UNIVERSIDADE FEDERAL DE GOIÁS
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA
E DE COMPUTAÇÃO

COMPLEXIDADE NATURAL DE SISTEMAS COM BASE EM ANÁLISE DE SENSIBILIDADE

Viviane Margarida Gomes

[UFG] & [UC]
[Goiânia - Brasil] & [Ottawa - Canadá]
30 de novembro de 2020

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 [X] Tese

2. Nome completo do autor

Viviane Margarida Gomes

3. Título do trabalho

“Complexidade Natural de Sistemas com Base em Análise de Sensibilidade”

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

Concorda com a liberação total do documento [X] SIM [ ] NÃO[1]

[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(à) autor(a) e ao(à) 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 **Wesley Pacheco Calixto**, **Usuário**

Externo, em 26/11/2020, às 15:13, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do Decreto nº 8.539, de 8 de outubro de 2015.

Documento assinado eletronicamente por **VIVIANE MARGARIDA GOMES**, **Discente**, em 30/11/2020, às 10:49, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do Decreto nº 8.539, de 8 de outubro de 2015.

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 **1707147** e o código CRC **FDBC8283**.

Referência: Processo nº 23070.040704/2020-49 SEI nº 1707147

UNIVERSIDADE FEDERAL DE GOIÁS
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA
E DE COMPUTAÇÃO

COMPLEXIDADE NATURAL DE SISTEMAS COM BASE EM ANÁLISE DE SENSIBILIDADE

Viviane Margarida Gomes

Tese apresentada à Banca Examinadora como exigência parcial para a obtenção do título de Doutor em Engenharia Elétrica e de Computação pela Universidade Federal de Goiás (UFG), Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), sob a orientação do Prof. Dr. Wesley Pacheco Calixto e supervisão do Prof. PhD. Gabriel Andrés Wainer da Universidade de Carleton, Ottawa/Canadá.

[UFG] & [UC]
[Goiânia - Brasil] & [Ottawa - Canadá]
30 de novembro de 2020

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

Gomes, Viviane Margarida
Complexidade natural de sistemas com base em análise de sensibilidade [manuscrito] / Viviane Margarida Gomes. - 2020.
183 f.: il.

Orientador: Prof. Dr. Wesley Pacheco Calixto.
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, 2020.
Bibliografia. Apêndice.
Inclui siglas, fotografias, símbolos, gráfico, tabelas, lista de figuras, lista de tabelas.

1. Complexidade de sistemas. 2. Análise de sensibilidade. 3. Complexidade natural. 4. Modelagem de sistemas. 5. Entropia. I. Calixto, Wesley Pacheco, orient. II. Título.

CDU 621.3

UNIVERSIDADE FEDERAL DE GOIÁS

ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

ATA DE DEFESA DE TESE

Ata Nº 07/2020 da sessão de Defesa de Tese de **Viviane Margarida Gomes** que confere o título de Doutora em **Engenharia Elétrica e de Computação**, na área de concentração em **Engenharia de Computação.**

Aos **trinta dias do mês de setembro de dois mil e vinte**, a partir das **14h00min.**, realizou-se a sessão pública de Defesa de Tese intitulada **" Complexidade Natural de Sistemas com Base em Análise de Sensibilidade**". Os trabalhos foram instalados pelo Orientador, Professor Doutor **Wesley Pacheco Calixto (EMC/UFG)** com a participação dos demais membros da Banca Examinadora: Professor Doutor **Gabriel Andres Wainer (VSIM/Carleton University)**, membro titular externo; Professor Doutor **Igor Santos Peretta (ENG/UFU)**, membro titular externo; Professor Doutor **Daywes Pinheiro Neto (ECA/IFG)**, membro titular externo; Professor Doutor **Weber Martins (EMC/UFG),** membro titular interno**, cujas participações ocorreram através de videoconferência.** Durante a argüição 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 sida a candidata **aprovada** pelos seus membros. Proclamados os resultados pelo Professor Doutor **Wesley Pacheco Calixto**, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos **trinta dias do mês de setembro de dois mil e vinte**.

TÍTULO SUGERIDO PELA BANCA

Documento assinado eletronicamente por **Wesley Pacheco Calixto**, **Usuário Externo**, em 01/10/2020, às 12:26, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do Decreto nº 8.539, de 8 de outubro de 2015.

Documento assinado eletronicamente por **Gabriel Andres Wainer**, **Usuário Externo**, em 01/10/2020, às 20:29, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do Decreto nº 8.539, de 8 de outubro de 2015.

Documento assinado eletronicamente por **VIVIANE MARGARIDA GOMES**, **Discente**, em 15/10/2020, às 21:33, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do Decreto nº 8.539, de 8 de outubro de 2015.

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 **1583896** e o código CRC **453806BD**.

(...) o que é melhor para cada um é também o mais natural para ele?
- Sim, certamente; o melhor é o mais natural.

Platão
em *"República"*, 380 a.C..

A quem dedico minha vida, meus filhos Miguel e Gabriel.

AGRADECIMENTOS

Sou grata a Deus, por ser plenitude em mim.

Sou grata aos mestres, grandes homens da História e da minha história.

Aos meus primeiros mestres, papai e mamãe, que me ensinaram as virtudes com exemplos, principalmente honra e gratidão.

Aos meus familiares, irmãos, primos, tios, avós, por serem meu aconchego nos momentos difíceis.

Ao meu esposo, por ser meu companheiro de escrivaninha, lado a lado e de mãos dadas, sentindo o tempo passar como passam as horas do dia.

Aos meus filhos, do meu ventre e do meu coração, por me ensinar que amor e vontade pura caminham juntos.

Aos meus orientadores, pessoas que voluntaria e genuinamente dedicaram parte das suas vidas em prol do meu crescimento.

Ao professor Wesley Pacheco Calixto (EMC/UFG), por unir seus orientandos como equipe e fazer do todo mais que a soma das partes, nos conduzindo ao infinito e além com fé e humildade: valeu a pena!

Ao professor Gabriel Wainer (VSIM/Carleton University), pelo acolhimento no Canadá, por sua amabilidade e parceria nos trabalhos desenvolvidos.

Ao professor Weber Martins (EMC/UFG), por sua capacidade de sintetizar conhecimento e transmití-lo com palavras e com a vida, de forma coerente e sincera. Em sua pessoa, agradeço aos demais professores da banca, que gentilmente quiseram contribuir com o desenvolvimento da nossa tese: professores Igor Santos Peretta (ENG/UFU), Daywes Pinheiro Neto (ECA/IFG) e Marco Antonio Assfalk de Oliveira (EMC/UFG).

Aos amigos e amigas, que caminharam sempre comigo, me aconselhando, apoiando e amando. Em especial, agradeço com uma palavra aos companheiros de caminhada acadêmica e profissional: João Ricardo Braga Paiva (gratidão), Márcio Reis (visão), Alan Silva e Alana Magalhães (acolhimento), Flávio Adalberto Gomes (amparo), Julyana Saraiva (juventude), Beatriz Lima (leveza), Paulo Flores (sensibilidade), Wanderson Rainer (dedicação), Junio Bulhões (vontade), Laís Fernanda Araújo Silva

(vida), Michelle Silva (afeto), Danielle Almeida (presença), Ruberley Rodrigues de Souza (confiança) e Cleiton Bispo (amizade).

Às pessoas que contribuíram para minha formação, em especial, aos professores de Nova Acrópole, que me despertaram para a Filosofia.

RESUMO

Este trabalho propõe metodologia de análise dos sistemas com base em medida particular de complexidade, denominada complexidade natural do sistema. Esta medida corresponde a nível de complexidade que lhe é próprio, caracterizado por região de configurações otimizadas. Dada a solução ótima ou otimizada, realiza-se a análise de sensibilidade para definir o impacto gerado na saída do sistema devido a variações nos parâmetros de entrada. A metodologia proposta compreende: i) métricas de análise de sensibilidade, ii) métrica de complexidade de sistemas com base em conexões ponderadas, iii) análise do sistema utilizando a complexidade natural como referência e iv) desenvolvimento dos modelos para aplicação da metodologia. A métrica de complexidade utiliza os índices de sensibilidade dos parâmetros para definir os valores de relevância das conexões, de forma a estabelecer relação das partes com o todo. Os resultados apontam a métrica de complexidade como mecanismo de síntese da configuração, arranjo, desempenho e carga de trabalho do sistema em única medida. No que tange à medida de complexidade natural, verificou-se que ela pode ser utilizada como referência de nível de complexidade desejado, uma vez que foi significativamente diferente das medidas obtidas em condição de sobrecarga ou de ociosidade. Em vista disto, a complexidade natural pode corresponder ao valor mínimo de complexidade do sistema em atividade regular. A métrica de complexidade proposta fortaleceu a afirmação de que todo sistema exibe algum nível de complexidade. Assim, pode-se afirmar que complexidade é a totalidade do sistema em interação, com dinâmica interna e fluxos ambientais próprios.

NATURAL COMPLEXITY OF SYSTEMS BASED ON SENSITIVITY ANALYSIS

ABSTRACT

This work proposes a methodology for analyzing systems based on a particular measure of complexity, called the natural complexity of the system. This measure corresponds to the proper level of complexity of each system, characterized by the region of optimized configurations. Given the optimal or optimized solution, the sensitivity analysis is performed to define the impact generated at the output of the system due to variations in the input parameters. The proposed methodology comprises: i) sensitivity analysis metrics, ii) system complexity metrics based on weighted connections, iii) analysis of the system using natural complexity as a reference and iv) development of models for application of the methodology. The complexity metric uses the sensitivity indices of the parameters to define the relevance values of the connections, in order to establish a relationship between the parties and the whole. The results point to the complexity metric as a mechanism for synthesizing the configuration, arrangement, performance and workload of the system in a single measure. Regarding the measure of natural complexity, it may be used as a reference of the desired level of complexity, since it was significantly different from the measures obtained under overload or idle conditions. Thus the natural complexity may correspond to the minimum complexity value of the system in regular activity. The proposed complexity metric strengthened the assertion that every system exhibits some level of complexity. Thus, it may be said that complexity is the totality of the system in interaction, with its own internal dynamics and its own environmental flows.

SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE SÍMBOLOS

LISTA DE ABREVIATURAS E SIGLAS

CAPÍTULO 1 INTRODUÇÃO 33

CAPÍTULO 2 SISTEMAS, MODELOS E SIMULAÇÕES 39

2.1 Conceito de sistema e modelo 39
2.2 Ciência de sistemas 40
2.3 Propriedades de sistemas 42
2.3.1 Totalidade 42
2.3.2 Composição 42
2.3.3 Organização interna 42
2.3.4 Organização externa 43
2.4 Sistemas complexos 43
2.5 Modelagem e simulação 46
2.6 Considerações finais 50

CAPÍTULO 3 COMPLEXIDADE DE SISTEMAS 53

3.1 Conceito de complexidade de sistemas 53
3.2 Histórico 53
3.3 Características 56
3.3.1 Não linearidade 56
3.3.2 Emergência 57
3.3.3 Auto-organização 58
3.3.4 Diversidade 59
3.3.5 Interdependência 59
3.3.6 Evolução 60
3.4 Métricas de complexidade de sistemas 61
3.4.1 Métrica com base em conexões 63

3.4.2 Métrica com base em quantidade de informação . . . 65
3.4.3 Perfil de complexidade . . . 67
3.5 Considerações finais . . . 68

CAPÍTULO 4 ANÁLISE DE SENSIBILIDADE . . . 69
4.1 Conceito e finalidade da análise de sensibilidade . . . 69
4.2 Métodos de análise de sensibilidade . . . 70
4.2.1 Métodos visuais . . . 72
4.2.2 Métodos analíticos . . . 75
4.2.3 Métodos estatísticos . . . 78
4.3 Aplicações . . . 80
4.4 Considerações finais . . . 82

CAPÍTULO 5 METODOLOGIAS PROPOSTAS . . . 83
5.1 Métricas propostas de análise de sensibilidade . . . 83
5.1.1 Método da área . . . 83
5.1.2 Método da soma das diferenças . . . 85
5.1.3 Método da variância condicional local . . . 86
5.2 Métrica proposta de complexidade de sistemas . . . 87
5.3 Análise do sistema com base na complexidade natural . . . 89
5.4 Modelos para aplicação da metodologia . . . 91
5.4.1 Sistema do motor de corrente contínua com controlador PID . . . 91
5.4.2 Sistema de desenvolvimento de *startups* . . . 93
5.4.3 Sistema de unidade de terapia intensiva . . . 95
5.5 Considerações finais . . . 99

CAPÍTULO 6 RESULTADOS . . . 101
6.1 Análise de sensibilidade dos sistemas . . . 101
6.1.1 Análise de sensibilidade do sistema do motor de corrente contínua . . . 101
6.1.2 Análise de sensibilidade do sistema de desenvolvimento de *startups* . . . 112
6.1.3 Análise de sensibilidade do sistema de unidade de terapia intensiva . . . 115
6.2 Análise da complexidade dos sistemas . . . 124
6.2.1 Complexidade do sistema do motor de corrente contínua . . . 124
6.2.2 Complexidade do sistema de desenvolvimento de *startups* . . . 126
6.2.3 Complexidade do sistema de unidade de terapia intensiva . . . 129
6.3 Avaliação dos sistemas com base na complexidade natural . . . 133
6.4 Discussão . . . 137

CAPÍTULO 7 CONCLUSÃO . . . 143

7.1 Contribuições do trabalho 143
7.2 Demais trabalhos publicados durante o período do doutoramento 145
7.3 Trabalhos futuros 148

APÊNDICE A Estudos anteriores às metodologias propostas 151
A.1 Motivação para proposta da complexidade natural dos sistemas 151
A.1.1 Estudo de caso 1: centro de distribuição 151
A.1.2 Estudo de caso 2: centro médico 156

APÊNDICE B Medidas para análise de sensibilidade do Sistema de UTI 161

APÊNDICE C Dados da demanda de vagas de unidade de terapia intensiva 167

REFERÊNCIAS BIBLIOGRÁFICAS 171

LISTA DE FIGURAS

Pág.

2.1 Domínios de sistemas. 39
2.2 Classificação das ciências e dos sistemas. 41
2.3 Exemplos de comportamentos individuais nos sistemas. 45
2.4 Matriz de Stacey e sua relação com métodos de apoio a decisão. 48

3.1 Progressão histórica da complexidade da humanidade e as respectivas estruturas de controle. 56
3.2 Relação entre padrões de organização de sistema e medidas de complexidade. 62
3.3 Combinação de padrões aleatórios e regulares de organização na natureza. 62
3.4 Exemplo de configuração das conexões estabelecidas pelas entidades de E_1 a E_6 em dado instante. 64
3.5 Escalas do perfil de complexidade humana. 67

4.1 Esquema de medidas um parâmetro por vez para n parâmetros de entrada. 71
4.2 Exemplo de diagrama-aranha com três parâmetros: x_1, x_2 e x_3. 73
4.3 Diagrama de dispersão dos parâmetros de entrada de x_1 a x_4 em relação à saída y. 74

5.1 Exemplo de delimitação da área no diagrama-aranha para análise de sensibilidade. 84
5.2 Exemplo de modelo com cinco parâmetros de entrada e duas saídas. . . . 88
5.3 Fluxo da análise de sistema e monitoramento com base em complexidade natural. 90
5.4 Modelo de controle do motor de corrente contínua de excitação independente com campo variável. 92
5.5 Modelo de desenvolvimento de *startups*. 94
5.6 Diagrama-radar ilustrativo dos pilares de desenvolvimento para cada *startup*. 94
5.7 Modelo de unidade de terapia intensiva com base em conexões. 97
5.8 Fluxo de pacientes em unidade de terapia intensiva. 98

6.1 Contexto para análise de sensibilidade do MCC com controlador PID. . . 102
6.2 Diagrama-aranha dos parâmetros do MCC com controlador PID referente ao caso-base otimizado $\alpha_p^0 = (1,16 \cdot 10^2;\ 6,61 \cdot 10^{-3};\ 3,02;\ 4,81 \cdot 10^{-3})$. . 103

6.3 Dispersão dos valores de entrada referente aos casos de inconsistência: (a) V_f, (b) k_p, (c) k_i e (d) k_d. 104
6.4 Média e média acumulada das saídas do MCC com controlador PID × número de cenários: (a) IAE e (b) η_e. 106
6.5 Cenários do MCC com controlador PID para aplicação do método da variância local: (a) $V_f^* = 1,16 \cdot 10^2 V$, (b) $k_p^* = 6,61 \cdot 10^{-3} V \cdot s/rad$, (c) $k_i^* = 3,02 V \cdot s/rad$ e (d) $k_d^* = 4,81 \cdot 10^{-3} V \cdot s/rad$. 107
6.6 Diagrama de dispersão para os parâmetros: (a) V_f, (b) k_p, (c) k_i e (d) k_d. 108
6.7 Diagrama-aranha dos parâmetros do MCC com controlador PID referente a casos-base não otimizados: (a) $\alpha_p^{-40\%}$ e (b) $\alpha_p^{+40\%}$. 109
6.8 Contextos para análise da sensibilidade do MCC com controlador PID para os parâmetros: (a) entrada k_p, k_i e k_d saída $\longrightarrow IAE$ e (b) entrada ω_{ref} e V_f saída $\longrightarrow \eta_e$. 110
6.9 Diagrama-aranha dos parâmetros do MCC com controlador PID referente a caso-base otimizado: (a) $\alpha_{p_a}^0 = (6,61{\cdot}10^{-3};\ 3,02;\ 4,81{\cdot}10^{-3})$ e (b) $\alpha_{p_b}^0 = (2,35 \cdot 10^2;\ 1,16 \cdot 10^2)$. 111
6.10 Contexto para análise de sensibilidade do sistema de desenvolvimento de *startups*. 113
6.11 Quadro de gestão à vista para as *startups* em aceleração. 113
6.12 Diagrama-aranha dos parâmetros do sistema de desenvolvimento de *startups*. 115
6.13 Contexto para análise de sensibilidade da unidade de terapia intensiva. . 118
6.14 Comportamento das variáveis componentes do desempenho da UTI para os casos-base. 120
6.15 Diagrama-aranha dos parâmetros da unidade de terapia intensiva referente ao caso-base otimizado α_u^{36h}. 120
6.16 Diagrama-aranha dos parâmetros da UTI referente aos casos-base: (a) α_u^{12h} e (b) α_u^{24h}. 121
6.17 Diagrama-aranha dos parâmetros da UTI referente aos casos-base: (a) α_u^{48h}, (b) α_u^{60h} e (c) α_u^{72h}. 122
6.18 Valores dos índices de sensibilidade para casos-base em condições de sobrecarga, regularidade e ociosidade. 123
6.19 Modelo das conexões do MCC com sistema de controle, parâmetros de entradas e variável de saída utilizados no cálculo de complexidade. 125
6.20 Modelo das conexões do sistema de desenvolvimento de *startups*, parâmetros de entradas e variável de saída utilizados para cálculo de complexidade. 127
6.21 Modelo das conexões do sistema de UTI, parâmetros de entradas e variável de saída utilizados para cálculo de complexidade. 130

6.22 Comparação entre medidas de complexidade com base em conexões $\psi^{uti}(c)$ e em conexões ponderadas $\psi^{uti}(c, \gamma_c)$ referente a distintas situações de demanda do sistema de UTI. 132
6.23 Complexidade com base em conexões ponderadas $\psi^{uti}(c, \gamma_c)$ e desempenho da UTI η_{uti} referente a distintas situações de demanda do sistema. . 135
6.24 Desempenho da UTI η_{uti} × complexidade com base em conexões ponderadas $\psi^{uti}(c, \gamma_c)$. 136

A.1 Medidas do tempo de entrega t_e e de complexidade $\psi(c)^{cd}$ relacionadas aos cenários do centro de distribuição. 152
A.2 Diagrama-aranha do centro de distribuição para saída $\psi(c)^{cd}$. 154
A.3 Comparação entre medidas de complexidade $\psi(c)^{cd}$ e $\psi(H)^{cd}$ para o centro de distribuição. 156
A.4 Utilização de recursos e a complexidade $\psi(c)^{cm}$ relacionados aos cenários do centro médico. 158
A.5 Diagrama-aranha do centro médico para saída $\psi(c)^{cm}$. 160

C.1 Demanda de vagas em UTI localizadas na cidade de Goiânia de abril a julho de 2019. 167
C.2 Origem da demanda de vagas em UTI localizadas em Goiânia de maio a julho de 2019: (a) UTI Neonatal, (b) UTI Pediátrica e (c) UTI Adulto. . 168

LISTA DE TABELAS

Pág.

2.1 Classificação de modelos de acordo com as bases de tempo e variáveis de estado. . . . 50

3.1 Métricas de complexidade de sistemas. . . . 63

4.1 Combinações de planejamento fatorial de 2^3. . . . 77

5.1 Classificação de prioridade de admissão de paciente na UTI. . . . 98

6.1 Dados dos parâmetros V_f, k_p, k_i e k_d para análise de sensibilidade do MCC com controlador PID. . . . 102

6.2 Estatísticas da saída IAE para diferentes contextos de simulação. . . . 105

6.3 Estatísticas da saída eficiência energética η_e para diferentes contextos de simulação. . . . 105

6.4 Índices de sensibilidade de V_f, k_p, k_i e k_d do MCC com controlador PID referente à saída IAE. . . . 106

6.5 Índices de sensibilidade de V_f, k_p, k_i e k_d do MCC com controlador PID referente à saída IAE com $\alpha_p^{-40\%}$. . . . 109

6.6 Índices de sensibilidade de V_f, k_p, k_i e k_d do MCC com controlador PID referente à saída IAE com $\alpha_p^{+40\%}$. . . . 110

6.7 Dados dos parâmetros k_p, k_i e k_d para análise de sensibilidade do MCC com controlador PID. . . . 110

6.8 Dados dos parâmetros ω_{ref} e V_f para análise de sensibilidade do MCC com controlador PID. . . . 110

6.9 Índices de sensibilidade de k_p, k_i e k_d do MCC com controlador PID referente à saída IAE. . . . 111

6.10 Índices de sensibilidade de ω_{ref} e V_f do MCC com controlador PID referente à saída η_e. . . . 112

6.11 Dados dos parâmetros para análise de sensibilidade do sistema de desenvolvimento de *startups*. . . . 114

6.12 Índices de sensibilidade de p_e, p_s, η_s, p_{ch} e g_p do sistema de desenvolvimento de *startups*. . . . 114

6.13 Parâmetros e respectivos valores definidos para análise de sensibilidade do sistema de UTI. . . . 118

6.14 Casos-base para análise de sensibilidade do sistema da UTI em condição de sobrecarga, regularidade e ociosidade. . . . 119

6.15 Dados de simulação das variáveis componentes do desempenho da UTI para os casos-base. 119
6.16 Índices de sensibilidade dos parâmetros da UTI referente à saída η_{uti} obtidos por meio do método da área. 123
6.17 Relevância γ_c das conexões do modelo do MCC com controlador PID. . . 125
6.18 Complexidade $\psi^{mcc}(c, \gamma_c)$ do MCC com controlador PID de acordo com método de análise de sensibilidade. 126
6.19 Probabilidades das conexões $P(c)$ do sistema de desenvolvimento de *startups*. 127
6.20 Relevância γ_c das conexões do sistema de desenvolvimento de *startups*. . 127
6.21 Complexidade do sistema de desenvolvimento de *startups* de acordo com método de análise de sensibilidade. 128
6.22 Complexidade $\psi^{sds}(c, \gamma_c)$ do sistema de desenvolvimento de *uma startup* de acordo com método de análise de sensibilidade. 129
6.23 Probabilidades das conexões $P(c)$ do sistema da unidade de terapia intensiva referente à fila para distintos casos-base. 130
6.24 Probabilidades $P(c)$ das conexões do sistema da unidade de terapia intensiva referente aos recursos e eventos adversos. 131
6.25 Relevância γ_c das conexões do sistema da unidade de terapia intensiva. . 131
6.26 Valores de complexidade com base em conexões $\psi^{uti}(c)$ e em conexões ponderadas $\psi^{uti}(c, \gamma_c)$ referente a distintas situações de demanda do sistema de UTI. 132
6.27 Valores das componentes da complexidade $\psi^{uti}(c, \gamma_c)$ referente a distintas situações de demanda do sistema de UTI. 133
6.28 Estatística descritiva da complexidade das amostras referentes às condições de atividade do sistema de UTI. 136

A.1 Índice R_c^{cd} como relação entre tempo de entrega t_e e complexidade $\psi(c)^{cd}$. 153
A.2 Dados para análise de sensibilidade do centro de distribuição. 153
A.3 Índice de sensibilidade dos parâmetros do centro de distribuição para a saída $\psi(c)^{cd}$. 154
A.4 Matriz resposta para o centro de distribuição. 155
A.5 Índice R_c^{cm} como relação entre tempo no centro médico t_p e complexidade $\psi(c)^{cm}$. 158
A.6 Dados para análise de sensibilidade do centro médico. 159
A.7 Índice de sensibilidade dos parâmetros do centro médico para saída $\psi(c)^{cm}$. 160

B.1 Medidas *one-at-a-time* para caso-base $\alpha_u^{12h} = (10;\ 1;\ 1,05;\ 0,12;\ 12)$. . . 161
B.2 Medidas *one-at-a-time* para caso-base $\alpha_u^{24h} = (10;\ 1;\ 1,05;\ 0,12;\ 24)$. . . 162
B.3 Medidas *one-at-a-time* para caso-base $\alpha_u^{36h} = (10;\ 1;\ 1,05;\ 0,12;\ 36)$. . . 163

B.4 Medidas *one-at-a-time* para caso-base $\alpha_u^{48h} = (10;\ 1;\ 1,05;\ 0,12;\ 48)$. . . 164
B.5 Medidas *one-at-a-time* para caso-base $\alpha_u^{60h} = (10;\ 1;\ 1,05;\ 0,12;\ 60)$. . . 165
B.6 Medidas *one-at-a-time* para caso-base $\alpha_u^{72h} = (10;\ 1;\ 1,05;\ 0,12;\ 72)$. . . 166

