method using large-scale electric explosion tests. *Powder Technology*, Elsevier, v. 415, p. 118202, 2023.
- ZHAO, M. et al. On the emd sifting property and instantaneous parameters. *Advances in Data Science and Adaptive Analysis*, v. 08, n. 02, p. 1650010, 2016.
- ZHENG, J. et al. An improved empirical wavelet transform and refined composite multiscale dispersion entropy-based fault diagnosis method for rolling bearing. *IEEE Access*, v. 8, p. 168732–168742, 2020.
- ZHIDONG, Z.; YANG, W. A new method for processing end effect in empirical mode decomposition. In: *2007 International Conference on Communications, Circuits and Systems*. [S.l.: s.n.], 2007. p. 841–845.
- ZÖLZER, U. *Digital Audio Signal Processing*. [S.l.]: Wiley, 2022. ISBN 9781119832676.
- ZWICKER, E. Subdivision of the audible frequency range into critical bands (frequenzgruppen). *The Journal of the Acoustical Society of America*, Acoustical Society of America, v. 33, n. 2, p. 248–248, 1961.
- ZWICKER, E.; FASTL, H. *Psychoacoustics: Facts and models*. [S.l.]: Springer Science & Business Media, 2013. v. 22.