LISTA DE SÍMBOLOS

α	–	caso-base ou conjunto dos valores-base dos parâmetros de entrada
α_j	–	valor-base do parâmetro de entrada x_j
α_p^0	–	caso-base otimizado do sistema do motor de corrente contínua composto pelos parâmetros V_f, k_p, k_i e k_d
$\alpha_p^{-40\%}$	–	caso-base correspondente ao valor otimizado reduzido em 40% referente ao sistema do motor de corrente contínua
$\alpha_p^{+40\%}$	–	caso-base correspondente ao valor otimizado acrescido em 40% referente ao sistema do motor de corrente contínua
$\alpha_{p_a}^0$	–	caso-base otimizado do sistema do motor de corrente contínua composto pelos parâmetros k_p, k_i e k_d
$\alpha_{p_b}^0$	–	caso-base otimizado do sistema do motor de corrente contínua composto pelos parâmetros V_f e ω_{ref}
α_s	–	caso-base otimizado do sistema de desenvolvimento de *startups*
α_u^{12h}	–	caso-base do sistema de unidade de terapia intensiva referente à taxa de chegada seguindo distribuição $N(12, 4)$
α_u^{24h}	–	caso-base do sistema de unidade de terapia intensiva referente à taxa de chegada seguindo distribuição $N(24, 4)$
α_u^{36h}	–	caso-base do sistema de unidade de terapia intensiva referente à taxa de chegada seguindo distribuição $N(36, 4)$
α_u^{48h}	–	caso-base do sistema de unidade de terapia intensiva referente à taxa de chegada seguindo distribuição $N(48, 4)$
α_u^{60h}	–	caso-base do sistema de unidade de terapia intensiva referente à taxa de chegada seguindo distribuição $N(60, 4)$
α_u^{72h}	–	caso-base do sistema de unidade de terapia intensiva referente à taxa de chegada seguindo distribuição $N(72, 4)$
β	–	saída correspondente ao caso-base
γ_c	–	relevância de conexão
γ_{AC}	–	relevância da conexão AC
γ_{kappa}	–	relevância da κ-ésima conexão
δ_{x_j,x_l}	–	variância devido à interação entre os parâmetros de entrada x_j e x_l
ϵ_{x_j}	–	número de polígonos de x_j usado no método da área
ζ_{x_j}	–	número de pontos de intersecções da curva do parâmetro x_j com o eixo-base no intervalo $[a, b]$
η_e	–	eficiência energética
η_s	–	desempenho do sistema de desenvolvimento de *startups*
η_{uti}	–	desempenho da unidade de terapia intensiva
$\mu_{chegada}$	–	média da taxa de chegada
θ	–	constante adimensional
κ	–	contador
λ	–	número de estados das entidades

$\overline{\mu}_{\sigma^2}$ – média da variância
$\overline{\mu}_{x_j}$ – média do parâmetro de entrada x_j
ν – combinação de valores de parâmetros de entrada no método de planejamento fatorial
ξ – número de saídas
ρ – número de conexões ativas
σ – desvio padrão
σ_{x_j} – desvio padrão do parâmetro de entrada x_j
σ_y – desvio padrão da saída y
σ^2 – variância
$\sigma^2_{\delta_{x_j,x_l}}$ – variância devido à interação entre os parâmetros de entrada x_j e x_l
$\sigma^2_{\overline{\mu}}$ – variância da média
υ – restrições de relacionamento entre entidade e recurso/fila
ψ – complexidade de sistemas
ψ_n – complexidade natural de sistemas
$\psi(c, \gamma_c)$ – complexidade de sistemas com base em conexões ponderadas
$\psi_n(c, \gamma_c)$ – complexidade natural de sistemas com base em conexões ponderadas
$\psi^{mcc}(c, \gamma_c)$ – complexidade com base em conexões ponderadas do sistema do motor de corrente contínua
$\psi^{sds}(c, \gamma_c)$ – complexidade com base em conexões ponderadas do sistema de desenvolvimento de *startups*
$\psi^{uti}(c, \gamma_c)$ – complexidade com base em conexões ponderadas do sistema de unidade de terapia intensiva
$\psi^{mcc}_n(c, \gamma_c)$ – complexidade natural com base em conexões ponderadas do sistema do motor de corrente contínua
$\psi^{sds}_n(c, \gamma_c)$ – complexidade natural com base em conexões ponderadas do sistema de desenvolvimento de *startups*
$\psi^{uti}_n(c, \gamma_c)$ – complexidade natural com base em conexões ponderadas do sistema de unidade de terapia intensiva
$\psi(c)$ – complexidade de sistemas com base em conexões
$\psi^{mcc}(c)$ – complexidade com base em conexões do sistema do motor de corrente contínua
$\psi^{sds}(c)$ – complexidade com base em conexões do sistema de desenvolvimento de *startups*
$\psi^{uti}(c)$ – complexidade com base em conexões do sistema de unidade de terapia intensiva
$\psi(H)$ – complexidade de sistemas com base em quantidade de informação
ω – velocidade angular do motor
ω_{ref} – velocidade angular de referência

a – limite inferior do intervalo de análise no diagrama-aranha

A_{x_j} – área no diagrama-aranha entre a curva de variação do parâmetro x_j e o eixo-base no intervalo $[a, b]$

b – limite superior do intervalo de análise no diagrama-aranha

B – constante de atrito viscoso

c – conexão entre elementos do sistema

cp_1 – componente da complexidade $\psi(c, \gamma_c)$ relativa à sensibilidade

cp_2 – componente da complexidade $\psi(c, \gamma_c)$ relativa à entropia

C_n – matriz de contingência

D_{x_j} – soma das diferenças entre os valores discretos $y|_{x_j}$ e o valor de β no intervalo $[a, b]$

e_r – número máximo de entidades atendidas por recurso

$e(\upsilon)$ – número de entidades atendidas por recurso ou em cada fila dadas as restrições υ

e_l – erro de linearização

E_ω – erro de velocidade

E_g – força eletromotriz

f_{aval} – função de avaliação do sistema de desenvolvimento de *startups*

g_p – gestão de portfólio

$H(x)$ – quantidade de informação de entrada

$H(y)$ – quantidade de informação de saída

i – contador de linha de matriz

I_a – corrente de armadura

I_f – corrente de campo

IAE – integral do módulo do erro

j – contador de coluna de matriz

J – momento de inércia

k_d – ganho derivativo do controlador PID

k_i – ganho integral do controlador PID

k_p – ganho proporcional do controlador PID

l – contador de coluna de matriz $\neq j$

L_{af} – indutância mútua entre o circuito de campo e de armadura

L_a – indutância do circuito de armadura

L_f – indutância do circuito de campo

m – número de cenários

M – matriz de relacionamento

n – número de parâmetros de entrada

n_ε – número de entidades por estado

n_a – número de admissões na UTI

$n_{a_{ref}}$ – valor de referência para número de admissões na UTI

n_c – número das conexões ativas por estado

n_e – número de entidades

n_f – número de pacientes na fila da UTI
$n_{f_{ref}}$ – valor de referência para número de pacientes na fila da UTI
n_l – número de leitos em uso na UTI
$n_{l_{ref}}$ – valor de referência para número de leitos em uso na UTI
n_q – número de filas
n_r – número de recursos
n_{equipe} – percentual de equipe médica
$n_{insumos}$ – percentual de insumos
n_{leitos} – número de leitos
p_{ch} – nota do *pitch*
p_e – perfil dos empreendedores
p_s – perfil da *startup*
P – probabilidade
$P(c)$ – probabilidade de ocorrência da conexão c
$P(r_i)$ – probabilidade estimada como frequência relativa por linha i da matriz resposta
$P(r_j)$ – probabilidade estimada como frequência relativa por coluna j da matriz resposta
r – frequência da entrada em relação à saída
r_i – frequência da entrada em relação à saída referente à linha i da matriz resposta
r_j – frequência da entrada em relação à saída referente à coluna j da matriz resposta
R_a – resistência do circuito de armadura
R_c – relação de custo em termos de desempenho para cada unidade de complexidade do sistema
R_f – resistência do circuito de campo
s – domínio da frequência
S_{η_s} – índice de sensibilidade do desempenho do sistema de desenvolvimento de *startups* η_s
$S_{\mu_{chegada}}$ – índice de sensibilidade da média da taxa de chegada $\mu_{chegada}$
$S_{\omega_{ref}}$ – índice de sensibilidade da velocidade angular de referência
S_{g_p} – índice de sensibilidade da gestão de portfólio g_p
S_{k_p} – índice de sensibilidade do ganho proporcional k_p
S_{k_i} – índice de sensibilidade do ganho integral k_i
S_{k_d} – índice de sensibilidade do ganho derivativo k_d
$S_{n_{equipe}}$ – índice de sensibilidade do percentual de equipe médica n_{equipe}
$S_{n_{insumos}}$ – índice de sensibilidade do percentual de insumos $n_{insumos}$
$S_{n_{leitos}}$ – índice de sensibilidade do número de leitos n_{leitos}
$S_{p_{ch}}$ – índice de sensibilidade da nota do *pitch* p_{ch}
S_{p_e} – índice de sensibilidade do perfil dos empreendedores p_e
S_{p_s} – índice de sensibilidade do perfil das *startups* p_s

$S_{tx_{ea}}$ – índice de sensibilidade da taxa de eventos adversos tx_{ea}
S_{V_f} – índice de sensibilidade da tensão de campo V_f
$S^f_{x_j}$ – sensibilidade do parâmetro x_j dado pelo método de planejamento fatorial
$S^\sigma_{x_j}$ – sensibilidade do parâmetro x_j dado pelo método de derivadas parciais normalizado pelo desvio padrão
$S^{\sigma^2}_{x_j}$ – índice de sensibilidade do parâmetro x_j dado pelo método de variância condicional
$S^{\sigma^2*}_{x_j}$ – índice de sensibilidade do parâmetro x_j dado pelo método de variância condicional local
$S^\tau_{x_j}$ – índice de sensibilidade do parâmetro x_j dado pelo método de efeitos totais
$S^a_{x_j}$ – índice de sensibilidade do parâmetro x_j dado pelo método da área
$S^d_{x_j}$ – índice de sensibilidade do parâmetro x_j dado pelo método da soma das diferenças
$S^p_{x_j}$ – sensibilidade do parâmetro x_j dado pelo método de derivadas parciais
$t_{s_{ref}}$ – valor de referência para tempo de internação na UTI em dias
tx_{ea} – taxa de eventos adversos
T_d – torque desenvolvido
T_l – torque da carga
T_m – torque do motor
t_s – tempo de internação na UTI em dias
v – quantidade de valores discretos da curva de variação do parâmetro x_j
V_a – tensão de armadura
V_f – tensão de campo
x – parâmetro de entrada do sistema
X – matriz de valores dos conjuntos de parâmetros de entrada ou cenários
y – saída do sistema
Y – matriz de valores de saída respectivos aos cenários
$Y|_{x_{\sim j}}$ – matriz de saídas quando x_j constante e demais parâmetros variáveis
z – número de startups prontas para decolagem

LISTA DE ABREVIATURAS E SIGLAS

IAE	–	Integral Absolute Error
CRE	–	Complexo Regulador Estadual
MCC	–	Motor de Corrente Contínua
PID	–	Proporcional-Integral-Derivativo
MVP	–	Minimum Viable Product
SDS	–	Sistema de Desenvolvimento de *Startups*
SUS	–	Sistema Único de Saúde
UTI	–	Unidade de Terapia Intensiva

CAPÍTULO 1

INTRODUÇÃO

Durante séculos, cientistas tentam explicar o todo por suas partes, realizando sucessivas divisões em busca da menor estrutura que caracterize cada sistema e em última análise, todos os sistemas. A partir dos anos 1945, alguns estudos apresentam movimento contrário, partindo do pressuposto de que a compreensão do sistema requer conhecimento das leis e propriedades de suas interações (WEAVER, 1948; SIMON, 1962; BERTALANFFY, 1969). Neste sentido, diversas pesquisas têm sido desenvolvidas a fim de compreender como a combinação de **simples estruturas** pode resultar em **composições complexas**.

Para Bak (1996), os físicos são reducionistas ao considerar que o mundo pode ser entendido em termos das propriedades de simples blocos de construção. Embora tenham obtido sucesso em alguns casos, a **complexidade dos sistemas** exige mais que a análise fragmentada dos mesmos. Os pesquisadores têm percebido que subdividir os sistemas para analisá-los pode causar perdas relevantes quanto à estrutura interna do sistema original (NOHARA et al., 1989). Portanto, é preferível observar todo o sistema, modelando-o em termos de entradas e saídas para simular seu comportamento com o auxílio de tecnologias.

A abordagem global no estudo dos sistemas torna a afirmação filosófica de que o **todo é mais que a soma das partes** comum no meio científico. De acordo com Simon (1962), em sistemas complexos, esta afirmação significa compreender que as propriedades do todo não podem ser facilmente inferidas a partir das propriedades das partes e de suas leis de interação. Ao estudar os sistemas integralmente, as **interações** assumem papel de destaque, especialmente quando as formas de interação superam as distâncias físicas devido ao desenvolvimento tecnológico (WANG; BJØRKET, 1994; MAIER, 1996; MOSLEH et al., 2016). Os sistemas criados pelo homem tornam-se mais integrados e interdependentes, consequentemente, mais complexos.

Bar-Yam (1997a) afirma que o aumento na complexidade está diretamente relacionado à crescente **interdependência** dos sistemas econômico e social globais e às instabilidades políticas. Para o autor, a interdependência é caracterizada pela estrutura de controle em rede, que considera as interações laterais e transfere a tomada de decisão para equipes, devido à alta complexidade do comportamento coletivo. Independentemente da escala e do tipo de sistema em análise, a complexidade surge como característica unificadora do nosso mundo (BAR-YAM, 1997a; MEED, 2005).

Segundo Holland (2014), o termo **complexidade** tem assumido tamanha importância que, ao invés de ser nome comum para descrever objetos com várias partes interconectadas, passa a designar **campo científico** com várias ramificações. Alguns autores consideram que a ciência do Século XXI é a ciência da complexidade (MAINZER; CHUA, 2011). No entanto, a existência da ciência ou teoria da complexidade é refutada, devido à falta de consenso na definição quantitativa de complexidade. Nenhuma das diversas métricas é universalmente aceita pelos cientistas, nem tão pouco são práticas (MITCHELL, 2009).

Lloyd (2001) argumenta que as **métricas de complexidade** são desenvolvidas para responder questões sobre o sistema quanto a: dificuldade de descrição, dificuldade de criação ou grau de organização. Nestas categorias, a complexidade tem sido abordada de diferentes formas: entropia (ROSSO et al., 2012; BATTY et al., 2014), estatística (FELDMAN; CRUTCHFIELD, 1998; ABDALLAH; PLUMBLEY, 2012; ARBONA et al., 2014), dimensão fractal (CORBIT; GARBARY, 1995; YOUNG et al., 2017), conteúdo de informação algorítmica (GELL-MANN; LLOYD, 1996; AY et al., 2010), profundidade dinâmica (DEACON; KOUTROUFINIS, 2014), **conexões** (PAIVA et al., 2017; GOMES et al., 2019), entre outras formas.

Ao investigar complexidade observando objetos autossimilares, Balaban et al. (2018) propõem métrica para quantificar emergência e auto-organização estendendo a **dimensão fractal** a uma função, uma vez que a maioria dos objetos semelhantes a fractal possui múltiplas taxas de escala. Logo a análise multifractal investiga as leis de escala estatística de objetos geométricos fragmentados e complexos como os agregados de bactérias. Balaban et al. (2018) observam a evolução de arranjos espaciais de agregados de *Enterobacter cloacae* e aplicam análise multifractal para calcular alterações em termos de emergência e auto-organização na população bacteriana. Os resultados experimentais indicam que o grau de emergência diminui à medida que o agregado popula o prato, ao passo que o grau de auto-organização aumenta.

Entre as métricas de complexidade, a dimensão fractal é frequentemente aplicada à análise de texturas, formas e estruturas de rede (XUE; BOGDAN, 2017; LI et al., 2009; CORBIT; GARBARY, 1995). No entanto, quando a dinâmica detalhada do sistema é conhecida, outras métricas podem ser mais eficazes, como aquelas que se baseiam em **interações**. Por exemplo, as métricas propostas por Koorehdavoudi e Bogdan (2016) para quantificar a complexidade das interações espaço-temporais, as quais estimam o panorama de energia livre dos estados e distinguem entre estados estáveis e de transição. Esta modelagem é aplicada a três grupos naturais: bactérias nadadoras,

pombos voadores e formigas. A análise demonstra que o grupo coletivo tem menor nível de energia e maior grau de complexidade em estados estáveis em comparação com os estados de transição.

Em Koorehdavoudi e Bogdan (2016), a complexidade de sistemas é analisada pela aplicação de métricas propostas com base na segunda lei da termodinâmica, assim como de Jacobson (1955) a Gomes et al. (2019). Esta lei pode ser enunciada como disposição natural dos sistemas em ter sua entropia (ou desordem) aumentada à medida que evoluem (BARANGER, 2000). Em alguns destes estudos, a complexidade mínima é estimada e tomada como referência, a fim de propiciar comparações do sistema com ele próprio.

De forma geral, as diversas métricas existentes constituem visões parciais do objeto analisado, destoando do conceito de complexidade. Afinal os estudos sobre o tema decorrem da necessidade de utilizar o paradigma de distinção/conjunção na organização do conhecimento, que concebe a **unidade** e **multiplicidade** do real, escapando à unidade abstrata do holismo e do reducionismo (MORIN, 2005). Segundo Morin (2005), a complexidade é o tecido de constituintes heterogêneas inseparavelmente associadas (paradoxo do uno e do múltiplo).

Apesar dos esforços de filósofos, sociólogos e cientistas, o conhecimento sobre o tema **complexidade** ainda é incipiente. Até mesmo características consideradas próprias de sistemas complexos possuem demarcação incerta, como emergência, que pode ser concebida como a combinação de simples elementos para gerar organização complexa (HOLLAND, 2014). Definir o sistema como complexo ainda é esforço de certo modo subjetivo.

Do ponto de vista filosófico, o conceito da palavra **complexo**, enquanto adjetivo, é o oposto de **simples**. De forma qualitativa, a simplicidade refere-se à clareza que se tem a respeito do objeto em análise. Portanto, a atribuição do adjetivo simples depende do conhecimento do indivíduo acerca do objeto. Logo, pode-se afirmar que o termo complexo é atribuído a tudo que não se tem clareza nem conhecimento suficiente, que se ainda vê de forma obscura.

A falta de clareza deve-se, em parte, ao desconhecimento do **princípio** ou **lei** que rege o sistema. Em outros casos, mesmo que se conheça o princípio, o número de variáveis que participam do sistema pode ser expressivo ao ponto de gerar comportamentos emergentes, de difícil previsão ou domínio. Gell-Mann (1988) afirma que a aparente complexidade é parcialmente removida quando a lei é encontrada. Este

autor analisa a aplicação dos conceitos de simplicidade e complexidade na descrição da natureza, avaliando se o fractal é sistema simples ou complexo.

Sob o ponto de vista da **complexidade ideal**, definida como o comprimento mínimo da mensagem que descreve o sistema, o fractal não é de todo complexo, visto que toda informação necessária para gerá-lo parte de regra simples. Contudo, a complexidade ideal não leva em conta o tempo, o trabalho ou o custo de gerar a figura do fractal a partir da fórmula ou a dificuldade de descobrir como voltar do fractal à regra simples que o constitui (GELL-MANN, 1988).

Analisando os conceitos de simples e complexo pelo viés quantitativo, tem-se que o simples é constituído de apenas um elemento e o complexo é composto por vários elementos ou partes (HOUAISS, 2009). Sob este ponto de vista, **todo sistema possui algum grau de complexidade**, visto que todo sistema é composto por elementos que funcionam como um todo. Assim, tanto a organização interna quanto externa dos sistemas contribuem na definição do seu grau de complexidade, pois as conexões e mecanismos internos refletem a interação com ambiente por meio das variáveis de entrada e saída (MOBUS; KALTON, 2015).

Compreender como o sistema se comporta devido a variações nos parâmetros de entrada é objeto de estudo da **análise de sensibilidade**, que investiga: i) como a incerteza na entrada propaga-se pelo sistema contribuindo na variabilidade da saída e ii) como os parâmetros de entrada e a saída estão correlacionados (HAMBY, 1994).

O estudo sobre sensibilidade tem aplicações em diversas áreas, como as engenharias, biologia, química entre outras, incluindo a complexidade de sistemas (ZHANG et al., 2001; GANOPOLSKI et al., 2001; LINDENSCHMIDT, 2006; BASTIDAS et al., 2006; SOLSVIK; JAKOBSEN, 2011; GOMES et al., 2015). Em estudo sobre complexidade com base em conexões, Paiva et al. (2017) observam que os picos de complexidade refletem a influência do parâmetro mais sensível no comportamento do sistema.

Métodos de análise de sensibilidade possibilitam medir quanto o sistema é sensível a variações nos parâmetros de entrada, de forma que aspectos internos do sistema possam ser relacionados a fatores externos. Logo, considera-se relevante a análise de sensibilidade no estudo da complexidade, uma vez que algumas variáveis podem eventualmente emergir e gerar impacto significativo no sistema (PAIVA et al., 2017).

Considerando ainda: i) o aumento em complexidade, ii) a abordagem integral dos sistemas, iii) a complexidade como variável unificadora e iv) a ausência de definição

quantitativa de complexidade que seja prática e representativa, verifica-se **lacuna existente** no processo de síntese das características descritivas e organizacionais dos sistemas em medida particular. Portanto, pretende-se investigar como a complexidade dos sistemas pode ser mensurada com foco nas partes e no todo.

Com base na segunda lei da termodinâmica e na análise de sensibilidade, este trabalho propõe métrica de complexidade de sistemas com base em conexões ponderadas por índices de sensibilidade e conceito de **complexidade natural**: valor de complexidade referente à configuração otimizada do sistema, quando seus parâmetros estão ajustados de forma a maximizar seu desempenho. Logo, se a complexidade natural for tomada como referência de funcionamento adequado do sistema, então o **sistema** está **ocioso** quando apresenta complexidade inferior à sua complexidade natural e está **sobrecarregado** quando apresenta complexidade superior à sua complexidade natural, compreendendo assim a hipótese básica deste trabalho.

Este trabalho limita-se a investigar o **grau de complexidade** dos sistemas como medida que compreende mecanismos da dinâmica interna e externa dos mesmos. Não se pretende definir qualquer referência para classificar determinado sistema como complexo ou não, por exemplo, sistema complexo é aquele que tem partes interdependentes e viola o teorema ergódico (BAR-YAM, 1997b).

O **objetivo** geral deste trabalho é contribuir para a análise integral dos sistemas por meio de metodologia para medir complexidade. Dentre os objetivos específicos, têm-se: i) desenvolver estudo filosófico sobre o tema, ii) desenvolver métricas para quantificar a sensibilidade dos parâmetros, iii) desenvolver métrica de complexidade com base em conexões ponderadas, iv) definir sistemas para estudo, v) modelar e simular os sistemas escolhidos, vi) calcular a sensibilidade dos parâmetros, vii) calcular a complexidade dos sistemas e viii) analisar e interpretar os resultados.

Como síntese do conhecimento obtido durante a pesquisa, esta tese está estruturada da seguinte forma: a fundamentação teórica é apresentada nos Capítulo 2, Capítulo 3 e Capítulo 4, com conteúdo sobre: i) sistemas, modelos e simulações, ii) complexidade de sistemas e iii) análise de sensibilidade, respectivamente. A metodologia proposta é abordada no Capítulo 5, compreendendo as métricas de análise de sensibilidade e sua integração à métrica de complexidade de sistemas. Os resultados são expostos no Capítulo 6, em que são utilizados diferentes sistemas para análises de complexidade. A conclusão é apresentada no Capítulo 7 por meio da síntese de toda pesquisa e da observação de desdobramentos ou lacunas que poderão ser investigadas em trabalhos futuros.

CAPÍTULO 2

SISTEMAS, MODELOS E SIMULAÇÕES

Este capítulo traz fundamentos sobre sistemas e suas representações por meio de modelos utilizados em simulações. Inicialmente conceituam-se sistema e modelo, além de contextualizar o tema como área de estudos da Ciência de Sistemas. Esta área investiga propriedades comuns aos sistemas, as quais são apresentadas neste capítulo. Em seguida, foca-se no estudo de sistemas complexos, nos comportamentos que lhes são particulares e em suas subclasses. Por fim, são apresentados os processos e técnicas de modelagem e simulação.

2.1 Conceito de sistema e modelo

Sistema é o conjunto de elementos em interação (BERTALANFFY, 1969). Constitui entidade organizada como todo que tem conexões com outras entidades e existe em algum meio ambiente (MOBUS; KALTON, 2015). De acordo com Maier (1996), sistema é a coleção de componentes que produz comportamento ou função que não poderia ser obtida por qualquer componente individualmente.

De acordo com Mobus e Kalton (2015), sistemas podem ser classificados em três domínios: i) sistemas no mundo, ii) sistemas na mente e iii) sistemas no abstrato. Estes domínios referem-se a aspectos ontológicos, epistemológicos e matemático/simbólico, respectivamente. Os sistemas que constituem a realidade somente são abstraídos matemática e simbolicamente após representação mental, como ilustrado na Figura 2.1, adaptada de Mobus e Kalton (2015).

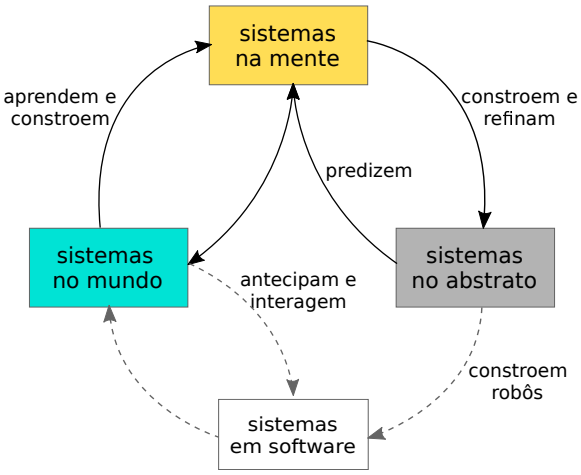

Figura 2.1 - Domínios de sistemas.

As representações mentais e abstratas dos sistemas são conhecidas como **modelos**. Para Tarantola et al. (2007), a criação de modelos como mapas úteis do mundo constitui processo de simplificação, separação e identificação. Para os autores, este processo é incerto. Mesmo que o modelo seja extensivamente corroborado, resistindo a testes formais, de consistência interna ou relativos à capacidade de explicar ou prever o mundo, ele não pode ser validado como representação exata do sistema, uma vez que constitui abstração da realidade.

Um mesmo modelista pode representar determinado sistema por diferentes modelos, dependendo do nível de abstração aplicado a ele ou de seleção das partes de interesse. As partes geralmente constituem subsistemas, com conjunto próprio de elementos, fronteira e relações. Independente do nível de hierarquia em questão, os sistemas exibem padrões e comportamentos comuns que são estudados pela ciência de sistemas.

2.2 Ciência de sistemas

Diante da importância do termo **sistema**, amplamente usado, foi criado um campo de investigação científica cujo objeto de estudo é sistemas, conhecido como **Ciência de Sistemas** (KLIR, 2013). Este campo busca o entendimento de sistemas como tal, apontando continuidades entre as diferenças (linear, não-linear, fechado, aberto, complexo) ao invés de segregar os sistemas em grupos como ocorre habitualmente (MOBUS; KALTON, 2015).

Dentro da Ciência, Hieronymi (2013) classifica a ciência de sistemas como ciência formal, devido às concepções matemáticas sobre sistemas. No entanto, as suas expressões (sistemas físicos, biológicos, cognitivos e outros) são enquadradas nas ciências fenomenológicas ou factuais e relacionam-se a algumas disciplinas diretamente, como ilustrado na Figura 2.2, adaptada de Hieronymi (2013). Enquanto a ciência de sistemas compreende a teoria sobre sistemas, incluindo definições matemáticas, o campo **projeto de sistemas** abrange métodos gerais e práticas relevantes para aplicação (em sistemas criados por humanos) e por isto encontra-se classificado como ciência normativa (HIERONYMI, 2013).

Por meio da investigação de atributos gerais, dinâmica, características e comportamento de sistemas, a Ciência de Sistemas propõe princípios que regem todos os sistemas. Dentre os princípios, Mobus e Kalton (2015) apresenta o termo *systemness*, utilizado também na área de Sociologia e traduzido como **sistemidade**. Para os autores, sistemidade é a propriedade recursiva em que o sistema pode, ao mesmo

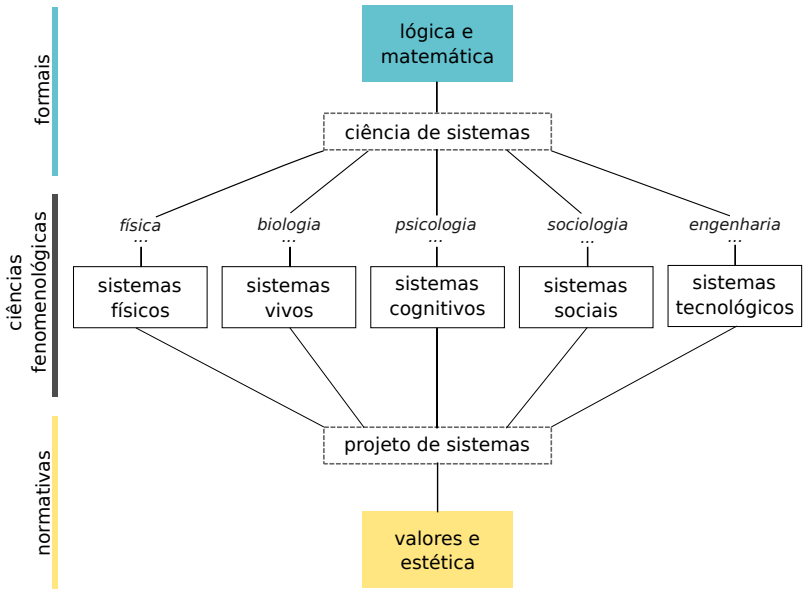

Figura 2.2 - Classificação das ciências e dos sistemas.

tempo, abranger sistemas menores e ser abrangido por sistemas maiores, no entanto cada sistema em si possui sua totalidade.

Os princípios da Ciência de Sistemas afirmam que sistemas: i) possuem sistemidade, ii) são processos organizados em hierarquias estruturais e funcionais, iii) podem ser representados como redes de relações entre componentes, iv) são dinâmicos em várias escalas de tempo, v) **exibem vários tipos e níveis de complexidade**, vi) evoluem, vii) codificam conhecimento e compartilham informação, viii) possuem subsistemas de regulação para alcançar estabilidade, ix) contêm modelos de outros sistemas, x) se adaptativos, podem conter modelos de si mesmos, xi) podem ser entendidos (Ciência) e xii) podem ser melhorados (Engenharia) (MOBUS; KALTON, 2015).

Com base nestes princípios, tem-se desenvolvido subáreas de estudo dentro da ciência de sistemas, como termodinâmica clássica, teoria de sistemas abertos, teoria da informação, cibernética, teoria da autopoiese (produzir a si próprios), teoria do caos, modelagem multi-agente e conceito de agentes autônomos, teoria da complexidade e ciência de rede (HIERONYMI, 2013). Contudo, embora existam especificidades, os sistemas exibem propriedades comuns, relativas à sua composição e organização formando um todo.

2.3 Propriedades de sistemas

Tendo em vista que o sistema pode abranger ou ser abrangido por sistemas particulares, o que faz dele sistema em si é a união de propriedades básicas. De forma geral, os sistemas possuem estrutura limitada e organizada para estabelecer relações internas e externas. Estas propriedades são, segundo Mobus e Kalton (2015), universais e compreendem: totalidade, composição, organização interna e organização externa.

2.3.1 Totalidade

Totalidade significa coesão interna entre elementos limitados por fronteira, que pode ser concreta, porosa, difusa ou conceitual. Para determinar o que entra e sai do sistema, existem as condições de fronteira, que são responsáveis pela troca controlada de material, energia e mensagens com outros sistemas (MOBUS; KALTON, 2015). Qualquer sistema visto como entidade deve ter fronteiras, que são, em última análise, dinâmicas (BERTALANFFY, 1969). Devido à lei de recursão (ou princípio de sistemidade), os sistemas sobrepõem-se e são aninhados ao ponto de compor o universo como totalidade unificada, em que os seres interagem com outros seres pertencentes ao mesmo nível ontológico ou ao mesmo nível de recursão (WILSON, 2015).

2.3.2 Composição

A **composição** refere-se aos elementos e interações que formam os sistemas. Os elementos, ou componentes, são geralmente subsistemas vistos como entidades com potenciais interações expressas por suas condições de fronteira, podendo ser tratadas como caixas pretas (estrutura interna desconhecida). Cada tipo de componente possui singularidade própria, denominada personalidade, a qual expressa sua capacidade específica de interagir com outros tipos de componentes. Assim quanto maior a heterogeneidade de componentes do sistema, maior a complexidade de sua estrutura interna e função. Além disto, o mesmo componente pode ter múltiplas finalidades em tempos diferentes, permitindo a sobreposição de função como mecanismo de segurança para funções críticas (MOBUS; KALTON, 2015).

2.3.3 Organização interna

A **organização interna** dos sistemas diz respeito à forma como a estrutura desempenha funções ou processos. Enquanto a estrutura está relacionada a padrões que persistem ao longo do tempo, a organização refere-se à dinâmica estabelecida

internamente. Nos sistemas, os elementos são organizados por meio de padrões de conexões ou redes, representadas por vértices (elementos) e arestas (conexões). Assim, a conexão que une dois elementos possui força de acoplamento[1] particular, determinada pelo impacto que a mudança em um dos componentes provoca no outro (MOBUS; KALTON, 2015; NEWMAN, 2010).

De acordo com Bunge (2003), os componentes podem unir-se de várias maneiras, tais como: associação, justaposição, concatenação, agrupamento ou acréscimo. Dentre as formas citadas, a associação é a mais comum no que tange à geração de novidade de tipo combinatório e assume papel fundamental na maioria dos sistemas complexos. Além da conectividade entre elementos, a organização interna baseia-se em hierarquia, visto que os componentes podem ser subsistemas, que por sua vez, podem ser formados por subsistemas e assim sucessivamente até que cesse o particionamento e sejam definidos quais subsistemas são elementares (SIMON, 1962). Somado a estas características ou como consequência delas, ainda verifica-se a complexidade manifestada nos sistemas de diversas formas e níveis.

2.3.4 Organização externa

Os sistemas interagem de múltiplas formas, estabelecendo contatos ascendentes, descendentes, laterais e externos com sistemas semelhantes ou diferentes que pertencem à mesma totalidade unificada ou não (WILSON, 2015). Quando o sistema é visto como totalidade dentro do sistema maior, algumas características dele tornam-se parâmetros de entrada ou de saída na relação **sistema-ambiente**, mediada pelas condições de fronteira. No fluxo de vida do sistema, o ambiente é responsável por prover alimento (entrada) e receber descartes (saída). Alimento refere-se a tudo o que é necessário para o funcionamento do sistema (matéria, energia ou informação) e descartes são os resultados do alimento processado. Assim os fluxos ambientais contribuem para o entendimento do comportamento dos sistemas ao mesmo tempo que refletem sua organização interna (MOBUS; KALTON, 2015).

2.4 Sistemas complexos

Sistemas complexos são coleções de entidades diversas, conectadas e interdependentes, cujo comportamento é determinado por regras que podem ou não se adaptar (PAGE, 2010). Como área da Ciência, sistemas complexos abordam: i) como as relações internas resultam em comportamentos coletivos e ii) como as relações externas são formadas (BAR-YAM, 2002). Os comportamentos e os tipos de sistemas com-

[1] Conexão entre quaisquer dois componentes do sistema.

plexos, classificados em físicos e adaptativos, possuem características que ajudam a distinguí-los de outros tipos de sistemas.

A partir de regras simples de funcionamento, os sistemas podem exibir complexos comportamentos coletivos, processamento sofisticado de informações e adaptação via aprendizagem ou evolução (MITCHELL, 2009). Estas características referem-se a sistemas complexos, os quais, segundo Holland (2014), apresentam: auto-organização em padrões, comportamento caótico, comportamento cauda-gorda, interação adaptativa e comportamento emergente.

A **auto-organização em padrões** corresponde à capacidade dos sistemas de definir por si mesmos padrões de comportamento. No entanto, os sistemas tendem a evoluir para a forma de prontidão ou estado crítico auto-organizado, ficando na iminência de sair do equilíbrio. Neste estado, pequenas pertubações podem levar a eventos de elevada magnitude, devido ao seu **comportamento caótico** (WALDROP, 1993; BAK, 1996). Além disto, em sistemas complexos, eventos raros ocorrem com mais frequência do que seria previsto por distribuição normal, o que explica o termo **comportamento cauda-gorda**. Outro comportamento comum nestes sistemas é a **interação adaptativa**, em que agentes modificam suas estratégias em diversos caminhos à medida que a experiência se acumula (HOLLAND, 2014).

A sincronia dos pássaros voando em bando ou dos peixes nadando em cardumes são exemplos de sistemas com auto-organização em padrões. Quanto ao comportamento caótico, o exemplo usual é o bater de asas de uma borboleta na Argentina contribuir para ocorrência de furacão no Caribe. Extinções em massa e falências no mercado referem-se ao comportamento cauda-gorda. No mercado financeiro, verifica-se a interação adaptativa, pois as estratégias de ação são diversificadas dada a experiência. Em todas as situações citadas, verifica-se ainda o **comportamento emergente**, visto que o conjunto apresenta propriedades não alcançadas pela soma das partes, o que corresponde a interações não-lineares (HOLLAND, 2014).

Bar-Yam (1997a) explica que o **comportamento coletivo complexo** resulta do comportamento correlacionado das partes, que atuam de forma especializada e coordenada. O autor classifica os comportamentos individuais em aleatórios, coerentes e correlacionados, os quais podem ser observados em sistemas físicos, biológicos e sociais, como ilustrado na Figura 2.3, adaptada de Bar-Yam (1997a). Quando os comportamentos individuais são aleatórios ou coerentes, o comportamento coletivo do sistema é simples, no entanto quando são correlacionados, o comportamento coletivo é complexo, combinando regularidade com aleatoriedade.

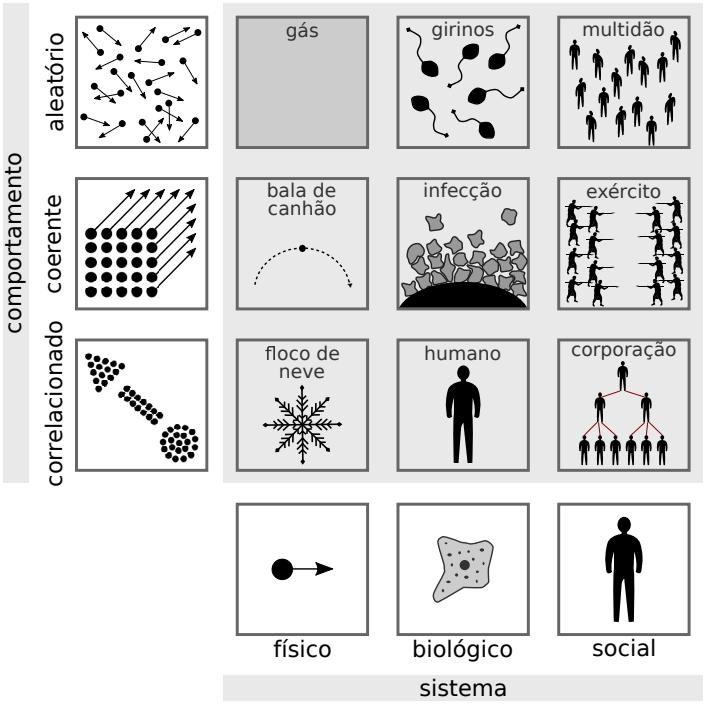

Figura 2.3 - Exemplos de comportamentos individuais nos sistemas.

Para Waldrop (1993), os sistemas complexos adquiriram, de alguma forma, a capacidade de gerar ordem e caos num tipo especial de equilíbrio, obtido pela combinação de qualidades como espontaneidade, auto-organização, adaptação e atividade. Dentre os sistemas complexos, existem aqueles com elementos e leis fixas, chamados de sistemas complexos físicos, e aqueles que estão em constante mudança, chamados de sistemas complexos adaptativos.

Nos **sistemas complexos físicos**, somente as posições dos elementos mudam com o tempo. Estes sistemas são caracterizados por auto-similaridade, escalonamento, estrutura em rede e dinâmica. **Auto-similaridade** pode ser observada na maioria dos sistemas naturais por meio de curvas fractais, construídas pela repetição da mesma forma geométrica de modo contínuo e regular.

Combinada à auto-similaridade, tem-se o **escalonamento** obtido por leis de potência, caracterizadas pela relação exponencial entre os elementos e a frequência em que são usados. Além disto, a forma como os elementos são arranjados constituem estrutura do sistema em **rede**, que pode ser regular, como nos fractais, ou irregular, onde alguns elementos possuem mais conexões que outros, formando agrupamentos. Outra característica de sistemas físicos complexos é a **dinâmica** representada por estados, em que é possível prever estados futuros a partir dos atuais (HOLLAND,

2014).

Sistemas complexos adaptativos são compostos de elementos, chamados **agentes**, que aprendem ou adaptam-se em resposta a interações com outros agentes, exibindo variação aleatória e seleção (HOLLAND, 2014; GELL-MANN, 1988). Para Zadeh (1963), todos os sistemas são adaptativos, a questão real é para quê e em que medida eles são adaptativos. A diferença principal entre sistemas complexos físicos e adaptativos reside em como o processo de adaptação exerce influência sobre tais sistemas. Enquanto, nos sistemas físicos, há mudança de estados, nos sistemas adaptativos, a mudança ocorre em toda rede de interações (HOLLAND, 2014).

De acordo com Holland (2006), as principais características de sistemas complexos adaptativos são: i) paralelismo, ii) ação condicional, iii) modularidade e iv) adaptação e evolução. O **paralelismo** refere-se às interações simultâneas entre os diversos agentes, produzindo elevado número de sinais. Por **ação condicional**, entende-se como a dependência do recebimento de pelo menos um sinal para que determinada ação seja executada. Cada agente possui ainda mecanismos de reação a diversas situações, quando executam conjunto específico de regras, definido por sua **modularidade**. Assim, considerando sua experiência com o ambiente e seus processos internos, os agentes estão em constante mudança devido à necessidade de **adaptação e evolução**.

Todas estas características (paralelismo, ação condicional, modularidade, adaptação e evolução) podem ser implementadas computacionalmente por modelos que simulam a dinâmica dos sistemas. Assim os sistemas complexos podem ser observados e manipulados a partir de seus modelos, uma vez que existem softwares robustos de modelagem e simulação, bem como hardwares de alto desempenho.

2.5 Modelagem e simulação

Investigações sobre o comportamento dos sistemas baseiam-se em observação ou, mais especificamente, em experimentos. Nos dois casos, é comum o uso de modelos que abstraem aspectos essenciais da organização dos sistemas e de sua relação com ambiente. De posse do modelo, pode-se simular o funcionamento do sistema de interesse em situações comuns ou raras, manipulando variáveis e verificando as implicações geradas. Desta forma, é possível conhecer o comportamento dos sistemas sob condições específicas, levando à solução de problemas cujas causas eram desconhecidas ou mal compreendidas até então (CHWIF; MEDINA, 2015; WAINER, 2009; TARANTOLA et al., 2007).

Os sistemas, naturais ou artificiais, são governados por regras que dirigem seus comportamentos. A **modelagem** consiste, portanto, no processo de representar tais regras por meio de conjunto de estruturas, chamado modelo (TARANTOLA et al., 2007). Para Chwif e Medina (2015), o **modelo** é a representação simplificada das diversas interações entre as partes do sistema, que captura apenas o que realmente é importante no sistema para a finalidade em questão.

O modelo pode estar associado a experimentos e ser implementado como programa de computador, também chamado de modelo de simulação ou **simulador**. A acurácia do simulador é verificada por meio de testes, em que se avalia se o comportamento do simulador condiz com a especificação do modelo para maior quantidade de casos possíveis. De forma análoga, valida-se o modelo comparando os resultados obtidos do simulador com os resultados gerados pelo sistema real. Assim, a precisão do simulador e do modelo pode ser devidamente avaliada por meio de técnicas de **verificação** e **validação**, respectivamente (WAINER, 2009).

De acordo com Wainer (2009), os seguintes passos compreendem o processo de modelagem e simulação: i) formulação do problema, ii) criação do modelo conceitual, iii) obtenção e análise de dados de entrada e saída, iv) modelagem, v) simulação, vi) verificação e validação, vii) experimentação e viii) análise das saídas. A **formulação do problema** refere-se à contextualização do sistema de interesse, identificando o quadro experimental e as variáveis de entrada e saída, além de definir o conjunto de métricas de desempenho e a função objetivo quando o problema envolver análise de desempenho. O **quadro experimental** compreende as condições experimentais, os valores dos parâmetros e os mecanismos de geração de comportamento.

Após o problema ter sido formulado, cria-se o **modelo conceitual**, que consiste na descrição da estrutura e comportamento do sistema, identificando todos os elementos com seus atributos e interfaces. Nesta fase, também são definidas as variáveis de estado, características críticas e informação não funcional. Na fase seguinte, de **obtenção e análise de dados de entrada e de saída**, o tamanho da amostra de dados e tipo dos atributos (estocásticos ou determinísticos) são definidos antes de obter e analisar os dados. No entanto, quando não existe fonte de dados, pode-se utilizar sistemas similares para obter os conjuntos de dados ou usar abordagem estocástica para gerá-los. Assim, estes dados, o quadro experimental e o modelo conceitual servem de base para **modelagem**, processo de desenvolvimento de representação detalhada do sistema (WAINER, 2009).

A fase seguinte refere-se à **simulação**, em que o modelo é implementado e tem-se

o simulador, somado ao modelo do quadro experimental. Após realizar a **verificação** do simulador e **validação** do modelo, o processo de **experimentação** pode ser iniciado com o planejamento dos experimentos, usando técnicas como: análise de sensibilidade, otimização, redução de variância, classificação e seleção. Nesta fase, o objetivo é executar o simulador quantas vezes forem necessárias para proceder à experimentação. Concluída esta fase, procede-se à **análise da saída**, ou seja, compreensão de como os valores de saída podem fornecer respostas sobre o comportamento do sistema original (WAINER, 2009).

Durante a experimentação, **métodos de otimização** podem ser aplicados na resolução de problemas no contexto de sistemas. Tais métodos podem ser associados a classes de sistemas (simples, complicado, complexo e caótico) expressas pela matriz de Stacey (2007) na Figura 2.4, adaptada de Paiva (2016). Verifica-se que os sistemas complexos podem ser otimizados por métodos heurísticos, inferenciais e estocásticos, pois encontram-se nas regiões em que predomina o desacordo (sobre o sistema em si e as formas de descrevê-lo) e a incerteza (em sua dinâmica). Esta incerteza também diz respeito às variações nos parâmetros devido às alterações nas condições ambientais. Os efeitos na saída do sistema causados por estas variações são mensurados pela análise de sensibilidade.

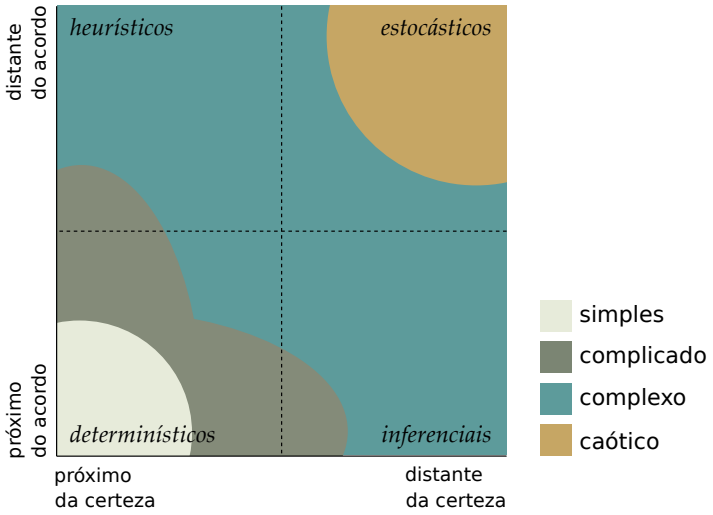

Figura 2.4 - Matriz de Stacey e sua relação com métodos de apoio a decisão.

A **complexidade dos sistemas**, portanto, está associado à natureza dinâmica e aleatória dos mesmos, ou seja, à mudança de estado ao longo do tempo ou adaptação do próprio sistema, além da presença de variáveis aleatórias em sua concepção. Assim

o modelo de simulação é capaz de reproduzir estas características à medida que expressa comportamento compatível com o do sistema original quando submetido às mesmas condições de fronteira (HOLLAND, 2014; CHWIF; MEDINA, 2015; MOBUS; KALTON, 2015).

Segundo Chwif e Medina (2015), os **modelos de simulação** podem ser classificados computacionalmente em três categorias básicas: simulação de Monte Carlo, simulação contínua e simulação de eventos discretos. A simulação de Monte Carlo baseia-se na geração de números aleatórios para os valores de variáveis, porém o tempo não é considerado explicitamente como variável. Ao passo que em simulação contínua e de eventos discretos, existem variáveis contínuas e discretas, respectivamente, que são observadas ao longo do tempo.

As diferentes técnicas de **modelagem e simulação discreta ou contínua** são categorizadas de acordo com as representações de variáveis de estado e tempo no modelo. Quando a base é o tempo, as técnicas consideram que o tempo evolui continuamente (tempo contínuo) ou por porções discretas (tempo discreto). Quanto aos valores de variáveis de estados, as variáveis podem ser representadas por conjunto contínuo de valores (variáveis contínuas) ou por conjunto finito de valores (variáveis discretas), dependendo do modelo. A Tabela 2.1, adaptada de Wainer (2009), dispõe graficamente estes casos.

Existem técnicas de modelagem apropriadas para cada classificação da Tabela 2.1. As técnicas comumente utilizadas são: para os casos da Tabela 2.1(a) equações diferenciais parciais ou ordinárias, grafos de ligação e diagramas de circuitos elétricos, para os casos da Tabela 2.1(b) equações de diferença, método de elementos finitos, diferenças finitas e métodos numéricos, para os casos da Tabela 2.1(c) utilizam-se formalismos de sistemas de eventos discretos, redes de Petri temporizadas, máquinas de estados finitos temporizados, grafos de eventos e para os casos da Tabela 2.1(d) usam-se máquinas de estado finito, autômato de estado finito, redes de Petri, lógica booleana e cadeias de Markov (WAINER, 2009).

Nos sistemas, quando existem variáveis discretas, a transição de estado é conduzida por eventos. No modelo de tais sistemas, as variáveis discretas representam os estados e são definidas em domínios qualitativos (SAYED-MOUCHAWEH, 2014). **Sistemas de eventos discretos** com base de tempo contínuo são dinâmicos, concorrentes e altamente não lineares e, em geral, modelam criações do homem, como exemplo, têm-se controladores de tráfego, braços robóticos, fábricas automatizadas, fábricas de produção, redes de computadores entre outros. Para os casos em que o tempo

Tabela 2.1 - Classificação de modelos de acordo com as bases de tempo e variáveis de estado.

Variável/Tempo	Tempo Contínuo	Tempo Discreto
Variável Contínua	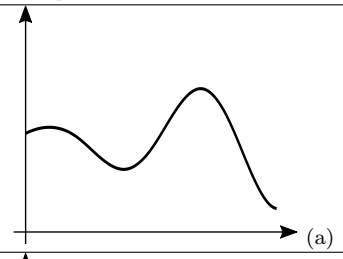 (a)	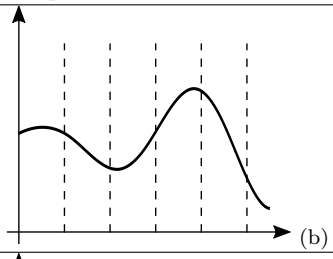 (b)
Variável Discreta	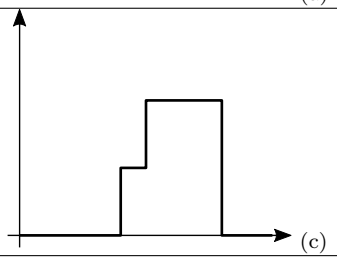 (c)	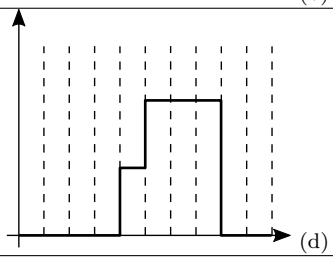 (d)

também é discreto, os eventos ocorrem em tempo fixo (WAINER, 2009).

O tempo pode ainda ser variável implícita na simulação através de séries temporais, por exemplo, aplicadas em **métodos de Monte Carlo**. Este tipo de simulação independe da evolução do sistema no tempo, pois avalia as saídas do sistema para diferentes conjuntos de entradas gerados aleatoriamente de acordo com distribuições probabilísticas que representam as variáveis em questão. Segundo Graham e Talay (2013), modelos probabilísticos são utilizados em situações críticas, em que modelos determinísticos são ineficientes, como na simulação de sistemas físicos com elevado número de graus de liberdade, dinâmicas complexas e escalas de tempo particulares. Por esta razão, simulação de Monte Carlo tem sido igualmente aplicada a sistemas físicos, assim como a modelos matemáticos e financeiros.

2.6 Considerações finais

Sistemas são objetos de estudos em diversas áreas das ciências fenomenológicas, como física, biologia, sociologia, psicologia e engenharias. Entretanto, a área que investiga os sistemas em si, denominada Ciência de Sistemas, é classificada como ciência formal, devido às concepções matemáticas sobre o tema. Este campo científico aponta propriedades comuns a todos os sistemas, embora existam características específicas de algumas classes, como no caso dos sistemas complexos. Para compreender o comportamento das classes, modelagem e simulação são frequentemente empregados como ferramentas para manipular variáveis sem afetar o sistema original. De forma geral, mesmo que o sistema não seja classificado como complexo, a

Ciência de Sistemas afirma a existência de algum nível e tipo de complexidade dos sistemas, assunto aprofundado no próximo capítulo.

CAPÍTULO 3

COMPLEXIDADE DE SISTEMAS

Este capítulo apresenta a complexidade de sistemas por meio de seu conceito, histórico, características e métricas. As investigações realizadas sobre o tema oferecem base teórica para afirmação de que os sistemas exibem tipos e níveis de complexidade. Somado a isto, formas de medir a complexidade têm sido desenvolvidas a fim de realizar comparações e acompanhar o funcionamento dos sistemas.

3.1 Conceito de complexidade de sistemas

A **complexidade de sistemas** consiste na presença de diversas partes interconectadas que seguem regras e frequentemente adaptam-se por meio das regras, aprendizagem ou seleção natural (HOLLAND, 2014; PAGE, 2010; MITCHELL, 2009). Regras ou leis que regem os sistemas, mesmo sendo simples, podem produzir estruturas e comportamentos complexos. A esta característica, Holland (2014) dá o nome de **novidade perpétua** e afirma que ela está presente na maioria dos sistemas complexos. O autor cita o exemplo do DNA, que consiste de códigos formados por combinações de apenas quatro nucleotídeos, porém nunca existiu dois humanos exatamente iguais.

Comumente o tema complexidade de sistemas é abordado como: i) qualidade do que é complexo e ii) campo científico com diversas ramificações (HOLLAND, 2014; MAINZER; CHUA, 2011; MITCHELL, 2009; BAK, 1996; SIMON, 1962). Como qualidade do que é complexo, as seguintes características destacam-se: não linearidade, emergência, auto-organização, diversidade, interdependência e evolução. No que se refere ao campo científico, o histórico do tema abarca vários estudos publicados.

3.2 Histórico

Em 1945, Ludwig von Bertalanffy, um dos fundadores da Teoria Geral dos Sistemas, apontou limitações dos procedimentos analíticos na ciência moderna. O método proposto por Descartes concebia a investigação acerca de qualquer objeto por meio da redução do todo às suas partes constituintes para análise e posterior agregação destas partes, buscando a síntese a respeito do objeto investigado. Esta abordagem ficou conhecida como reducionismo clássico ou mecanicismo (PRADO, 2009).

Em seu livro *General system theory: foundations, development, applications*, pág. 19, Bertalanffy (1969) afirma (tradução da autora):

> A aplicação do procedimento analítico depende de duas condições. A primeira é que as interações entre "partes" sejam inexistentes ou suficientemente fracas para serem negligenciadas em certos propósitos de pesquisa. Somente sob esta condição, as partes podem ser "trabalhadas", na realidade, logicamente e matematicamente, e depois ser "colocadas juntas". A segunda condição é que as relações que descrevem o comportamento das partes sejam lineares; somente então é obtida a condição da somatividade, isto é, uma equação que descreve o comportamento do total é da mesma forma que as equações que descrevem o comportamento das partes; processos parciais podem ser sobrepostos para obter o processo total, etc. Essas condições não são cumpridas nas entidades chamadas sistemas, isto é, constituídas por partes "em interação" (BERTALANFFY, 1969).

Em consonância com os estudos de Bertalanffy, Warren Weaver publica na revista *American Scientist*, em 1948, o artigo *Science and Complexity*, no qual categoriza os problemas abordados pela ciência em: i) de simplicidade, ii) de complexidade organizada e iii) de complexidade desorganizada. Estas categorias seguem a gradação do número de variáveis: de poucas a numerosas. A posição intermediária, com quantidade moderada de variáveis, refere-se a problemas de complexidade organizada, cuja característica principal é apresentar a essência da organização. Estes problemas, ao contrário dos de complexidade desorganizada, não podem ser manipulados com técnicas estatísticas (WEAVER, 1948).

Em 1962, Herbert A. Simon, professor do *Carnegie Institute of Technology*, publica o artigo *The Architecture of Complexity*, afirmando que a complexidade frequentemente toma a forma de hierarquia, devido à composição dos sistemas por subsistemas que, por sua vez, possuem seus próprios subsistemas e, assim, sucessivamente. O autor explica que sistemas hierárquicos possuem algumas propriedades comuns que são independentes do conteúdo específico de cada um deles. E que estes sistemas evoluem mais rapidamente que sistemas não-hierárquicos de tamanho similar (SIMON, 1962).

Em contraposição ao estudo de complexidade, surgem questionamentos acerca da simplicidade ou do limiar existente entre as duas qualidades. Murray Gell-Mann, em 1988, afirma em seu texto *Simplicity and Complexity in the Description of Nature*, que simplicidade e complexidade exibem maravilhosa interação no universo, coexistindo em cadeias de DNA, nas formas de nuvem, nos movimentos individuais dos pássaros em bando e na aparência dos cristais nas rochas. Este autor argumenta que definir complexidade requer especificar o nível de detalhe desejado, ignorando todo o resto (GELL-MANN, 1988).

Como resultado das discussões sobre o tema, M. Mitchell Waldrop publica, em 1993,

o livro *Complexity: The Emerging Science at the Edge of Order and Chaos*. Waldrop (1993) apresenta a ciência da complexidade como campo ainda indefinido, até mesmo no que se refere aos seus limites, o que é justificado pelo fato de lidar com questões que desafiam todas as categorias convencionais.

Em 1996, Per Bak afirma em seu livro *How Nature Works: The Science of Self-Organized Criticality* que a questão da origem da complexidade com base em leis simples da física surge como ciência ativa a partir das investigações propiciadas pelo processamento computacional. No entanto, Bak (1996) considera que a ciência da complexidade está envolta por expressivo ceticismo, uma vez que ainda persiste a dúvida sobre como qualquer resultado geral pode ser útil, pois cada ciência funciona bem dentro de seu próprio domínio.

No ano seguinte, 1997, Yaneer Bar-Yam, do *New England Complex Systems Institute*, em Cambridge, discorre sobre a progressão histórica da complexidade em seu texto *Complexity Rising: From Human Beings to Human Civilization, a Complexity Profile*. De hierarquias simples com poucos sujeitos a estruturas complexas em rede, a humanidade tem passado por períodos de mudanças radicais em sua organização, como as revoluções neolítica, industrial e da informação. Em decorrência destas mudanças, as formas de exercer controle nos grupos também mudam, como ilustrado na Figura 3.1 (sem escala), adaptada de Bar-Yam (1997a). No controle hierárquico, o comportamento individual do líder é reproduzido em escala ampliada ao passo que, no controle distribuído, as decisões são descentralizadas e realizadas por equipes que interagem entre si (BAR-YAM, 1997a).

A organização da civilização em rede torna-se mais evidente a partir da crescente conexão do mundo em termos econômicos, políticos e sociais. Page (2010) afirma que quando as interações eram poucas e distantes, os sistemas resultantes eram mais episódicos do que complexos. O autor discorre em seu livro *Diversity and Complexity* que a complexidade depende particularmente da quantidade de diversidade, pois ao mesmo tempo que favorece produtividade, robustez, conhecimento coletivo e maior diversidade, pode contribuir para o colapso, conflito e incompreensíveis mutilações.

Estudos sobre diversidade e especialização também foram publicados por John H. Holland. Em 2014, este autor sintetiza seus estudos sobre complexidade no livro *Complexity: A Very Short Introduction*, no qual classifica os sistemas complexos em físicos e adaptativos. De forma geral, o comportamento de sistemas complexos é caracterizado por auto-organização em padrões, sensibilidade a pequenas variações nos parâmetros, ocorrência de eventos raros e interação adaptativa, em que agentes

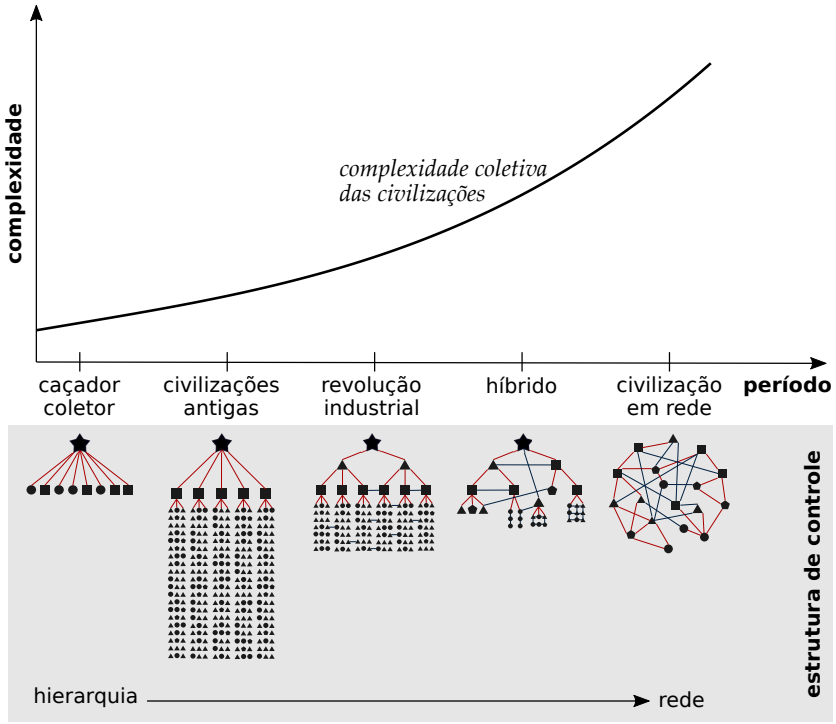

Figura 3.1 - Progressão histórica da complexidade da humanidade e as respectivas estruturas de controle.

aprendem e modificam suas estratégias (HOLLAND, 2014). Neste sentido, existem características que podem ser comuns a alguns ou a todos os tipos de sistemas complexos.

3.3 Características

A complexidade dos sistemas tem sido definida por meio da associação de certas características como: não linearidade, emergência, interdependência, auto-organização, diversidade, conectividade, evolução, entre outras. Assim, no contexto de sistemas, investigar se estas características são percebidas e em que grau é a forma mais comum de oferecer subsídios para determinação do nível de complexidade do objeto em estudo.

3.3.1 Não linearidade

Não linearidade refere-se à ausência da propriedade de sobreposição, uma vez que somente relações lineares são representadas por processos parciais que podem ser sobrepostos para obter o processo total, como afirma Bertalanffy (1969). Existem diversas classes de sistemas não lineares, por isto os autores tendem a focar naquelas que podem ser bem definidas, embora sejam limitadas (BILLINGS, 2013).

Matematicamente, o sistema não linear possui comportamento que não pode ser expresso como função linear de seus descritores. Logo, não satisfaz a propriedade ou princípio de sobreposição, constituído por: i) aditividade, em que a resposta (saída) causada por dois ou mais sinais é igual à soma das respostas causadas por cada sinal individualmente e ii) homogeneidade, que corresponde à relação de proporcionalidade entre entrada e saída.

Segundo Savi (2006), as não linearidades podem ser geométricas, se associadas ao movimento, ou físicas, quando referem-se ao comportamento. Para o autor, ao abordar problemas não-lineares de forma qualitativa, busca-se compreender o comportamento global do sistema. Por outro lado, a abordagem quantitativa analisa a evolução do sistema no tempo. Assim as duas abordagem atuam de forma complementar.

3.3.2 Emergência

Emergência é a característica dos sistemas nos quais comportamentos complexos surgem de regras de interação simples (WATKINS; FREEMAN, 2008). Para Holland (2014), a emergência ocorre quando os geradores do sistema combinam-se para produzir objetos com propriedades não obtidas pela soma das propriedades dos geradores individuais. Este termo **geradores** foi extraído do formalismo da gramática universal, proposto por Noam Chomsky. Holland (2014) utiliza o termo para se referir às mínimas unidades com significado necessárias para formar o todo.

Bar-Yam (1997b) aborda emergência como a relação entre os detalhes e a visão de amplo alcance. Ele classifica o tema em: emergência local, em que o comportamento coletivo aparece em pequena parte do sistema e emergência global, em que o comportamento coletivo pertence ao sistema como todo. A emergência global é, segundo o autor, particularmente relevante para o estudo de sistemas complexos (BAR-YAM, 1997b).

A emergência pode ainda ser caracterizada como forte ou fraca. Segundo Chalmers (2006), quando o fenômeno de alto nível surge do domínio de baixo nível, ele pode ser: i) fortemente emergente, uma vez que os fatos relativos a este fenômeno não são deduzíveis, mesmo em princípio, dos fatos no domínio de baixo nível ou ii) fracamente emergente, uma vez que os fatos relativos a este fenômeno são inesperados embora sejam deduzíveis, dados os princípios que regem o domínio de baixo nível. Comumente, discussões filosóficas tratam da emergência forte, enquanto que a emergência fraca torna-se escopo de investigações científicas recentes, inclusive na teoria de sistemas complexos (CHALMERS, 2006).

Bak (1996) considera que os cientistas referem-se aos fenômenos complexos como emergentes quando não são capazes de explicar a causalidade existente entre mecanismos físicos e complexidade. O autor afirma que qualidade, de alguma forma, emerge da quantidade.

3.3.3 Auto-organização

As interações nos sistemas podem gerar padrões sem que haja intervenções externas. Este comportamento é conhecido como auto-organização, capacidade de certos sistemas em estabelecer topologias e regras próprias. Bak (1996) apresenta analogia do monte de areia para explicar esta característica, normalmente comum quando o tema **complexidade** é abordado:

> Considere o cenário de uma criança na praia pegando areia com a mão e soltando aos poucos no mesmo lugar até formar um monte. No início, o monte é plano e os grãos individuais permanecem perto de onde eles caem. (...) Como o processo continua, o monte torna-se mais íngreme e haverá pequenas camadas de areia. Com o passar do tempo, as camadas tornam-se maiores e maiores. Eventualmente, alguma das camadas de areia pode abranger todo ou a grande parte do monte. Neste ponto, o sistema está fora de equilíbrio e o seu comportamento não mais pode ser entendido em termos de grãos individuais. As avalanches formam uma dinâmica própria.

O autor conclui que o monte de areia é sistema complexo e chama este ponto em que as avalanches são formadas de **estado crítico auto-organizado**. Afirma ainda que a natureza opera neste estado observado em diversos fenômenos e que a criticalidade auto-organizada é o mecanismo responsável por gerar complexidade.

Para Gershenson e Fernández (2012), os sistemas auto-organizados possuem dinâmica interna capaz de produzir padrão global e aumentar sua própria organização com o tempo. Mesmo interações simples entre componentes dos sistemas podem gerar padrões extremamente sofisticados, de acordo com Camazine (2003), como os padrões espaciais de exército de formigas durante ataque ou os movimentos coordenados na escola de peixes[1]. Outros exemplos comuns são as ondulações causadas pelo vento na superfície de dunas de areia, a pigmentação da pele em peixes, zebras, girafas, entre outros.

[1]Escola de peixe: movimento coreografado dos peixes em cardume, que nadam como se fossem único indivíduo. Os peixes se unem devido ao fenômeno auto-organizado, onde milhares de movimentos individuais compõem o movimento maior.

3.3.4 Diversidade

Diversidade e complexidade são frequentemente entendidos como conceitos indissociáveis. Bak (1996) define sistemas complexos considerando seu nível de variabilidade, que é observado em ampla gama de escalas. Ele afirma que os seres humanos podem reconhecer uns aos outros porque são todos diferentes e ressalta que o cérebro pode ser considerado o sistema com maior nível de complexidade, uma vez que cria representações de outros sistemas complexos.

Um aspecto relevante observado pela presença de diversidade é a cooperação. Na sociedade, o comportamento cooperativo ocorre mais facilmente quando existe diversidade, situação que gera benefícios para o todo (SANTOS et al., 2012). As diferenças são necessárias para que haja complementaridade, propiciando que as partes contribuam de forma particular para formar o todo.

Neste sentido, Holland (2014) relaciona os conceitos de especialização e diversidade, afirmando que comunidades desempenham seu papel por meio da interação de especialistas. Ao considerar alguma atividade independente realizada por quantidade equivalente de generalistas, o autor conclui que o rendimento seria significativamente menor. Assim a especialização torna crescente o conjunto de possibilidades de interação que culmina em diversidade e maior rendimento, especialmente no contexto de sistemas adaptativos complexos.

De acordo com Page (2010), a diversidade é classificada em três categorias: i) dentro de um tipo, ii) através dos tipos e iii) entre comunidades ou sistemas. As variações realizadas dentro do mesmo parâmetro impulsionam a diversidade de tipos, criando sinergias. E quando observada entre sistemas, proporciona robustez a consideráveis mudanças. Na primeira categoria, é possível realizar busca local e responder a pequenas mudanças no ambiente. O autor apresenta medidas de diversidade para as três categorias: i) Categoria 1 - variação, ii) Categoria 2 - entropia, distância e atributo e iii) Categoria 3 - população.

3.3.5 Interdependência

Interdependência é a relação de influência existente entre as partes e o todo. Em outras palavras, caso uma parte seja removida do sistema, verifica-se como ela será afetada e como todo o sistema reagirá à ausência dela (BAR-YAM, 2002). Esta característica está relacionada à força do acoplamento entre as partes, que refere-se à quantidade de alteração efetuada em um componente como resultado de mudanças

em outro componente (MOBUS; KALTON, 2015).

Comumente, os sistemas estão organizados em rede, em que as partes conectam-se direta ou indiretamente às outras. As interações podem contribuir para que haja interdependência, no entanto Bar-Yam (1997b) salienta que mesmo interações fortes não implicam necessariamente em interdependência de comportamentos.

Segundo Page (2010), a complexidade dos sistemas é caracterizada pela presença de diversas entidades que seguem regras e apresentam comportamentos interdependentes. Desta forma, quanto mais complexo for o sistema, maior a importância de cada parte para o todo. Sistemas verdadeiramente complexos possuem comportamento coletivo que depende do comportamento de todas as suas partes, logo a ausência de apenas um elemento pode comprometer todo o sistema (BAR-YAM, 2002).

Para exemplificar, Bar-Yam (2002) considera a situação em que é removida parte de: um material, uma planta e um animal. No caso do material, como pedaço de metal ou líquido, tanto a parte sem o todo quanto o todo sem a parte mantêm suas propriedades inalteradas. Diferentemente da planta e do animal, em que a parte retirada perde sua vitalidade e os sistemas (planta e animal) podem também ser fortemente afetados.

3.3.6 Evolução

Evolução refere-se à capacidade dos sistemas de seguir trajetórias de desenvolvimento no espaço e no tempo, revelando-se como princípio que se aplica ao universo como todo, mesmo em escala subatômica (MOBUS; KALTON, 2015). Quanto aos organismos complexos, os processos evolucionários explicam sua formação por meio de mudanças incrementais determinadas pela propriedade de aptidão (BAR-YAM, 1997b).

Segundo Bak (1996), os sistemas na natureza tendem a evoluir para o **estado crítico**, de equilíbrio instável. A este estado, Waldrop (1993) chama de **fronteira do caos**, membrana infinitamente fina que separa a ordem do caos. Nesta região, o autor afirma que há infinidade de maneiras para os agentes serem complexos e adaptativos. O universo gera regiões de crescente organização e complexidade, mesmo enquanto a entropia aumenta para o todo (MOBUS; KALTON, 2015).

Como intersecção destas regiões, Holland (2014) argumenta a respeito de **coevolução**, em que nichos evoluem através de recombinação de blocos de construção, estruturas básicas em determinado contexto. Para o autor, os nichos são importante

parte da organização hierárquica de sistemas adaptativos complexos, uma vez que utilizam localmente sinais e recursos. A influência de uma espécie no processo evolutivo de outra pode resultar em organismos mais complexos, no entanto Mobus e Kalton (2015) questiona se o aumento em complexidade implica em algo melhor, de acordo com algum critério.

3.4 Métricas de complexidade de sistemas

As métricas de complexidade são instrumentos que permitem tratar a complexidade de forma quantitativa e, portanto, estabelecer comparações entre sistemas ou entre configurações diferentes do mesmo sistema (MITCHELL, 2009; REPPERGER et al., 2012). Lloyd (2001) categoriza cerca de 40 métricas de complexidade e enfatiza que as diversas formas de medir complexidade representam variações em alguns temas subjacentes, com várias formulações para cada tema, constituindo problema análogo ao de descrever eletromagnetismo antes das equações de Maxwell.

Algumas métricas, como entropia de Shannon ou complexidade algorítmica, quantificam a complexidade de acordo com o grau de aleatoriedade do sistema em estudo. Assim, quanto mais aleatória for a organização do sistema, maior será sua medida de complexidade (SHANNON, 1948; ZUREK, 1989; KURTHS et al., 1994). No entanto, a qualidade de ser complexo está no equilíbrio entre ordem e desordem, regularidade e aleatoriedade. Desta forma, a métrica de complexidade intuitivamente ideal trata distribuições completamente aleatórias e completamente ordenadas como minimamente complexas, ao passo que configurações intermediárias são tratadas como altamente complexas (KURTHS et al., 1994; DEACON; KOUTROUFINIS, 2014), como ilustrado na Figura 3.2, adaptada de Deacon e Koutroufinis (2014).

Na Figura 3.2, a curva adaptada de Deacon e Koutroufinis (2014) refere-se a medidas de complexidade obtidas pela métrica intuitivamente ideal a partir dos seguintes padrões de organização: do padrão completamente regular (à esquerda, p_1) ao completamente aleatório (à direita, p_3). O pico de complexidade da curva está relacionado ao padrão que combina regularidade e aleatoriedade (ao centro, p_2). Esta combinação pode ser percebida em diversos sistemas da natureza, como apresentado na Figura 3.3[2], ou mesmo nos sistemas criados pelo homem, independente da escala.

Embora com limitações conceituais e práticas, além da restrição quanto à abordagem e aplicação, métricas de complexidade têm sido desenvolvidas há quase um

[2]Direito autoral das fotografias reservado à autora e ao orientador. As imagens originais estão disponíveis em: https://www.flickr.com/photos/wpcalixto.

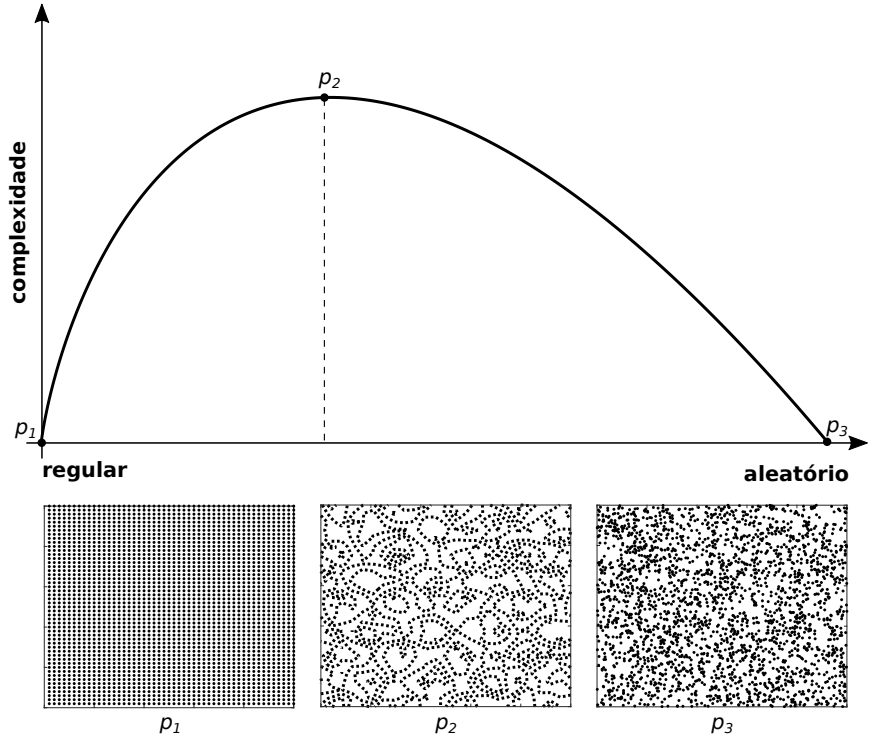

Figura 3.2 - Relação entre padrões de organização de sistema e medidas de complexidade.

(a) Tronco de árvore.

(b) Conjunto de plantas.

(c) Paisagem com rio.

(d) Paisagem com mar.

Figura 3.3 - Combinação de padrões aleatórios e regulares de organização na natureza.

século. Algumas das métricas existentes estão dispostas na Tabela 3.1 de acordo com abordagem adotada. A segunda e a terceira colunas da Tabela 3.1 referem-se ao principal trabalho científico da abordagem em questão e sua descrição em termos da métrica proposta, respectivamente.

Tabela 3.1 - Métricas de complexidade de sistemas.

Abordagem	**Referência**	**Descrição**
Entropia	Shannon (1948)	conteúdo de informação médio da mensagem
Grau de Hierarquia	Simon (1962)	quantidade de níveis de subsistemas no sistema
Conteúdo de Informação Algorítmica	Kolmogorov (1965)	tamanho do menor algoritmo capaz de gerar o objeto
Capacidade Computacional	Wolfram (1984)	habilidade computacional equivalente à da máquina de Turing universal
Profundidade Termodinâmica	Lloyd e Pagels (1988)	quantidade de informação necessária para especificar a trajetória do sistema até o estado atual
Estatística	Crutchfield e Young (1989)	quantidade mínima de informação prévia do sistema necessária para predizer seu comportamento futuro
Dimensão Fractal	Theiler (1990)	número de graus de liberdade no sistema
Profundidade Lógica	Bennett (1995)	tempo exigido por uma máquina de Turing universal padrão para gerar o objeto a partir de entrada que seja algoritmicamente aleatória
Informação	Bar-Yam (1997b)	quantidade de informação necessária para descrever o comportamento do sistema
Tamanho	Mitchell (2009)	número absoluto de par de bases ou genes
Profundidade Dinâmica	Deacon e Koutroufinis (2014)	grau de níveis discretos de organização dinâmica não linear
Conexões	Paiva et al. (2017)	número de conexões aplicado na entropia do sistema

3.4.1 Métrica com base em conexões

No contexto de sistemas a eventos discretos, Paiva (2016) propõe métrica de complexidade de sistemas com base em conexões. Independente do fluxo de informação entre os elementos do sistema, as conexões entre entidades, recursos e filas são mapeadas em dado instante por matriz de relacionamento. Nesta matriz, as colunas representam as entidades e as linhas representam as filas e os recursos. A complexidade do sistema é expressa por $\psi(c)$ em (3.1), em que a probabilidade $P(c_\kappa)$ refere-se à ocorrência da κ-ésima conexão c em (3.2).

$$\psi(c) = -\sum_{\kappa=1}^{\rho} P(c_\kappa) \cdot \log_2 P(c_\kappa) \tag{3.1}$$

$$P(c) = \frac{1}{e_r \cdot (n_r + n_q)} \tag{3.2}$$

onde e_r é o número de entidades que cada recurso pode atender, n_r é o número de recursos, n_q é o número de filas e ρ é o número de conexões ativas em determinado instante, dado por:

$$\rho = \sum_{\kappa=1}^{\lambda} n_{c_\kappa} \cdot n_{\varepsilon_\kappa} \tag{3.3}$$

onde λ é o número de estados das entidades, n_c é o número das conexões ativas em cada estado e n_ε é o número de entidades em cada estado.

As expressões (3.2) e (3.3) são aplicadas no contexto de sistemas a eventos discretos, ou seja, classe de sistemas dinâmicos que dependem da ocorrência de eventos para que haja mudança de estado (WAINER, 2009). O conceito de fila é comumente utilizado na modelagem a eventos discretos, uma vez que as entidades frequentemente precisam compartilhar os recursos do sistema. Nestes casos, as entidades esperam em fila para usar certos recursos, os quais fornecem a elas algum serviço ou algo de que elas necessitem (CASSANDRAS; LAFORTUNE, 2009).

A métrica com base em conexões $\psi(c)$ mapeia as conexões ativas relacionadas às entidades, recursos e filas em dado instante. A Figura 3.4 exemplifica certa configuração de sistema considerando as conexões existentes entre as entidades E_1 a E_6 (em amarelo) e os recursos D_1, D_2, T_1, T_2, T_3, G_1 e G_2 (em cinza).

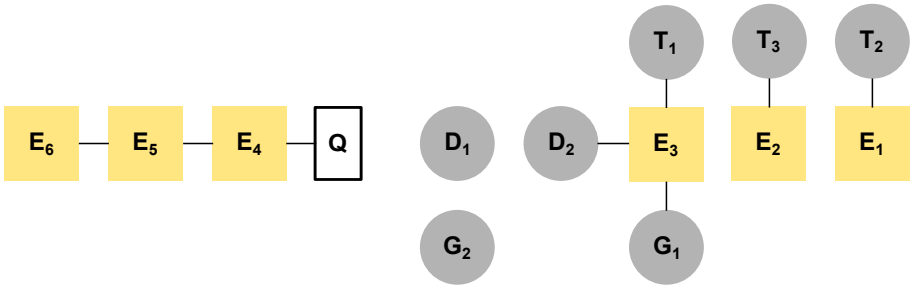

Figura 3.4 - Exemplo de configuração das conexões estabelecidas pelas entidades de E_1 a E_6 em dado instante.

Na Figura 3.4, existem oito conexões ativas no sistema: i) E_1 com T_2, ii) E_2 com T_3, iii) E_3 com T_1, iv) E_3 com D_2, v) E_3 com G_1, vi) a fila Q com E_4, vii) E_4 com E_5, viii) E_5 com E_6. Não existem entidades conectadas aos recursos D_1 e G_2, consequentemente eles estão ociosos. As conexões são expressas pela matriz de relacionamento M, dada por:

$$M = \begin{bmatrix} 0 & 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \tag{3.4}$$

onde as colunas representam as entidades de E_1 a E_6 e as linhas representam a fila Q e os recursos, D_1, D_2, T_1, T_2, T_3, G_1 e G_2, respectivamente.

A complexidade $\psi(c)$, de acordo com métrica proposta por Paiva (2016), é calculada durante a simulação do sistema a partir do modelo das conexões entre os elementos, dado sua dinâmica.

3.4.2 Métrica com base em quantidade de informação

No trabalho de Repperger et al. (2012), a métrica com base em quantidade de informação é descrita detalhadamente, em que as entradas são modeladas como ações e as saídas como objetivos. Assim cria-se a matriz resposta R (frequência das entradas em função das saídas) de cada configuração do sistema, em que as linhas correspondem às ações (entradas) e as colunas, aos objetivos (saídas). Cada posição desta matriz é preenchida com a frequência de cada entrada em relação a cada saída. Para Repperger et al. (2012), a complexidade $\psi(H)$ é dada por:

$$\psi(H) = \frac{\theta}{\det(C_n^T \cdot C_n)} \cdot \log_2 \left[\frac{H(x)}{H(y)} \right] \tag{3.5}$$

onde θ é constante adimensional, C_n é matriz de contingência, C_n^T é a matriz transposta de C_n, $H(x)$ é quantidade de informação de entrada e $H(y)$ é quantidade de informação de saída.

A matriz de contingência C_n contém as frequências relativas das entradas em relação às saídas, obtidas a partir da matriz resposta R. A constante adimensional θ geralmente assume o valor 1 ou pode ser variada dependendo do tipo de sistema que está sendo analisado. Quanto ao cálculo da quantidade de informação, tem-se (3.6) referente às entradas e (3.7) referente às saídas.

$$H(x) = \sum_{i=1}^{n} P(r_i) \cdot \log_2 \left[\frac{1}{P(r_i)} \right] \tag{3.6}$$

$$H(y) = \sum_{j=1}^{\xi} P(r_j) \cdot \log_2 \left[\frac{1}{P(r_j)} \right] \tag{3.7}$$

onde n corresponde ao número de entradas, ξ refere-se ao número de saídas e as probabilidades $P(r_i)$ e $P(r_j)$ são frequências relativas, dadas por:

$$P(r_i) = \frac{\sum r_i}{\sum r_{i,j}} \tag{3.8}$$

$$P(r_j) = \frac{\sum r_j}{\sum r_{i,j}} \tag{3.9}$$

Os valores r_i e r_j correspondem, respectivamente, às frequências por linha i e às frequências por coluna j da matriz resposta R, de dimensão $n \times \xi$. A métrica proposta por Repperger et al. (2012), ao ser aplicada a modelo com três entradas (ações) e três saídas (objetivos), apresenta a matriz resposta R expressa por (3.10) e a matriz de contingência C_n expressa por (3.11).

$$R = \begin{bmatrix} r_{1,1} & r_{1,2} & r_{1,3} \\ r_{2,1} & r_{2,2} & r_{2,3} \\ r_{3,1} & r_{3,2} & r_{3,3} \end{bmatrix} \tag{3.10}$$

$$C_n = \begin{array}{c} \\ \\ \\ \\ P(r_j) \rightarrow \end{array} \begin{array}{c} \begin{bmatrix} \frac{r_{1,1}}{\sum r_{i,j}} & \frac{r_{1,2}}{\sum r_{i,j}} & \frac{r_{1,3}}{\sum r_{i,j}} \\ \frac{r_{2,1}}{\sum r_{i,j}} & \frac{r_{2,2}}{\sum r_{i,j}} & \frac{r_{2,3}}{\sum r_{i,j}} \\ \frac{r_{3,1}}{\sum r_{i,j}} & \frac{r_{3,2}}{\sum r_{i,j}} & \frac{r_{3,3}}{\sum r_{i,j}} \end{bmatrix} \\ \begin{array}{ccc} \frac{\sum r_{i,1}}{\sum r_{i,j}} & \frac{\sum r_{i,2}}{\sum r_{i,j}} & \frac{\sum r_{i,3}}{\sum r_{i,j}} \end{array} \end{array} \begin{array}{c} P(r_i) \\ \downarrow \\ \frac{\sum r_{1,j}}{\sum r_{i,j}} \\ \\ \frac{\sum r_{2,j}}{\sum r_{i,j}} \\ \\ \frac{\sum r_{3,j}}{\sum r_{i,j}} \end{array} \tag{3.11}$$

Os valores de $P(r_i)$ e $P(r_j)$ são aplicados em (3.6) e (3.7), respectivamente, a fim de calcular a quantidade de informação H referente às ações e aos objetivos. Ao dispor da matriz de contingência C_n, expressa em (3.11), e dos valores de $H(x)$ e de $H(y)$, pode-se calcular a complexidade do sistema $\psi(H)$ utilizando (3.5). Embora $H(x)$ e $H(y)$ sejam medidas em $bits$, a complexidade com base em quantidade de informação não possui unidade de medida.

3.4.3 Perfil de complexidade

O perfil de complexidade, descrito em Bar-Yam (1997a), é ferramenta matemática que contabiliza o número de comportamentos independentes observáveis em escala particular, refletindo o grau de dificuldade de descrever o sistema. A escala indica a precisão da observação do sistema e considera abrangência espacial, duração, momento e energia de comportamento.

Como métrica, o perfil de complexidade captura importantes aspectos da relação entre o comportamento das partes do sistema e o comportamento do sistema inteiro. Para Bar-Yam (1997a), os comportamentos podem ser classificados em: i) aleatórios e independentes, ii) coerentes e iii) correlatos e especializados. Sistemas complexos são formados por partes correlatas e especializadas, no entanto exibem comportamento que equilibra movimentos altamente aleatórios e altamente ordenados. Nestes sistemas, o perfil de complexidade diminui à medida que a escala aumenta, por exemplo: escala varia do nível atômico ao social para complexidade humana.

A Figura 3.5 (sem escala), adaptada de Bar-Yam (1997a), apresenta a complexidade de um indivíduo observado em escalas distintas, de forma que a quantidade de comportamentos independentes contabilizados em escala atômica é maior que na escala social.

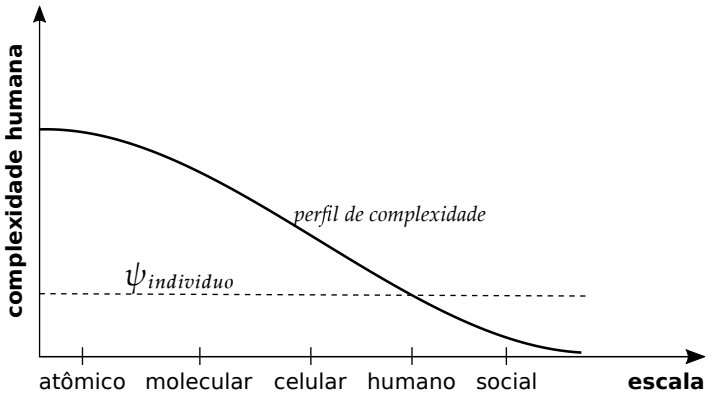

Figura 3.5 - Escalas do perfil de complexidade humana.

3.5 Considerações finais

A complexidade dos sistemas tem aumentado progressivamente nas organizações humanas devido às revoluções e mudanças nas estruturas de controle. No entanto, independente da ação humana, a natureza em si é caracterizada por padrões de organização complexa, que combinam regularidade e aleatoriedade em suas estruturas e comportamentos. No que se refere a comportamento, a maioria dos sistemas apresenta características como não linearidade, emergência, auto-organização que geram complexidade em algum nível, passível de ser quantificada por métrica apropriada. Além da observação de aspectos da organização interna dos sistemas, pode-se verificar ainda como eles são influenciados por aspectos externos, através de técnicas como análise de sensibilidade, abordada no próximo capítulo.

CAPÍTULO 4

ANÁLISE DE SENSIBILIDADE

Este capítulo aborda a análise de sensibilidade em termos conceituais e de aplicação. Diversos métodos exploram a relação entrada-saída dos sistemas de forma visual ou por procedimentos numéricos, analíticos ou estatísticos. Baseado nos métodos, o estudo de sensibilidade possui aplicações diversas, pois serve como ferramenta matemática em áreas como química, biologia, medicina, engenharias, economia e outras.

4.1 Conceito e finalidade da análise de sensibilidade

Para Saltelli et al. (2004), a **análise de sensibilidade** é o estudo do efeito de dada entrada sobre determinada saída, em que se avalia como as incertezas das saídas podem ser atribuídas a diferentes fontes de incerteza nas entradas. A análise de sensibilidade pode ainda ser entendida como a busca por quantificar a contribuição relativa de cada entrada na saída do modelo (HOMMA; SALTELLI, 1996). Comumente, a análise de sensibilidade é acompanhada da análise de incerteza (IMAN; HELTON, 1988; MARINO et al., 2008). A diferença essencial entre elas é que a **análise de incerteza** avalia quão incerta é determinada conclusão e a análise de sensibilidade indica de onde vem a incerteza (SALTELLI; ANNONI, 2010; LOUCKS; BEEK, 2005).

No estudo de sistemas, diferentes cenários ou circunstâncias indicam a necessidade de simplificar os modelos, procurar erros, verificar a robustez da solução ótima e compreender a relação entre variáveis de entrada e saída do sistema. Para atingir tais objetivos, a análise de sensibilidade é utilizada no processo de tomada de decisão, comunicação, compreensão de sistemas e desenvolvimento de modelos. O impacto que potenciais mudanças e erros nas entradas podem gerar na saída indica quão sensível é o sistema a estas variações (PANNEL, 2009).

A fim de simular determinado sistema, busca-se o modelo que o represente adequadamente, preservando suas características essenciais. O tamanho do modelo não deve ser confundido com sua complexidade. Neste caso, a análise de sensibilidade pode contribuir para identificar a complexidade, verificando se o modelo processa corretamente os parâmetros, e restringir a complexidade pela fixação das variáveis de entrada pouco relevantes, reduzindo o esforço computacional durante a simulação do modelo (FREY; PATIL, 2002; IMAN; CONOVER, 1980). Além de descobrir erros no modelo e simplificá-lo, a análise de sensibilidade pode ser útil na identificação

de regiões críticas no espaço das entradas, na avaliação de política, na definição de prioridades para pesquisa e defesa contra falsificações dos analistas (SALTELLI et al., 2008).

Segundo Hamby (1994), a sensibilidade do sistema a variações nos parâmetros de entrada permite indicar: i) esforços de pesquisa para aprofundar o conhecimento sobre determinado parâmetro, reduzindo a incerteza na saída, ii) os parâmetros que podem ser eliminados do modelo final devido a sua insignificância, iii) as variáveis de entrada que mais contribuem para a variabilidade da saída, iv) os parâmetros de maior correlação com a saída e v) uma vez que o modelo esteja em uso, as consequências advindas da mudança de determinado parâmetro de entrada. Definido o propósito da análise, procede-se à escolha do método mais adequado para estudo da sensibilidade, uma vez que os métodos podem divergir nas respostas para as mesmas perguntas.

4.2 Métodos de análise de sensibilidade

Os métodos de análise de sensibilidade fornecem informação sobre a relação entre variáveis de entrada e de saída dos sistemas. Com base no propósito da análise, são definidos os parâmetros de entrada e as saídas de interesse, que podem ser quantitativos ou qualitativos. Os parâmetros de entrada referem-se às variáveis independentes (que podem ser manipuladas) e as saídas referem-se às variáveis dependentes (que podem ser afetadas pelas manipulações dos parâmetros de entrada) (BARROS NETO et al., 2001).

As manipulações dos parâmetros de entrada são conduzidas com base em métodos de análise de sensibilidade, classificados de acordo com a abordagem adotada em relação ao espaço de busca dos parâmetros de entrada: local ou global. A análise local depende de estimativas pontuais dos valores dos parâmetros, ao passo que a análise global examina a sensibilidade com base em toda distribuição dos parâmetros (HAMBY, 1995). Para Saltelli et al. (1999), a abordagem local avalia as saídas do sistema obtidas pela variação dos parâmetros de entrada um de cada vez. Assim, enquanto um parâmetro varia, os outros são mantidos fixos no valor central (nominal). Na análise global, além do espaço dos parâmetros de entrada ser explorado dentro de região finita (ou viável), as saídas são tomadas globalmente, pelo uso de média sobre a variação de todos os parâmetros de entrada.

A Figura 4.1 ilustra medidas relativas a um parâmetro por vez (*one-at-a-time*): enquanto um parâmetro (indicado pela seta vermelha) tem seus valores alterados,

os outros permanecem fixos no valor nominal ou valor-base, $\alpha = (\alpha_1,\ \alpha_2,\ \cdots,\ \alpha_n)$. Assim, no primeiro ciclo, apenas o valor do parâmetro x_1 é modificado, no segundo ciclo, o valor de x_2 é alterado, e assim sucessivamente até o n-ésimo ciclo, em que apenas o valor x_n é variado.

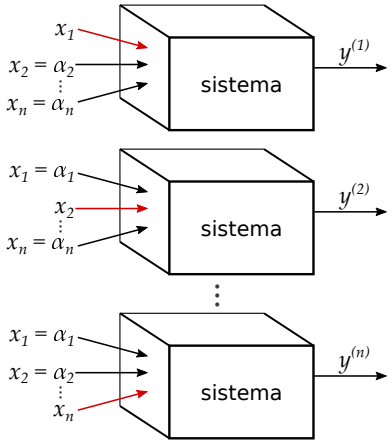

Figura 4.1 - Esquema de medidas um parâmetro por vez para n parâmetros de entrada.

Embora restritos ao ponto central (ou caso-base), os métodos de análise local são frequentemente utilizados devido ao esforço computacional relativamente baixo, ao contrário da análise global, que geralmente requer simulações tipicamente na ordem de 10^4 (PETROPOULOS G. IRELAND; KALIVAS, 2015; VERRELST N. SABATER; MORENO, 2016). No processo de análise de sensibilidade, métodos globais demandam tempo nas etapas de: i) definição das distribuições de incerteza dos parâmetros de entrada e ii) simulação do sistema para os conjuntos de entrada. O tempo de análise para encontrar a distribuição de incerteza própria de cada parâmetro pode ser financeiramente onerosa devido ao acesso a diversas fontes para extrair o conhecimento necessário sobre os parâmetros de entrada, como opinião de especialistas (SALTELLI et al., 2008). O tempo consumido na etapa de simulação depende do modelo e do hardware para processamento dos dados no simulador.

Considerando conhecida a distribuição probabilística que rege cada parâmetro de entrada, pode-se gerar valores aleatórios dos parâmetros de interesse. Assim, para n parâmetros de entrada e m cenários (conjuntos de valores de entrada), tem-se a matriz X, dada por (4.1). Na maioria dos casos, assume-se que os parâmetros de entrada são independentes uns dos outros, de modo que os valores aleatórios possam ser obtidas separadamente a partir da distribuição de cada parâmetro. Com objetivo de obter o valor da saída correspondente a cada conjunto de valores dos

parâmetros de entrada (linhas da matriz X), a simulação do modelo é executada m vezes, resultando assim na matriz Y dada por (4.2).

$$X = \begin{bmatrix} x_1^{(1)} & x_2^{(1)} & \cdots & x_n^{(1)} \\ x_1^{(2)} & x_2^{(2)} & \cdots & x_n^{(2)} \\ x_1^{(3)} & x_2^{(3)} & \cdots & x_n^{(3)} \\ \vdots & \vdots & \ddots & \vdots \\ x_1^{(m-1)} & x_2^{(m-1)} & \cdots & x_n^{(m-1)} \\ x_1^{(m)} & x_2^{(m)} & \cdots & x_n^{(m)} \end{bmatrix} \tag{4.1}$$

$$Y = \begin{bmatrix} y^{(1)} \\ y^{(2)} \\ y^{(3)} \\ \vdots \\ y^{(m-1)} \\ y^{(m)} \end{bmatrix} \tag{4.2}$$

onde a matriz X contém os valores dos parâmetros de entrada x_1 a x_n (colunas) dos m cenários (linhas) e a matriz Y contém os valores de saída y correspondentes aos conjuntos de parâmetros de entrada, chamados de cenários. Os valores sobrescritos indicam o cenário em questão.

Em síntese, a análise de sensibilidade geralmente compreende: i) definição do modelo e de suas variáveis independentes e dependentes; ii) atribuição de funções de densidade de probabilidade a cada parâmetro de entrada, iii) geração de matriz de entrada através de método de amostragem aleatória apropriado, iv) cálculo do vetor de saída e v) avaliação dos efeitos e da importância relativa da relação entrada-saída (HAMBY, 1994). Uma vez definidos os parâmetros de entrada e de posse do modelo ou do próprio sistema, a análise de sensibilidade é desenvolvida pela aplicação de métodos: i) visuais, ii) analíticos e iii) estatísticos (FREY; PATIL, 2002).

4.2.1 Métodos visuais

Dois métodos visuais são geralmente utilizados para analisar a sensibilidade do sistema: diagrama aranha e diagrama de dispersão. O primeiro método refere-se a medidas da saída para variações de um parâmetro por vez, enquanto o segundo método utiliza a dispersão de cada parâmetro em relação aos valores da saída cor-

respondentes aos conjuntos de entradas.

O **diagrama-aranha**, assim denominado por Eschenbach e McKeague (1989), apresenta as curvas de variação dos parâmetros de entrada, como ilustrado na Figura 4.2. Esta variação pode ser negativa ou positiva a partir do valor-base do parâmetro α_j. Quando $x_1 = \alpha_1,\ x_2 = \alpha_2,\ \cdots,\ x_n = \alpha_n$, tem-se a saída do sistema β, que corresponde a $y = f(\alpha_1,\ \alpha_2, \cdots,\ \alpha_n)$. Graficamente, a saída β é representada pelo ponto central de intersecção das curvas de sensibilidade.

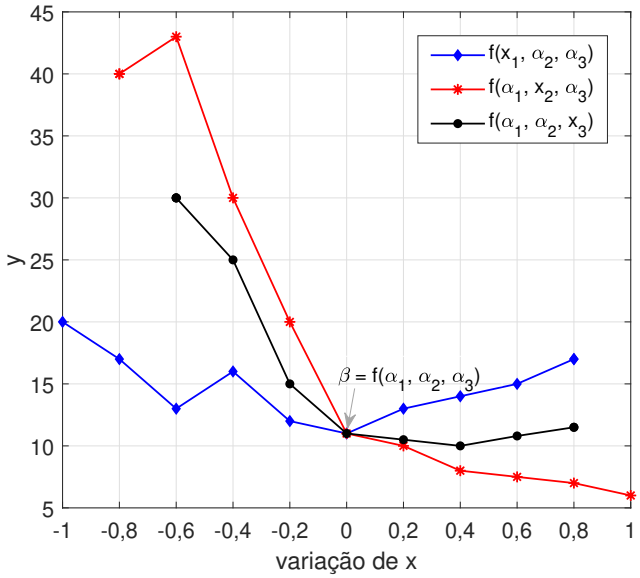

Figura 4.2 - Exemplo de diagrama-aranha com três parâmetros: x_1, x_2 e x_3.

Usualmente, o caso-base $\alpha = (\alpha_1,\ \alpha_2,\ \cdots,\ \alpha_n)$ refere-se à solução ótima ou otimizada, obtida após processo de otimização, ou à melhor aposta para as entradas, definida por especialista no sistema (PANNEL, 2009; SARAIVA et al., 2017). A partir do valor-base, o parâmetro pode ser variado até $\pm 100\%$ ou até o limite da sua faixa de valores viáveis. Em situações práticas, estabelecer o intervalo de variação dos parâmetros significa definir faixas de operação do sistema sem comprometer seus limites físicos. Devido às questões operacionais ou de otimização, os parâmetros podem ter restrições quanto ao tamanho do intervalo de variação, apresentando somente valores próximos do valor-base (GOMES et al., 2017).

Outra forma gráfica de analisar a sensibilidade dos parâmetros é por meio do **diagrama de dispersão**, frequentemente utilizado após simulação do modelo por métodos probabilísticos. A influência dos parâmetros de entrada é avaliada de forma

individual em determinada saída e a análise é visual (FREY; PATIL, 2002). Considerando a matriz X, dada por (4.1), contendo m conjuntos de entradas, pode-se obter o conjunto de saídas Y, dado por (4.2), de dimensão $m \times 1$. Com estes dados, pode-se produzir n diagramas de dispersão projetando por sua vez os m valores da saída y em relação aos m valores de cada um dos n parâmetros de entrada (SALTELLI et al., 2008).

Para exemplificar, a Figura 4.3 ilustra os diagramas de dispersão de modelo com quatro parâmetros, $x_1, ..., x_4$, cujas distribuições probabilísticas $N(\overline{\mu}_{x_j}, \sigma)$ são distribuições normais de média $\overline{\mu}_{x_j}$ e desvio padrão σ dadas por: $N(0,1)$, $N(0,2)$, $N(0,3)$ e $N(0,4)$, respectivamente. Utilizando simulação de Monte Carlo, os cenários podem ser gerados a partir das distribuições e o modelo pode ser simulado para obter o conjunto de saídas Y. A Figura 4.3 ilustra a dispersão de cada parâmetro em relação à saída y, em que $y = f(x_1, ..., x_4)$.

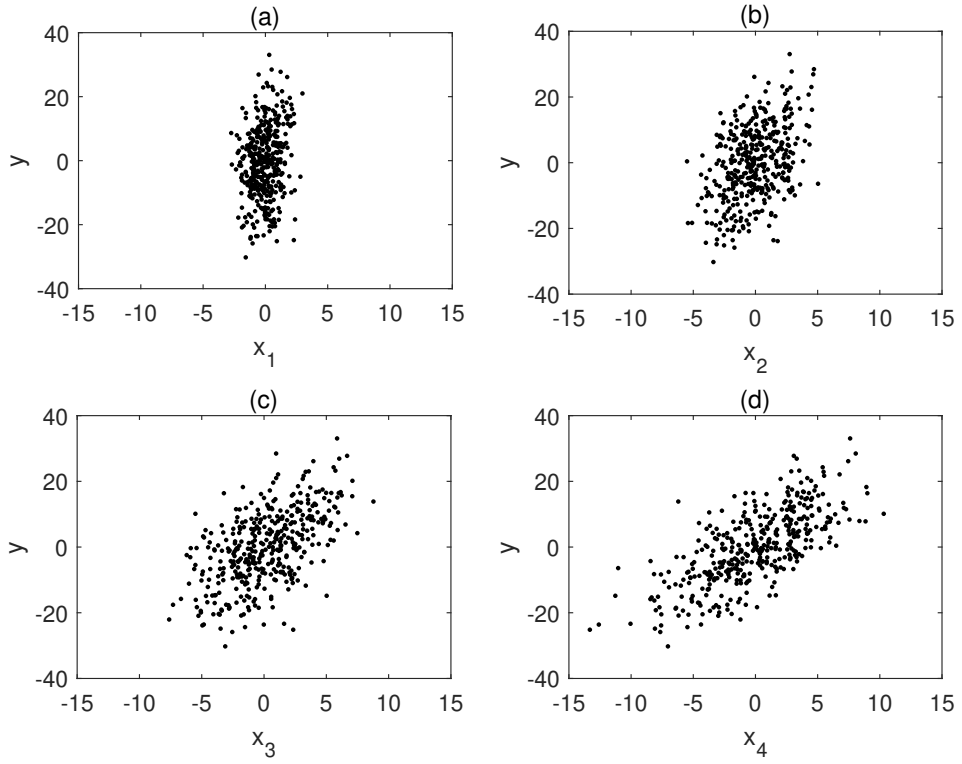

Figura 4.3 - Diagrama de dispersão dos parâmetros de entrada de x_1 a x_4 em relação à saída y.

Observa-se na Figura 4.3 que a dispersão indica a variabilidade do parâmetro, assim a Figura 4.3(a) refere-se ao parâmetro de menor variabilidade, pois todos os pontos

estão concentrados no intervalo $[-5, 5]$, e a Figura 4.3(d) refere-se ao parâmetro de maior variabilidade, cuja dispersão abrange o intervalo $[-15, 15]$. Além da variabilidade, deve-se observar no diagrama de dispersão a forma ou padrão dos pontos. A Figura 4.3(d) possui forma de dispersão com os pontos indicando tendência, devido à correlação entre a entrada x_4 e a saída y. Saltelli et al. (2008) afirma que o sistema em questão é mais sensível a variacões em x_4, x_3, x_2 e x_1, nesta ordem.

Segundo Hamby (1994), os modelos são sensíveis aos parâmetros de entrada de duas formas distintas: i) variabilidade ou incerteza dos parâmetros, em que a incerteza na entrada propaga-se pelo modelo resultando em contribuição na variabilidade da saída e ii) correlação entre entrada e saída, em que a saída pode ser altamente correlacionada com certo parâmetro de entrada. Assim, parâmetros importantes (de alta variabilidade, segundo análise de incerteza) são também parâmetros sensíveis. No entanto, podem existir parâmetros sensíveis de baixa variabilidade, considerados pouco importantes pela análise de incerteza, contudo podem conduzir a mudanças significativas na saída. Assim, os diagramas de dispersão podem representar visualmente tanto variabilidade como tendência na relação entrada-saída.

Com intuito de expressar visualmente a tendência local dos parâmetros, Chan et al. (2013) propõem diagrama de dispersão de sensibilidade generalizada. Neste tipo de diagrama, os coeficientes de sensibilidade são visualmente representados como linhas de fluxo, apresentando continuidade e orientação dos dados, além de resolver o problema de sobreposição de pontos. Tais coeficientes são calculados por método que compreende três transformações: i) seleção por subespaço, ii) diferenciação em relação a variável de interesse e iii) projeção.

Em diversas aplicações, os métodos visuais fornecem indicação de como dada saída é afetada pela variação das entradas. Geralmente, tais métodos são usados em estudos preliminares de análise de sensibilidade ou como complemento dos resultados de métodos analíticos e estatísticos (FREY; PATIL, 2002).

4.2.2 Métodos analíticos

Os **métodos analíticos** fornecem mecanismos para quantificar a sensibilidade da relação entrada-saída. Nesta linha, métodos baseados em derivadas ou planejamento fatorial são frequentemente aplicados em áreas como química, física, medicina e engenharias. Nos métodos baseados em derivadas, aplica-se a metodologia um parâmetro por vez para cálculo das derivadas ao passo que, no planejamento fatorial, todos os parâmetros são variados ao mesmo tempo.

Derivadas podem definir matematicamente quão sensível a saída y é em relação ao parâmetro de entrada x_j. Na análise de um parâmetro por vez, derivadas parciais são comumente aplicadas, possivelmente normalizadas pelo valor nominal do parâmetro ou por seu desvio padrão (SALTELLI et al., 1999). Em (4.3), a sensibilidade é dada pela derivada parcial (indicada pela letra p sobrescrita) de y em relação a x_j. De (4.3) pode-se escrever (4.4), em que a sensibilidade do parâmetro x_j resulta da derivada parcial normalizada pelo desvio padrão da entrada σ_{x_j} e da saída σ_y (SALTELLI et al., 2008).

$$S^p_{x_j} = \frac{\partial y}{\partial x_j} \tag{4.3}$$

$$S^\sigma_{x_j} = \frac{\sigma_{x_j} \partial y}{\sigma_y \partial x_j} \tag{4.4}$$

A análise de sensibilidade baseada em derivadas fica restrita ao ponto central no espaço dos parâmetros de entrada, além de ser injustificada quando a entrada é incerta e a linearidade do modelo é desconhecida. A fim de explorar o espaço das entradas, a abordagem local pode ser aplicada globalmente, por exemplo: cálculo de **taxas incrementais**, tal como $\frac{y(x_j+\Delta x_j)-y(x_j)}{\Delta x_j}$, em diferentes pontos no espaço dos parâmetros a fim de obter saída média de y (SALTELLI et al., 2008). Ainda assim, apenas um parâmetro por vez é variado para cada ponto escolhido.

Quando deseja-se variar todos os parâmetros ao mesmo tempo e medir o efeito ocorrido na saída devido a estas variações, pode-se utilizar o método analítico de **planejamento fatorial** (*factorial design*). Em seu caso mais simples, planejamento fatorial 2^n, os n parâmetros de entrada podem assumir dois níveis e 2^n combinações possíveis de caracterização do conjunto de entrada. A Tabela 4.1 dispõe todas combinações ν dos níveis (representados por $-$ e $+$) dos parâmetros x_1, x_2 e x_3 e as respectivas saídas $y^{(\nu)}$ com $1 \leq \nu \leq 2^3$ (LAW et al., 2007).

Os índices de sensibilidade dos parâmetros de entrada x_1, x_2 e x_3 são expressos por (4.5), (4.6) e (4.7), respectivamente, quantificando o efeito da variação de nível. A generalização de (4.5), (4.6) e (4.7) resulta em (4.8), que corresponde à diferença entre as médias das saídas quando o parâmetro está no nível $+$ e quando o parâmetro está no nível $-$ (LAW et al., 2007; BARROS NETO et al., 2001).

Tabela 4.1 - Combinações de planejamento fatorial de 2^3.

ν	x_1	x_2	x_3	$y^{(\nu)}$
1	−	−	−	$y^{(1)}$
2	+	−	−	$y^{(2)}$
3	−	+	−	$y^{(3)}$
4	+	+	−	$y^{(4)}$
5	−	−	+	$y^{(5)}$
6	+	−	+	$y^{(6)}$
7	−	+	+	$y^{(7)}$
8	+	+	+	$y^{(8)}$

$$S^f_{x_1} = \frac{(y^{(2)} - y^{(1)}) + (y^{(4)} - y^{(3)}) + (y^{(6)} - y^{(5)}) + (y^{(8)} - y^{(7)})}{4} \tag{4.5}$$

$$S^f_{x_2} = \frac{(y^{(3)} - y^{(1)}) + (y^{(4)} - y^{(2)}) + (y^{(7)} - y^{(5)}) + (y^{(8)} - y^{(6)})}{4} \tag{4.6}$$

$$S^f_{x_3} = \frac{(y^{(5)} - y^{(1)}) + (y^{(6)} - y^{(2)}) + (y^{(7)} - y^{(3)}) + (y^{(8)} - y^{(4)})}{4} \tag{4.7}$$

$$S^f_{x_j} = \bar{y}_{x_j^+} - \bar{y}_{x_j^-} \tag{4.8}$$

O valor da sensibilidade $S^f_{x_j}$ pode ser positivo ou negativo, o que significa aumento ou decréscimo, em média, da saída quando x_j passa do nível x_j^+ para o nível x_j^-. Na prática, os níveis podem ser representados por valores quantitativos ou qualitativos das variáveis em análise e o planejamento dos experimentos deve ser norteado pelo objetivo proposto (BARROS NETO et al., 2001).

As combinações dependem da quantidade de parâmetros de entrada e de níveis de cada parâmetro. No planejamento fatorial 2^n, assume-se que todos os parâmetros têm apenas dois níveis. Contudo, caso a quantidade de níveis varie, o total de combinações corresponderá ao número de níveis de um parâmetro multiplicado pelo do parâmetro seguinte e assim sucessivamente até chegar ao número de níveis do último parâmetro de entrada.

Cada combinação dos níveis dos parâmetros de entrada refere-se a um experimento, que geralmente é repetido algumas vezes para estimar o erro experimental. Portanto, todas as combinações possíveis dos níveis dos parâmetros de entrada é apenas o número mínimo necessário para realizar planejamento fatorial completo. Logo,

recomenda-se selecionar os parâmetros de entrada mais relevantes para análise, utilizando fatorial fracionário, por exemplo (BARROS NETO et al., 2001).

Além de derivadas e planejamento fatorial, outros métodos analíticos podem ser aplicados para medir a sensibilidade dos parâmetros de entrada, tais como: método de efeitos elementares, análise de sensibilidade da faixa nominal, análise do ponto de equilíbrio, diferença na razão *log-odds*, diferenciação automática entre outros. Estes métodos limitam-se à avaliação do impacto da faixa de variação nos valores de entrada na saída. Portanto, investigações sobre a relação da variância na saída devido à variância nas entradas desenvolvem-se com o auxílio de métodos estatísticos (FREY; PATIL, 2002).

4.2.3 Métodos estatísticos

Com base em medidas estatísticas de tendência central e de variabilidade, métodos de análise de sensibilidade podem percorrer o espaço dos parâmetros de entrada e obter as relações que definem a influência de cada parâmetro na saída do modelo. Pode-se gerar conjuntos de valores aleatórios dos parâmetros de entrada, como dado em (4.1) e assim obter a saída $y = f(x_1,\ x_2, \cdots,\ x_n)$, para cada conjunto de valores de entrada. A partir de diferentes manipulações com base em métodos como variância condicional e efeitos totais, pode-se conduzir a medidas de sensibilidade global dos parâmetros de entrada.

De forma inversa da análise local de um parâmetro por vez, o método da **variância condicional** consiste em medidas obtidas a partir da variação de $n-1$ parâmetros utilizando suas distribuições probabilísticas, enquanto um parâmetro permanece constante. O termo **condicional** refere-se à condição de fixar um parâmetro de entrada e observar a variabilidade da saída, comparando-a à variância incondicional ou total, dada por (4.9), obtida quando os n parâmetros de entrada possuem valores variados.

$$\sigma^2(Y) = \overline{\mu}_{\sigma^2}\left(Y|_{x_{\sim j}}\right) + \sigma^2_{\overline{\mu}}\left(Y|_{x_{\sim j}}\right) \tag{4.9}$$

onde $x_{\sim j}$ corresponde à variação de todos os parâmetros de entrada exceto x_j, $\overline{\mu}_{\sigma^2}$ é a média da variância, $\sigma^2_{\overline{\mu}}$ é a variância da média, Y é dado por (4.2) e $Y|_{x_{\sim j}}$ indica o vetor de saída quando x_j constante, ou seja, tal que x_j não varia. A média é utilizada uma vez que o parâmetro em análise assume distintos valores dentro do seu espaço de possibilidades, pois se x_j for fixado em apenas um valor, a análise

ficaria dependente deste ponto.

Assim a sensibilidade do parâmetro analisado é obtida pela relação entre a variância das médias da saída (para x_j fixo em distintos pontos) e a variância total, dada por (4.10), onde σ^2 sobrescrito em S_{x_j} indica o uso de variância condicional para calcular o índice de sensibilidade dos parâmetros de entrada.

$$S_{x_j}^{\sigma^2} = \frac{\sigma_{\overline{\mu}}^2\left(Y|_{x_{\sim j}}\right)}{\sigma^2(Y)} \tag{4.10}$$

Considerando o cálculo de sensibilidade em (4.10), tem-se que o parâmetro mais sensível é aquele que ao ser fixado gera, em média, maior redução na variância da saída. Diz-se **em média** porque calcula-se a média da fixação do parâmetro através da distribuição do parâmetro em si (SALTELLI et al., 2008). Como a análise refere-se a parâmetro isoladamente, ela é denominada de primeira ordem. Se os parâmetros de entrada forem tomados dois a dois (ou mais), a análise é de segunda ordem (ou ordens maiores), dado por:

$$\sigma_{\overline{\mu}}^2\left(Y|_{x_{\sim j},x_{\sim l}}\right) = \sigma_{\overline{\mu}}^2\left(Y|_{x_{\sim j}}\right) + \sigma_{\overline{\mu}}^2\left(Y|_{x_{\sim l}}\right) + \sigma_{\delta_{x_j,x_l}}^2(Y) \tag{4.11}$$

onde $j, l \in \mathbb{N}^*$ com $l \neq j \leq n$. O termo $\sigma_{\delta_{x_j,x_l}}^2(Y)$ corresponde à variância de Y devido à interação entre os parâmetros de entrada x_j e x_l, resultando em parte da saída y que não pode ser obtida pela superposição de efeitos produzidos separadamente por x_j e x_l.

Tendo em vista os efeitos advindos da interação entre parâmetros, o **método de efeitos totais** considera todos os termos de qualquer ordem que contenha o parâmetro em análise (SALTELLI et al., 2008; SARRAZIN et al., 2016). Por exemplo, em modelo genérico com três parâmetros de entrada, tem-se:

$$\begin{aligned}
S_{x_1}^{\tau} &= S_{x_1} + S_{x_1,x_2} + S_{x_1,x_3} + S_{x_1,x_2,x_3} \\
S_{x_2}^{\tau} &= S_{x_2} + S_{x_1,x_2} + S_{x_2,x_3} + S_{x_1,x_2,x_3} \\
S_{x_3}^{\tau} &= S_{x_3} + S_{x_1,x_3} + S_{x_2,x_3} + S_{x_1,x_2,x_3}
\end{aligned} \tag{4.12}$$

onde $S_{x_1}^{\tau}$, $S_{x_2}^{\tau}$ e $S_{x_3}^{\tau}$ são os índices de sensibilidade que representam os efeitos totais

de x_1, x_2 e x_3, respectivamente. Em (4.12) existem sete termos distintos de interação: S_{x_1}, S_{x_2}, S_{x_3}, S_{x_1,x_2}, S_{x_1,x_3}, S_{x_2,x_3}, S_{x_1,x_2,x_3}. A lei de formação é dada por $2^n - 1$, onde n é o número de parâmetros de entrada.

Genericamente, (4.12) equivale à (4.13), dada como a diferença entre a soma de todos os possíveis termos de sensibilidade e a sensibilidade de primeira ordem do parâmetro, obtida pelo método de variância condicional. Logo, considerando (4.9), esta diferença corresponde à relação entre a média das variâncias condicionais e a variância total (SALTELLI et al., 2008).

$$S_{x_j}^{\tau} = 1 - \frac{\sigma_{\overline{\mu}}^2\left(Y|_{x_{\sim j}}\right)}{\sigma^2(Y)} = \frac{\overline{\mu}_{\sigma^2}\left(Y|_{x_{\sim j}}\right)}{\sigma^2(Y)} \tag{4.13}$$

onde $S_{x_j}^{\tau}$ é índice de sensibilidade de x_j calculado com base nos efeitos totais.

Os métodos baseados em variância podem conduzir à compreensão completa do padrão de sensibilidade do modelo quando todos os termos de interação são verificados, ou seja, $2^n - 1$. Contudo, é suficiente a caracterização do padrão de sensibilidade através do conjunto total de termos de primeira ordem e dos efeitos totais. No caso da análise de 10 fatores, calculam-se 20 termos de sensibilidade ao invés de 1023.

Além dos métodos da variância condicional e de efeitos totais, os métodos estatísticos compreendem ainda análise de regressão, métodos de superfície de resposta, teste de sensibilidade de amplitude de Fourier, índice de informação mútua entre outros (FREY; PATIL, 2002).

4.3 Aplicações

Existem diversas aplicações de análise de sensibilidade em áreas como biologia, química, economia, engenharia entre outras. Em Marino et al. (2008), índices globais de sensibilidade são obtidos em modelos matemáticos e computacionais de sistemas biológicos. Segundo os autores, a precisão dos resultados destes modelos é afetada pela presença de incertezas nos dados experimentais usados para estimar valores de parâmetros. Contudo, estas incertezas podem ser identificadas e controladas com base nos resultados das análises de incerteza e sensibilidade.

Considerando o mesmo problema da estimativa dos parâmetros do modelo em sistemas biológicos, Cho et al. (2003) publicam trabalho sobre análise de sensibilidade aplicada na identificação dos principais parâmetros do modelo de via de transdu-

ção de sinal (mecanismo em que a célula recebe, processa e responde a estímulos bioquímicos). Os resultados apontaram aos biólogos quais proteínas devem ser consideradas para a medição. Ainda envolvendo estudos de sensibilidade na área de biologia, tem-se trabalhos sobre: velocidade de invasões biológicas (NEUBERT; CASWELL, 2000), declínio nas populações de anfíbios (BIEK et al., 2002), medida do gradiente de pressão venosa hepática (WANG et al., 2018) entre outros.

Na área de química, mensurar o efeito devido a alterações nas variáveis de entrada também produz conhecimnento útil acerca dos sistemas. Segundo Saltelli et al. (2005), os modelos químicos permitem estudos sobre mecanismos de reação, propriedades cinéticas, rendimento de processo sob diferentes condições operacionais ou o impacto de produtos químicos no homem e no meio ambiente, situações em que análise de sensibilidade é frequentemente empregada. Alguns trabalhos neste contexto podem ser listados, com aplicação em: cinética química (RABITZ et al., 1983; LUTZ et al., 1988), química atmosférica sem fase aquosa (PANDIS; SEINFELD, 1989), avaliação de desempenho para eliminação de resíduos radioativos (HELTON, 1993), exposição humana a produtos químicos (MOKHTARI et al., 2006), difusão multicomponente em catalisadores porosos (DONAUBAUER; HINRICHSEN, 2018) entre outros.

Análise de sensibilidade é ainda comumente aplicada a problemas de engenharia, economia e assuntos correlatos, como em casos de avaliação econômica ou de comportamento dos sistemas, por exemplo: níveis de estoque base em sistemas de inventário de produção multinível (GLASSERMAN; TAYUR, 1995), escalas de eficiência de unidades de produção (SIMAR; WILSON, 1998), produção de biodiesel (ZHANG et al., 2003), planejamento e gerenciamento de sistemas de recursos hídricos (LOUCKS; BEEK, 2005), relação entre inovação e desempenho (LÖÖF; HESHMATI, 2006), análise energética de edifícios (TIAN, 2013), proposta de rodovias premium multinível para combater congestionamento do tráfego (FAN; JIANG, 2018), gerador à relutância chaveada (SARAIVA et al., 2017), repotenciação do sistema elétrico (GOMES et al., 2017) entre outros.

Independente da área de aplicação, existem estudos que abordam a análise de sensibilidade como ferramenta para avaliar robustez de resultados, inclusive de processo de otimização (LEVINE; RENELT, 1992; PANNEL, 2009; BERTSIMAS; SIM, 2004; HLADÃK, 2016; SIMONE, 2016). A pesquisa realizada por Levine e Renelt (1992) analisa a robustez do sistema composto por indicadores econômicos, políticos e institucionais utilizando regressão de crescimento entre os países, em que se vinculam taxas de crescimento a longo prazo. A análise apontou fragilidade da maioria dos estudos a

pequenas variações no conjunto de informações de condicionamento.

Na área de complexidade de sistemas, a análise de sensibilidade contribui para simplificação de modelos, por meio da redução do número de variáveis (FU et al., 2011; LAWRIE; HEARNE, 2007), e compreensão da relação entre a complexidade e a sensibilidade do modelo (SOLSVIK; JAKOBSEN, 2011; ZHANG et al., 2001; GANOPOLSKI et al., 2001). Neste sentido, algumas investigações corroboram a hipótese de que a sensibilidade geral do modelo aumenta à medida que ele se torna mais complexo em termos do aumento do número de parâmetros, contudo satura após certo nível (LINDENSCHMIDT, 2006; BASTIDAS et al., 2006). Alguns trabalhos relacionam ainda a análise de sensibilidade a medidas de complexidade referente a: séries temporais não lineares (FADLALLAH et al., 2013), regressão simbólica (VLADISLAVLEVA et al., 2009) e análise de sinal fisiológico (REZEK; ROBERTS, 1998).

4.4 Considerações finais

A análise de sensibilidade permite a investigação das incertezas nas saídas dos sistemas. A fim de mensurar a contribuição de cada parâmetro de entrada na variabilidade das saídas, métodos visuais, analíticos e estatísticos são empregados em estudos diversos. Estes métodos resultam em medidas de sensibilidade, as quais fundamentam a tomada de decisão quanto à simplificação de modelos, robustez de solução otimizada, verificação de erros, entre outros aspectos. Além disto, as entradas e saídas dos sistemas compreendem os fluxos com o ambiente e refletem a organização interna dos mesmos. Logo, a metodologia proposta no próximo capítulo considera que a sensibilidade dos parâmetros pode compor métrica de complexidade de sistemas.

CAPÍTULO 5

METODOLOGIAS PROPOSTAS

Este capítulo compreende as métricas propostas de análise de sensibilidade e de complexidade de sistemas. Com base na complexidade natural, apresenta-se a análise do sistema desde a modelagem ao monitoramento seguido da tomada de decisão. A fim de aplicar as metodologias propostas, três modelos são apresentados, o primeiro na área de engenharia elétrica, o segundo na área da saúde e o terceiro na área de empreendedorismo.

5.1 Métricas propostas de análise de sensibilidade

A fim de contribuir para a análise integral dos sistemas, métricas de análise de sensibilidade são desenvolvidas e integradas à métrica de complexidade. A partir da modelagem, simulação e validação dos sistemas definidos para estudos, aplicam-se as métricas de sensibilidade e complexidade e realizam-se monitoramento e intervenções. As métricas de análise de sensibilidade propostas baseiam-se no método visual do diagrama-aranha e no método estatístico de variância condicional. Considerando abordagem local de análise dos parâmetros de entrada, propõem-se os seguintes métodos: da área, da soma das diferenças e da variância condicional local.

5.1.1 Método da área

O **método da área** utiliza o diagrama-aranha como base para cálculo da área entre as curvas dos parâmetros de entrada x_j e a reta definida pela saída β, chamada eixo-base. O **eixo-base** é paralelo ao eixo das abscissas e dispõe de valor constante no eixo das ordenadas igual ao valor da **saída** β, quando $y = f(\alpha_1,\ \alpha_2, \cdots,\ \alpha_n)$. O conjunto α de valores dos parâmetros de entrada é tomado como referência durante análise local de sensibilidade, ou seja, enquanto um parâmetro varia, os outros são mantidos fixos no seu valor-base α_j.

O método proposto compreende os seguintes passos: i) definição do caso-base α, ii) simulação ou experimentação com um parâmetro x_j variando por vez, iii) construção do **diagrama-aranha**, iv) definição do intervalo de interesse $[a, b]$ para análise, v) cálculo da área dos polígonos formados pela curva de cada parâmetro e o eixo-base no intervalo $[a, b]$ e vi) cálculo dos índices de sensibilidade $S^a_{x_j}$, dado por:

$$S^a_{x_j} = \frac{A_{x_j}}{\sum_{j=1}^{n} A_{x_j}} \tag{5.1}$$

onde $S^a_{x_j}$ é o índice de sensibilidade do parâmetro x_j dado pelo método da área, A_{x_j} é a área formada pela curva do parâmetro x_j e o eixo-base em β e n é o número de parâmetros de entrada.

O **índice de sensibilidade** $S^a_{x_j}$ representa a contribuição da área A_{x_j} em relação à área total (de todos os parâmetros). A Figura 5.1 exemplifica a delimitação da área no diagrama-aranha para cálculo dos índices $S^a_{x_j}$.

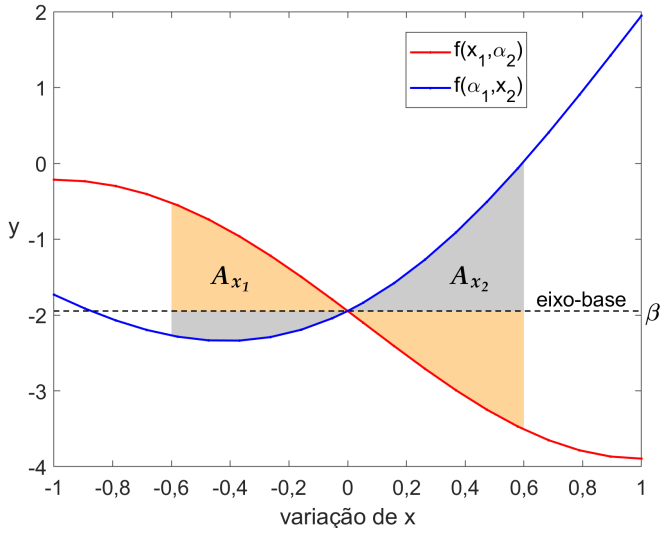

Figura 5.1 - Exemplo de delimitação da área no diagrama-aranha para análise de sensibilidade.

Na Figura 5.1, as áreas A_{x_1} (em amarelo) e A_{x_2} (em cinza) são estabelecidas com base no intervalo de interesse $[-0,6; 0,6]$ para análise, que corresponde à variação de -60% a 60% dos valores dos parâmetros de entrada a partir do respectivo valor-base. No diagrama-aranha, tanto x_1 quanto x_2 possuem dois polígonos para cálculo da área. Genericamente, cada parâmetro dispõe de quantidade de polígonos ϵ_{x_j} delimitados pela curva de x_j e o eixo-base, dado por:

$$\epsilon_{x_j} = \zeta_{x_j} + 1 \tag{5.2}$$

onde ϵ_{x_j} é o número de polígonos de x_j e ζ_{x_j} é o número de pontos de intersecções da curva do parâmetro x_j com o eixo-base para o intervalo escolhido $[a, b]$.

Por padrão, adota-se a variação dos parâmetros de entrada de -100% a $+100\%$ para analisar a sensibilidade, contudo podem existir restrições de operação do sistema que limitem a extensão da **faixa de variação dos parâmetros**. Uma vez que os índices $S^a_{x_j}$ são valores relativos em função da área, o parâmetro variado de -100% a $+100\%$ tende a ter maior área no diagrama-aranha que outro que possa ser variado apenas de -40% a $+40\%$, por exemplo. Assim, para estes casos, a análise discreta das curvas desenvolvida no método da soma das diferenças é mais representativa do efeito do parâmetro na saída do sistema que a análise contínua.

5.1.2 Método da soma das diferenças

O **método da soma das diferenças** é a adaptação do método da área com abordagem discreta, criado com o objetivo de resolver o problema de faixas distintas de variação a partir dos valores-base (GOMES et al., 2017). Os seguintes passos constituem o método da soma das diferenças: i) definição do caso-base α, ii) simulação ou experimentação com um parâmetro x_j variando por vez, iii) construção do diagrama-aranha, iv) definição do intervalo de interesse $[a, b]$ para análise, v) seleção de valores discretos da curva de cada parâmetro, vi) cálculo da soma das diferenças D_{x_j} entre os valores discretos selecionados e o valor de β no intervalo $[a, b]$ apresentado em (5.4) e vii) cálculo dos índices de sensibilidade $S^d_{x_j}$, dado por:

$$S^d_{x_j} = \frac{D_{x_j}}{\sum_{j=1}^{n} D_{x_j}} \tag{5.3}$$

onde $S^d_{x_j}$ é o índice de sensibilidade do parâmetro x_j dado pelo método da soma das diferenças, n é o número de parâmetros de entrada e D_{x_j} é a soma normalizada das diferenças entre os valores discretos da saída quando x_j é variado, dado por:

$$D_{x_j} = \frac{1}{v} \cdot \sum_{\kappa=1}^{v} \left\| y_\kappa|_{x_j} - \beta \right\| \tag{5.4}$$

Em (5.4), v é a quantidade de valores discretos da curva de variação do parâmetro x_j, $y_\kappa|_{x_j}$ é a saída do sistema dado pelo κ-ésimo valor discreto da curva tal que apenas x_j é variado e β é a saída correspondente ao caso-base α.

A transformação linear de normalização em (5.4) retira tendências em casos de quantidades distintas de valores discretos dos parâmetros, que podem corresponder a medidas experimentais. Outra solução é o tratamento dos dados antes da aplicação do método, reduzindo ou aumentando a quantidade de medidas por parâmetro para que todos tenham o mesmo valor de v. Em caso de redução do conjunto de medidas, recomenda-se que sejam retiradas as medidas com valor de saída menos impactantes. Quanto ao aumento, pode-se realizar interpolação a partir das medidas disponíveis para cada parâmetro a fim de obter novos valores de saída.

O valor do **índice de sensibilidade** $S^d_{x_j}$ em (5.3) também é normalizado e representa o efeito da variação do parâmetro x_j em relação ao efeito da variação de todos os parâmetros. Logo, a soma de todos $S^d_{x_j}$ do sistema em análise é sempre igual a 1.

No método da soma das diferenças, assume-se que a **saída possui componentes** que expressam a **contribuição de cada parâmetro de entrada**, dado por:

$$y = f(x_1, x_2, \cdots, x_n) = f(x_1) + f(x_2) + \cdots + f(x_n) + e_l \tag{5.5}$$

onde y é a saída, $x_1 \cdots x_n$ são os parâmetros de entrada e e_l é o erro de linearização.

Quando um parâmetro varia por vez e os outros permanecem fixos em seu valor-base, o efeito do parâmetro na saída pode ser medido através da diferença entre $y|_{x_j}$ e β, como observado em (5.6). Por exemplo, se apenas x_1 é variado, tem-se:

$$\begin{aligned} y|_{x_1} &= f(x_1, \alpha_2, \cdots, \alpha_n) = f(x_1) + f(\alpha_2) + \cdots + f(\alpha_n) + e_l \\ \beta &= f(\alpha_1, \alpha_2, \cdots, \alpha_n) = f(\alpha_1) + f(\alpha_2) + \cdots + f(\alpha_n) \end{aligned} \tag{5.6}$$

onde $y|_{x_1}$ é a saída do sistema tal que apenas x_1 é variado, β é a saída correspondente ao caso-base $\alpha = (\alpha_1, \alpha_2, \cdots, \alpha_n)$, $f(x_1), f(\alpha_1), f(\alpha_2), f(\alpha_n)$ são componentes da saída.

5.1.3 Método da variância condicional local

Baseado no **método da variância condicional**, propõe-se análise local de sensibilidade com $n-1$ parâmetros variados de acordo com suas distribuições probabilísticas e o parâmetro x_j mantido constante apenas no **valor-base**. Neste caso, **índice de sensibilidade** resulta da relação entre a variância da saída para x_j fixo e a variância incondicional, quando todos os parâmetros assumem valores aleatórios em seu

espaço de possibilidades, dado por:

$$S_{x_j}^{\sigma^2 *} = 1 - \frac{\sigma^2\left(Y|_{x_{\sim j}}\right)}{\sigma^2(Y)} \tag{5.7}$$

onde $S_{x_j}^{\sigma^2 *}$ é o índice de sensibilidade do parâmetro x_j dado pelo método da variância condicional local, σ^2 é a variância, Y é dado por (4.2) e $Y|_{x_{\sim j}}$ indica o vetor de saída com x_j constante e os demais parâmetros variáveis.

Como o parâmetro mais sensível é aquele que ao ser fixado causa maior redução na variância da saída, o **índice de sensibilidade** em (5.7) é o **complemento da relação entre variância condicional e incondicional**. Assim, quanto maior o índice, mais sensível é o parâmetro.

5.2 Métrica proposta de complexidade de sistemas

Com base no trabalho de Paiva (2016) e na análise de sensibilidade, a métrica proposta de complexidade de sistemas é expressa em função das conexões ativas c e de suas respectivas relevâncias de conexão γ_c, dada por:

$$\psi(c, \gamma_c) = \sum_{\kappa=1}^{\rho} \left[\gamma_{c_\kappa} - P(c_\kappa) \cdot \log_2 P(c_\kappa)\right] \tag{5.8}$$

onde $\psi(c, \gamma_c)$ é **complexidade do sistema** com base em **conexões ponderadas**, ρ é o número de conexões ativas em determinado instante, γ_{c_κ} é a relevância da κ-ésima conexão e $P(c_\kappa)$ é a probabilidade de ocorrência da κ-ésima conexão c.

A **relevância de conexão** γ_c consiste em quanto certa conexão reflete a influência dos fluxos com o ambiente (Seção 2.3.4) na organização interna do sistema. A fim de mensurar a relevância de conexão γ_c, é necessário verificar quais parâmetros de entrada tem relação direta com a conexão. Assim, pode-se calcular a relevância γ_c como a soma dos índices de sensibilidade dos parâmetros que estão diretamente relacionados com a conexão.

A Figura 5.2 ilustra o exemplo de modelo representado por grafo (organização interna), cujos parâmetros de entrada são $x_1 \cdots x_5$ e as saídas y_1 e y_2 (organização externa). Neste caso, se a conexão entre os componentes A e C está diretamente relacionada com os parâmetros x_1, x_3, x_4 e x_5, então $\gamma_{c_{AC}}$ é igual a média de S_{x_1},

S_{x_3}, S_{x_4} e S_{x_5}, obtidos pela aplicação da análise de sensibilidade.

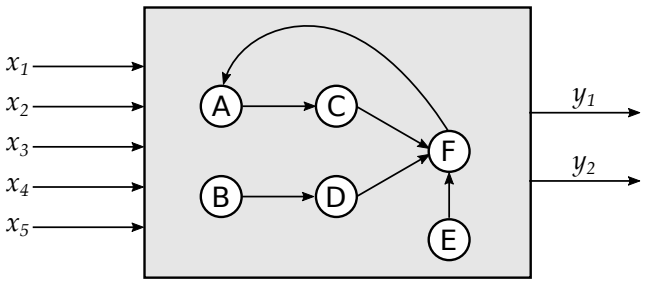

Figura 5.2 - Exemplo de modelo com cinco parâmetros de entrada e duas saídas.

A complexidade $\psi(c, \gamma_c)$ sintetiza a organização e o comportamento do sistema em **medida unificadora**, por meio das conexões ponderadas entre seus componentes nas diversas configurações assumidas durante seu funcionamento. Estas conexões são ponderadas pela sensibilidade dos parâmetros, que mapeia o comportamento do sistema dada a relação entrada-saída. Logo, **complexidade** é a **totalidade do sistema em interação**, é a capacidade de ser todo com dinâmica interna e fluxos ambientais próprios. Portanto, assim como a organização depende da estrutura, a complexidade depende da totalidade, observando o princípio de sistemidade (Seção 2.3.1).

No estudo da complexidade de sistemas, o cálculo de $\psi(c, \gamma_c)$ requer os valores da quantidade de conexões ativas ρ em cada instante e da probabilidade de conexão $P(c)$, definidos de acordo com a modelagem realizada. Em simulação a eventos discretos, ρ pode ser determinado por (3.3) e $P(c)$, por:

$$P(c) = \frac{1}{n_e \cdot (n_r + n_q)} \tag{5.9}$$

onde n_e é o número de entidades, n_r é o número de recursos e n_q é o número de filas.

Em (5.9), n_e pode ser generalizada como função $e(\upsilon)$, em que as restrições υ podem impedir a conexão entre entidades e recursos ou filas, diminuindo as possibilidades de relacionamento. A função $e(\upsilon)$ pode assumir valores no intervalo $1 \leq e(\upsilon) \leq n_e$.

5.3 Análise do sistema com base na complexidade natural

Na literatura, as medidas de complexidades têm o propósito de dizer quão complexo o sistema é com base em alguma referência. Usualmente, comparam-se sistemas de mesma natureza ou configurações distintas do mesmo sistema, a fim de afirmar que determinado sistema ou configuração é mais ou menos complexo que outro/a. Baseado na proposição filosófica de Platão de que o melhor para cada um é também o mais natural para ele, cada sistema pode exibir nível de complexidade que lhe é próprio, em que exerce sua função com alto desempenho, atingindo seu objetivo. A proposta é que este nível seja denominado **complexidade natural do sistema** ψ_n.

Quando o sistema opera no seu nível de complexidade natural, ele possui eficácia (atinge objetivo proposto) e eficiência (elevada produtividade). Logo, a complexidade natural refere-se a configurações ótimas ou otimizadas do sistema. Desta forma, ψ_n pode ser tomada como referência de operação do sistema, a fim de indicar ociosidade, atividade adequada ou sobrecarga. A Figura 5.3 ilustra o fluxo da análise e monitoramento do sistema com base na complexidade natural.

Na Figura 5.3, os passo **1** ao passo **8** compreendem todas as etapas para o cálculo da complexidade. Inicialmente, estes passos são executados com o intuito de calcular a complexidade natural ψ_n, logo, o **caso-base** α consiste em solução ótima ou otimizada para o sistema ou conjunto de valores definidos por especialista no sistema. Após o passo **8**, a sequência no fluxo da Figura 5.3 corresponde ao monitoramento do sistema em operação e tomada de decisão com base na comparação entre a complexidade vigente ψ e a complexidade natural ψ_n.

A Figura 5.3 ilustra as partes da análise do sistema com base em complexidade natural: i) modelagem ou representação do sistema (passo **1** e passo **2**), ii) análise de sensibilidade (passo **3** e passo **4**), iii) cálculo de complexidade (passo **5** ao passo **8**) e iv) monitoramento do sistema e tomada de decisão (após passo **8**). A **representação do sistema** consiste: na escolha dos parâmetros de entrada e das saídas de interesse (passo **1**) e na obtenção do modelo (passo **2**), facultativo no cálculo dos índices de sensibilidade quando as medidas são obtidas através de experimentos no sistema, porém necessário no cálculo de complexidade.

No fluxo ilustrado na Figura 5.3, a **análise de sensibilidade** corresponde a: i) definição do caso-base α (passo **3**), ou seja, os valores dos parâmetros de entrada que correspondem à presente configuração do sistema e ii) cálculo dos índices de sensibilidade S_{x_j} (passo **4**) através de análise local ou global, sendo a abordagem

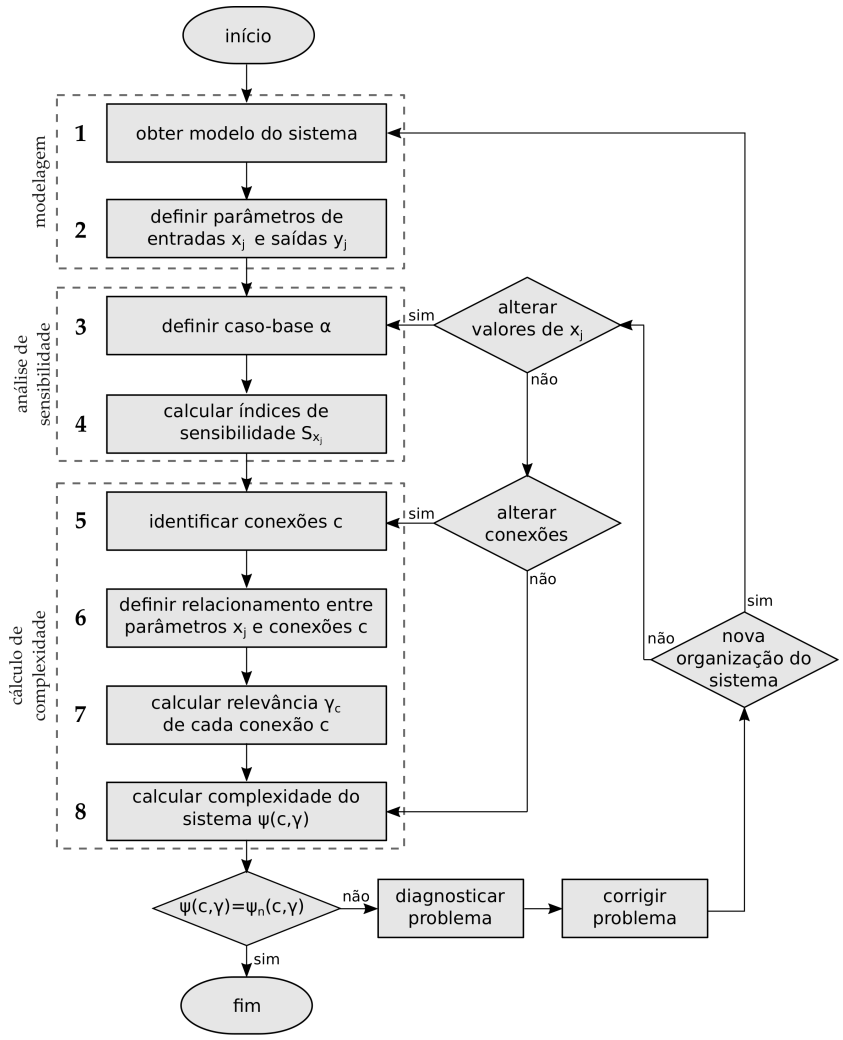

Figura 5.3 - Fluxo da análise de sistema e monitoramento com base em complexidade natural.

local recomendada para os casos de sistema em operação, pois permite verificar a sensibilidade dos parâmetros em torno do caso-base α. Entretanto, se o estudo de complexidade de sistemas basear-se na comparação de diversas configurações do sistema, representadas por cenários, recomenda-se a análise de sensibilidade global, dispensando a definição do caso-base α no passo **3**.

Os passo **5** ao passo **8** compreendem as etapas necessárias para **calcular a complexidade**, quais sejam: i) identificar conexões possíveis do sistema, que podem estar ativas em algum instante e ser relacionadas com estados das entidades como em (3.3), ii) definir relacionamento entre parâmetros x_j e conexões c, avaliando quais parâmetros exercem influência em cada conexão, iii) calcular a relevância de conexão γ_c com base no passo anterior e nos índices de sensibilidade S_{x_j} e iv) calcular a complexidade do sistema $\psi(c, \gamma_c)$, dado por (5.8).

Após calcular a complexidade do sistema, pode-se verificar se o valor obtido é igual a $\psi_n(c, \gamma_c)$. Caso seja diferente, há indicativo de problema no sistema, que pode ser diagnosticado e corrigido. A **tomada de decisão** no sentido de resolver o problema pode causar mudança no sistema quanto à organização, à configuração ou ao conjunto de conexões possíveis. Cada tipo de mudança conduz à repetição do processo a partir do: i) passo **1**, para nova organização do sistema, ii) passo **3**, para alteração nos valores dos parâmetros e iii) passo **5**, para alteração das conexões.

Na análise do sistema, a complexidade natural pode consistir em faixa de valores que representam distintas configurações em torno da solução ótima ou otimizada. Assim, ao comparar $\psi(c, \gamma_c)$ e $\psi_n(c, \gamma_c)$ (após o passo **8**), avalia-se o pertencimento de $\psi(c, \gamma_c)$ à região de $\psi_n(c, \gamma_c)$. A análise de sensibilidade local torna-se adequada, pois verifica a robustez da solução ótima ou otimizada, definida como caso-base. Desta forma, mesmo que as conexões c durante operação do sistema sejam as mesmas, as variações nos parâmetros podem afetar as relevâncias de conexão γ_c, verificado por meio de experimentos ou simulações dos modelos.

5.4 Modelos para aplicação da metodologia

A aplicação da metodologia proposta é realizada por modelos de: sistema de controle do motor de corrente contínua, unidade de terapia intensiva e sistema de desenvolvimento de *startups*. Estes modelos são escolhidos por representar casos atípicos de modelagem e simulação. No primeiro modelo, do sistema de controle, as variáveis e o tempo são contínuos, e nos outros modelos, as variáveis e o tempo são discretos.

5.4.1 Sistema do motor de corrente contínua com controlador PID

O **motor de corrente contínua** (MCC) é dispositivo eletromecânico que fornece potência mecânica de saída através de potência elétrica consumida na entrada. Embora tenha alto custo de fabricação, o uso do MCC é recomendado em situações em que se deseja variar a velocidade ou o torque (REIS, 2014). O MCC possui enrolamentos no estator (campo) e rotor (armadura) permitindo associações diversificadas (FITZGERALD et al., 2006). Desta forma, o MCC pode ser acionado através de dispositivos eletromecânicos e de dispositivos com controle automático.

No diagrama de blocos da Figura 5.4, o modelo do MCC de excitação independente é representado pela região de cor cinza. Este motor é acionado por **controlador de velocidade** de ação proporcional, integral e derivativa (PID) com sinal de controle sendo a tensão de armadura V_a. O controlador PID clássico é utilizado principal-

mente por sua simplicidade de implementação e baixo esforço computacional, como descrito em Nise (2009).

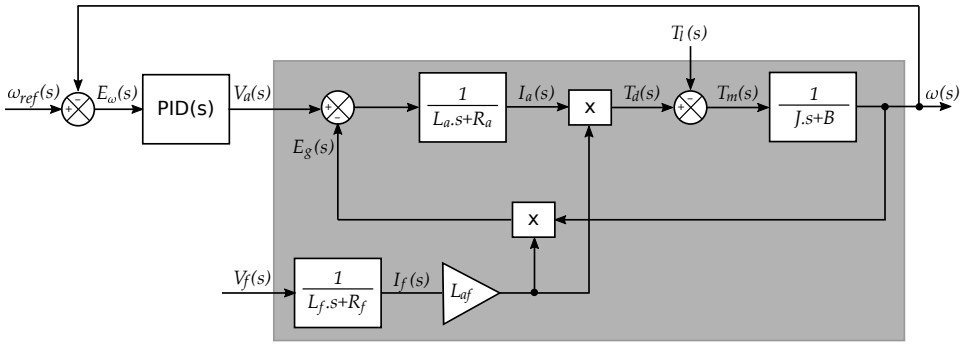

Figura 5.4 - Modelo de controle do motor de corrente contínua de excitação independente com campo variável.

Os parâmetros eletromecânicos do MCC dispostos na Figura 5.4 são: tensão de armadura V_a, resistência do circuito de armadura R_a, indutância do circuito de armadura L_a, corrente de armadura I_a, tensão de campo V_f, resistência do circuito de campo R_f, indutância do circuito de campo L_f, corrente de campo I_f, indutância mútua entre o circuito de campo e de armadura L_{af}, força eletromotriz E_g, torque desenvolvido T_d, torque da carga T_l, torque do motor T_m, momento de inércia J, constante de atrito viscoso B e velocidade angular do motor ω, modelados no domínio da frequência s como detalhado em Reis (2014). A velocidade ω é comparada com a velocidade de referência ω_{ref} para definir o erro de velocidade E_ω utilizado como entrada do controlador PID.

Para realizar a análise de sensibilidade, os **parâmetros de entrada** considerados do modelo de simulação ilustrado na Figura 5.4 são: velocidade de referência ω_{ref} $[rad/s]$, tensão de campo V_f $[V]$, ganho proporcional k_p $[V \cdot\ s/rad]$, ganho integral k_i $[V \cdot\ s/rad]$ e ganho derivativo k_d $[V \cdot\ s/rad]$ (ganhos do controlador PID). A partir de simulações, as seguintes **saídas** são analisadas: integral do módulo do erro (*Integral Absolute Error* – IAE), podendo ser representado como a qualidade do ajuste do controle de velocidade e eficiência energética η_e, que relaciona a potência mecânica de saída com a potência elétrica de entrada. A carga mecânica T_l aplicada no eixo do MCC é proporcional à velocidade ω, assim mantem-se a potência mecânica de saída fixa em qualquer velocidade.

As variáveis ω_{ref} e V_f influenciam diretamente nos valores de η_e e indiretamente nos valores do IAE, dado pela resposta de controle definida pelos ganhos k_p, k_i

e k_d. Em termos de saída do sistema, busca-se atingir maior eficiência energética η_e e menor IAE por meio de solução otimizada, ou seja, conjunto de valores das variáveis de entrada devidamente ajustados. Esta mesma análise pode ser realizada com outro tipo de controlador, por exemplo, controlador *fuzzy*, a fim de comparar a complexidade dos dois tipos de sistemas de controle do motor de corrente contínua.

5.4.2 Sistema de desenvolvimento de *startups*

Startup é organização temporária dedicada ao desenvolvimento de produtos ou serviços inovadores, formada por grupo de empreendedores que busca modelo de negócios replicável e escalável. Como as *startups* atuam em condições de extrema incerteza, existem instituições de suporte que prestam serviços, orientação, contatos e apoio na gestão das empresas nascentes, chamadas **aceleradoras**. As aceleradoras estimulam as interações das *startups* com o mercado, buscando o rápido aprendizado e as adaptações necessárias ao negócio (ROMAN, 2017).

A Figura 5.5 ilustra modelo de desenvolvimento de *startups* em aceleradora, proposto por Roman (2017), em que os projetos evoluem durante certo período de aceleração até atingir escala com vendas únicas[1] ou receitas recorrentes[2]. Neste modelo, a gestão de portfólio destaca-se como estratégia de avaliação das *startups* em desenvolvimento, a fim de classificá-las e agrupá-las de acordo com grau de maturidade. Desta forma, os gestores da aceleradora podem priorizar os investimentos nas *startups* com maior potencial de mercado e risco mitigado.

O processo de desenvolvimento de *startups* inicia-se com o diagnóstico dos empreendedores e do negócio, seguido do agrupamento das *startups* por grau de maturidade, acompanhamento e gestão de portfólio. Na fase de diagnóstico, a aceleradora observa as competências individuais dos empreendedores, capacidade técnica e coesão da equipe, além de conduzir a avaliação do negócio com base em quatro pilares: tecnologia, mercado, recursos e planejamento. **Tecnologia** refere-se à solução oferecida em algum segmento de mercado. Os esforços para inserir certa tecnologia no **mercado** dependem de recursos e de planejamento. Os **recursos** correspondem a aspectos humanos, financeiros e de infraestrutura necessários para sustentar o negócio por período significativo. De posse dos recursos, o negócio evolui a partir do **planejamento** dos objetivos e metas, bem como de ações de controle, padronizando

[1]Escala com vendas únicas refere-se a produto escalável e com base de transações mensais, porém os canais de vendas estão sendo testados e há necessidade de aumentar a receita.

[2]Escala com receita recorrente refere-se a produto escalável e com base de clientes mensais, porém há necessidade de aumentar a base de clientes.

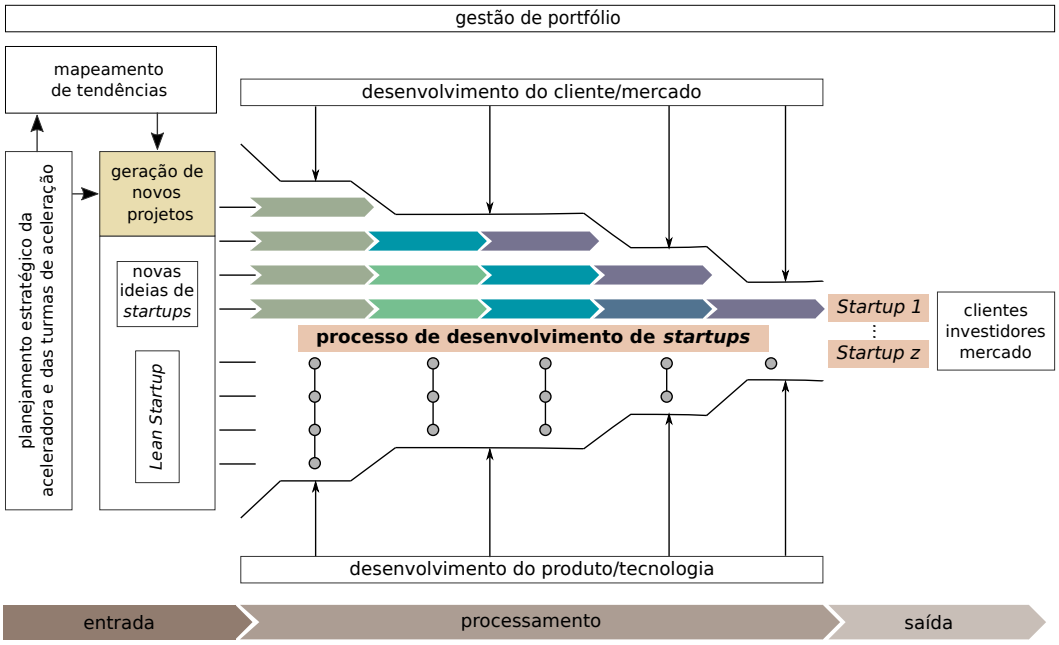

Figura 5.5 - Modelo de desenvolvimento de *startups*.

e otimizando os processos-chave. A Figura 5.6 ilustra o estágio atual (área do polígono na cor vermelha) da *startup*, que pode ser confrontado com o estágio ideal ou desejado (área do polígono na cor azul).

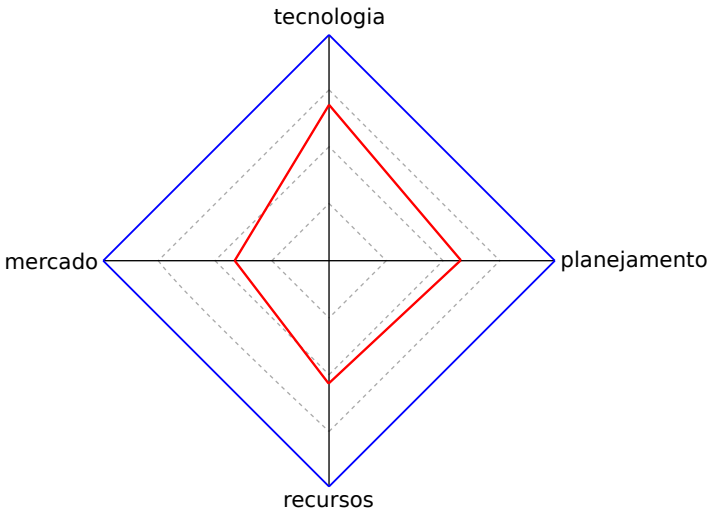

Figura 5.6 - Diagrama-radar ilustrativo dos pilares de desenvolvimento para cada *startup*.

O estudo de complexidade considera a dinâmica do sistema: *startup* e aceleradora. Durante a aceleração, três estágios definem a maturidade das *startups*: i) descoberta do cliente, ii) validação do cliente e iii) criação da base de clientes. O primeiro

estágio consiste em definir o produto viável mínimo (*Minimum Viable Product* – MVP) para atender demanda latente do mercado. O segundo estágio de validação do cliente é composto de testes de inserção do produto no mercado, que deve evoluir para formação de base mínima de clientes, quando se tem: produto desejável, tecnicamente escalável e receita operacional positiva. O terceiro estágio, criação da base de clientes, refere-se à fase do negócio em escala, com vendas únicas ou receita recorrente (ROMAN, 2017).

A aceleradora realiza integração entre *startups*, mentores e parceiros, além da gestão de portfólio no processo de prospecção, aceleração e graduação[3] das *startups*. O processo de aceleração possui ciclos de avaliação em que algumas *startups* progridem e outras não, até findar o período na aceleradora. Na Figura 5.5, observa-se o afunilamento que resulta em z *startups* preparadas para atuar de forma autônoma no mercado. Os **parâmetros de entrada** do sistema de desenvolvimento de *startups* correspondem ao perfil dos empreendedores, ao perfil das *startups*, maturidade e gestão de portfólio. A **saída** do sistema corresponde à função de avaliação que compreende relação entre os parâmetros de entrada.

5.4.3 Sistema de unidade de terapia intensiva

A **unidade de terapia intensiva** (UTI) é o ambiente hospitalar dedicado ao cuidado integral de pacientes com ou em risco de desenvolver disfunção aguda de orgãos que ameacem a vida. Este ambiente possui tecnologias capazes de atuar como suporte aos sistemas respiratório, cardiovascular e renal, somadas a atuação de profissionais da área de saúde: médicos, fisioterapeutas, enfermeiros e técnicos. A terapia intensiva, também conhecida como cuidados críticos, contribui para manter as condições fisiológicas de saúde do paciente durante o tratamento da doença subjacente (MARSHALL et al., 2017).

No cuidado crítico, entidades diversas, interligadas e interdependentes compõem sistema coeso capaz de proporcionar aos pacientes a recuperação da saúde. Estas características definem a unidade de terapia intensiva como sistema complexo cujo comportamento é determinado por regras, que podem se adaptar de acordo com a necessidade (KANNAMPALLIL et al., 2011; PAGE, 2010). Dos critérios de admissão às condições mínimas de funcionamento, as equipes multiprofissionais trabalham de maneira cooperativa e efetiva para atingir as metas relacionadas à recuperação

[3]Graduação refere-se à saída da *startup* da aceleradora, que tipicamente ocorre quando não é possível agregar mais valor à empresa, quando o espaço não é mais suficiente ou depois de determinado período de tempo (ROMAN, 2017).

de pacientes críticos ou potencialmente graves. Além dos recursos humanos, vários dispositivos, equipamentos e medicamentos são necessários na terapia intensiva, o que representa custo significativo para o gerenciamento hospitalar.

O modelo proposto de UTI abstrai características de complexidade de sistemas, como diversidade e interdependência. A diversidade é abordada com base nos recursos necessários à terapia intensiva e a interdependência é observada principalmente a partir dos casos de **eventos adversos**. Por evento adverso, entende-se qualquer dano gerado pela administração dos cuidados de saúde, resultando em hospitalização prolongada, invalidez ou morte. Além de afetar a integridade física e psicológica dos pacientes, os eventos adversos implicam em aumento dos custos de assistência médica devido a internações prolongadas e em transtornos para equipe médica, pois estima-se que um a dois terços destes eventos sejam evitáveis (RAFTER et al., 2014; ROTHSCHILD et al., 2005).

O aumento do tempo de permanência na UTI em decorrência de eventos adversos afeta a admissão de novos pacientes, devido à indisponibilidade de leitos. Usando teoria de filas e análise de sensibilidade, McManus et al. (2004) avalia o impacto da indisponibilidade de leito no desempenho da UTI em hospital pediátrico durante o período de dois anos. Com base nos dados de admissão, alta e de readmissão, os autores observam que a taxa de rejeição de pacientes aumenta exponencialmente à medida que os valores de utilização da UTI ultrapassam 85%. Este comportamento é confirmado pelos resultados fornecidos no modelo de filas, que permite predizer o desempenho do sistema a partir de mudanças no tamanho da unidade.

O modelo proposto da unidade de terapia intensiva é definido através de modelagem de sistemas a eventos discretos, em que as entidades (pacientes) demandam os recursos dos sistema (leitos, insumos e equipe médica). Em síntese, o fluxo proposto compreende a chegada do paciente, demanda de recursos, permanência do paciente na UTI até a alta e ocorrência de eventos adversos. Estas relações podem ser modeladas como conexões entre os elementos do sistema, como ilustrado na Figura 5.7.

O fluxo de pacientes no sistema de UTI inicia quando a vaga na unidade é solicitada. O paciente aguarda em fila até que os recursos estejam disponíveis e o intensivista confirme sua admissão. Se o paciente for admitido, os recursos são alocados, o paciente ocupa um leito e recebe atendimento da equipe médica. Se o paciente não for admitido, a solicitação de vaga é cancelada. Em caso de internação, o tempo de permanência na UTI é aumentado sempre que algum evento adverso ocorrer. Durante sua permanência na UTI, o paciente pode evoluir a óbito. Seja por óbito

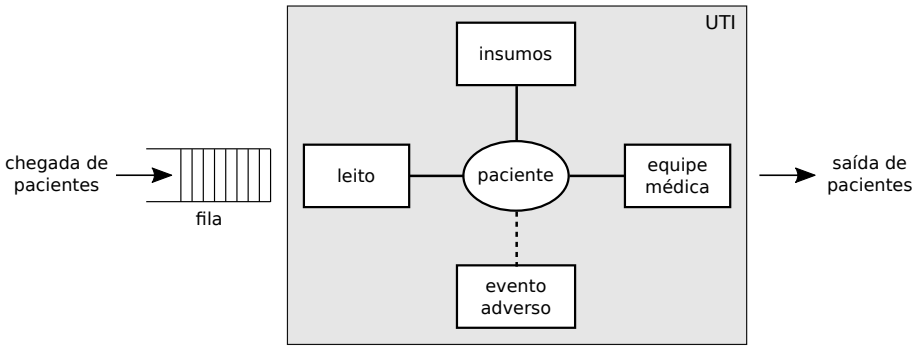

Figura 5.7 - Modelo de unidade de terapia intensiva com base em conexões.

ou recuperação, o paciente recebe alta e os recursos são desalocados, encerrando o fluxo do paciente na UTI, como ilustrado na Figura 5.8.

Considerando o fluxo de pacientes da Figura 5.8, a dinâmica do sistema é definida de acordo com distribuições de probabilidade. O sistema pode ser expresso em termos de estados e eventos. O conjunto de estados discretos dos pacientes na unidade de terapia intensiva é: i) em fila aguardando vaga, ii) em consulta com intensivista, iii) recusado à admissão, iv) internado, v) recuperado e vi) falecido. O conjunto de eventos são: i) chegada de paciente (cadastro de demanda de vaga), ii) avaliação do estado clínico do paciente, iii) recusa de admissão, iv) admissão, v) alocação de recursos, vi) ocorrência de evento adverso, vii) óbito, viii) saída de paciente (alta por óbito ou por recuperação) e ix) desalocação de recursos.

No modelo proposto, a fila de espera é considerada por prioridades. Como compete ao médico intensivista a admissão do paciente, no momento em que os recursos são disponibilizados, o paciente prioritário é avaliado pelo intensivista. A internação ou recusa à internação do paciente depende do prognóstico e do potencial benefício gerado com as intervenções terapêuticas na UTI. Os critérios de admissão e alta em unidade de terapia intensiva são estabelecidos em consonância com as orientações da Resolução nº 2.156/2016 do Conselho Federal de Medicina e de normas internacionais. Os pacientes indicados à UTI são priorizados de acordo com sua condição, como disposto na Tabela 5.1.

Os pacientes classificados como Prioridade 2 e Prioridade 4 de acordo com a Tabela 5.1 possuem alto risco de necessitar de intervenção imediata, por isto devem ser monitorados. Os pacientes avaliados como Prioridade 5 geralmente são doentes terminais, moribundos ou potenciais doadores de órgão, indicados a estar na UTI somente por especificação médica.

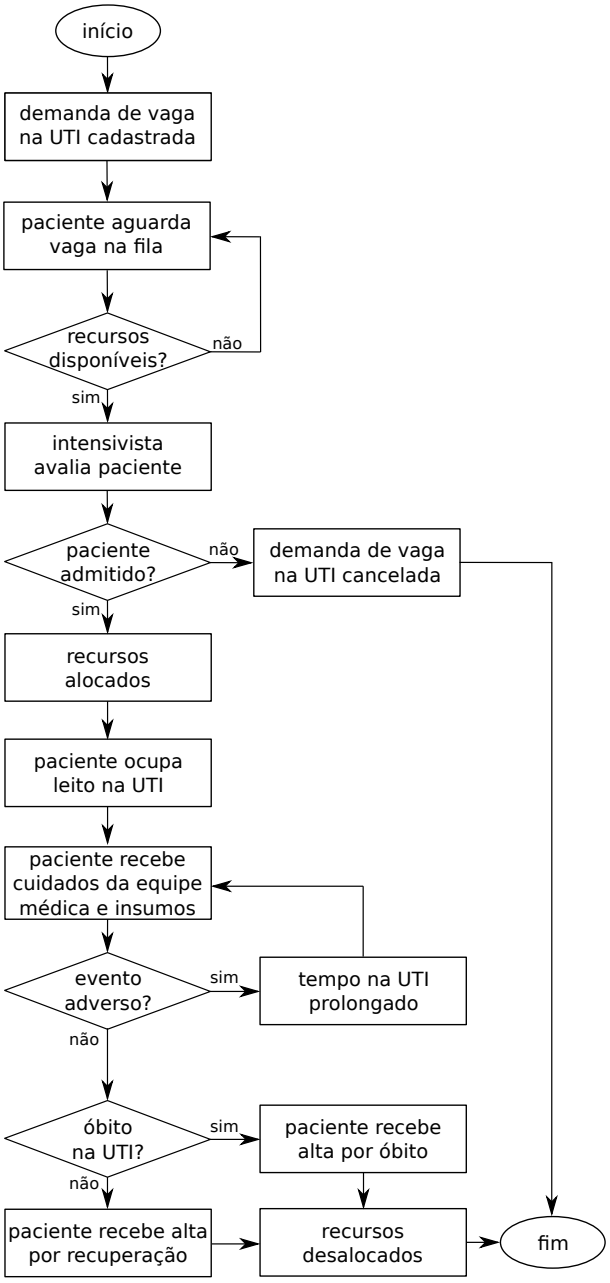

Figura 5.8 - Fluxo de pacientes em unidade de terapia intensiva.

Tabela 5.1 - Classificação de prioridade de admissão de paciente na UTI.

prioridade de admissão	probabilidade de recuperação	limitação de suporte terapêutico	necessidade de intervenção	necessidade de monitoramento
1	alta	não	sim	sim
2	alta	não	não	sim
3	baixa	sim	sim	sim
4	baixa	sim	não	sim
5	nula	sim	sim	sim

A unidade de terapia intensiva é sistema aberto em que os pacientes podem chegar à unidade a qualquer momento, de forma que o número de pacientes em fila e a utilização dos recursos variam no tempo. A métrica de desempenho deste sistema é dada pela relação entre o número de admissões n_a, tempo médio de internação t_s, número de pacientes na fila n_f e número de leitos em uso n_l. Assim, o desempenho da UTI pode ser medido por:

$$\eta_{uti} = \frac{\frac{n_a}{n_{a_{ref}}} + \frac{t_{s_{ref}} - t_s}{t_{s_{ref}}} + \frac{n_{f_{ref}} - n_f}{n_{f_{ref}}} + \frac{n_l}{n_{l_{ref}}}}{4} \tag{5.10}$$

onde as variáveis $n_{a_{ref}}$, $t_{s_{ref}}$, $n_{f_{ref}}$ e $n_{l_{ref}}$ são fixadas no valor máximo de referência das variáveis n_a, t_s, n_f e n_l, respectivamente.

Para definir os valores de referência, consideram-se as distribuições probabilísticas que determinam a dinâmica do sistema, ponderando a frequência das variáveis em análise, como prioridade dos pacientes em fila e eventos adversos.

A medida de complexidade é calculada usando (5.8) durante a simulação do modelo. Cada paciente esperando por vaga em leito da UTI acrescenta uma conexão na fila e quando internado o paciente acrescenta três conexões (uma com o leito, uma com os insumos e outra com a equipe médica). Os pacientes podem ser afetados por eventos adversos, adicionando uma conexão ao sistema.

5.5 Considerações finais

A metodologia proposta compreende métrica de complexidade de sistemas com base em análise de sensibilidade. A organização interna de cada sistema é representada pelas conexões entre seus componentes. Estas conexões são ponderadas por índices de sensibilidade, os quais refletem a organização externa do sistema. Ao observar a relação entre entradas e saída, pode-se realizar a análise de sensibilidade em torno da solução otimizada. Neste ponto, o sistema atua em seu nível de complexidade natural, em que apresenta alto desempenho na execução de sua função. No próximo capítulo são dispostos os resultados obtidos utilizando as metodologias propostas.

CAPÍTULO 6

RESULTADOS

Os resultados compreendem a aplicação e análise das metodologias propostas a três modelos distintos: motor de corrente contínua com sistema de controle PID, sistema de desenvolvimento de *startups* e sistema de unidade de terapia intensiva. Além disso, este capítulo apresenta a complexidade natural destes sistemas e a discussão do trabalho como um todo.

6.1 Análise de sensibilidade dos sistemas

A sensibilidade dos sistemas a variações nos parâmetros de entrada foi analisada por meio de métodos conhecidos na literatura e pela aplicação das métricas propostas. Os métodos tradicionais utilizados compreendem diagrama-aranha, diagrama de dispersão e método da variância condicional global. Quanto às métricas propostas, têm-se o método da área, o método da soma das diferenças e o método da variância condicional local.

O método da área e da soma das diferenças foram concebidos com base no diagrama-aranha, considerando a diferença entre as curvas e o eixo-base. Enquanto o método da soma das diferenças faz análise discreta do comportamento do sistema a variações nos parâmetros, o método da área realiza a análise contínua. O método proposto chamado de variância condicional local também foi aplicado, o qual avalia estatisticamente a sensibilidade em torno do caso-base.

Os sistemas modelados referem-se ao controle de motor de corrente contínua, à aceleradora de negócios e à unidade de terapia intensiva. O motor de corrente contínua foi simulado considerando variáveis de estado e tempo contínuos. O sistema de desenvolvimento de *startups* (SDS) ou aceleradora de negócios foi analisado analiticamente. Para a UTI, foi desenvolvido modelo de sistema a eventos discretos, em que as variáveis de estado são discretas e o tempo contínuo. Em relação a estes modelos foram definidos contextos distintos para análise de sensibilidade, que compreendem os parâmetros de entrada em questão, modelo e variáveis de saída.

6.1.1 Análise de sensibilidade do sistema do motor de corrente contínua

A análise de sensibilidade foi realizada utilizando os métodos locais (área, soma das diferenças e variância condicional local) e o método global de variância condicional. Os parâmetros escolhidos para análise foram tensão de campo V_f, ganho proporci-

onal k_p, ganho integral k_i e ganho derivativo k_d, enquanto a saída observada foi a integral do módulo do erro IAE, como apresentado na Figura 6.1.

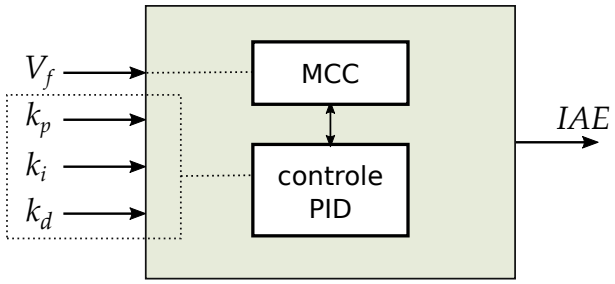

Figura 6.1 - Contexto para análise de sensibilidade do MCC com controlador PID.

A fim de analisar o sistema operando em sua **complexidade natural**, os valores-base foram definidos como **valores otimizados** dos parâmetros. Após o processo de otimização, o sistema MCC com controlador PID forneceu potência mecânica fixa com eficiência energética η_e máxima e IAE mínimo. Os parâmetros foram ajustados de acordo com os valores-base dispostos na Tabela 6.1, mantendo a velocidade angular de referência ω_{ref} em $235,35\ rad/s$.

Tabela 6.1 - Dados dos parâmetros V_f, k_p, k_i e k_d para análise de sensibilidade do MCC com controlador PID.

parâmetro	**faixa de variação**	**valor-base**
$V_f\ [V]$	$5,50 \cdot 10^{1} - 1,50 \cdot 10^{2}$	$1,16 \cdot 10^{2}$
$k_p\ [V \cdot\ s/rad]$	$1,00 \cdot 10^{-8} - 1,32 \cdot 10^{-2}$	$6,61 \cdot 10^{-3}$
$k_i\ [V \cdot\ s/rad]$	$1,00 \cdot 10^{-1} - 6,04$	$3,02$
$k_d\ [V \cdot\ s/rad]$	$0 - 9,62 \cdot 10^{-3}$	$4,81 \cdot 10^{-3}$

Para aplicar os métodos locais, primeiramente foram definidos os valores-base e as faixas de variação dos parâmetros dispostos na Tabela 6.1. A sensibilidade dos parâmetros foi analisada **visualmente** por meio de **diagrama-aranha**, em que apenas um parâmetro é variado por vez. O conjunto dos valores dos parâmetros para simulação foi definido utilizando taxa de variação de 10^{-2} a partir do valor-base.

Aplicou-se a notação de asterisco $(^*)$ sobrescrito para indicar parâmetro que se manteve fixo em seu valor-base. A curva $f(V_f, k_p^*, k_i^*, k_d^*)$, apresentada na Figura 6.2, representa a saída IAE em função dos parâmetros V_f, k_p, k_i e k_d, na qual V_f é

variável e k_p, k_i e k_d são constantes iguais a seu respectivo valor-base.

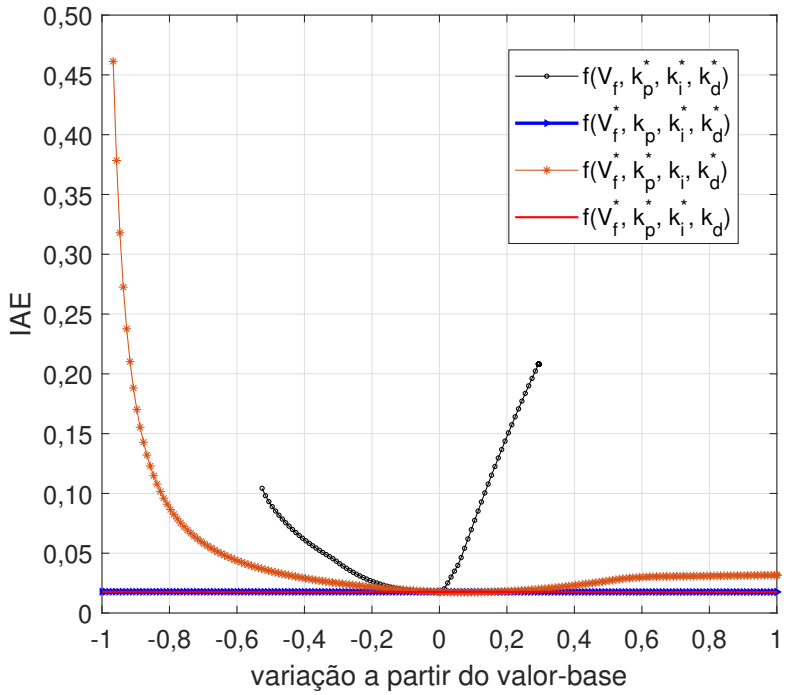

Figura 6.2 - Diagrama-aranha dos parâmetros do MCC com controlador PID referente ao caso-base otimizado $\alpha_p^0 = (1,16 \cdot 10^2;\ 6,61 \cdot 10^{-3};\ 3,02;\ 4,81 \cdot 10^{-3})$.

No diagrama-aranha da Figura 6.2, observa-se que a variação do ganho proporcional k_p e do ganho derivativo k_d no intervalo de -100% a 100% manteve a saída ($IAE = 0,018$) próxima do valor correspondente ao caso-base. O ganho integral k_i gera impacto na saída IAE quando variado, sobretudo para valores inferiores a -60% do valor-base ($k_i < 1,2V \cdot s/rad$), como apresentado pelo comportamento da curva na cor laranja. Quando a tensão de campo V_f é analisada, percebe-se sensibilidade em toda faixa de variação, de $-52,5\%$ a $29,4\%$, ou seja, valores entre $55V$ e $150V$.

Ao aplicar os **métodos estatísticos** no estudo de sensibilidade do MCC com controlador PID, analisaram-se as saídas IAE e eficiência energética η_e. Foi observado que sob certas circunstâncias, os resultados apresentavam valores inconsistentes: $IAE > 1$ e $\eta_e < 0$. Em 20.000 cenários, obtidos pela variação dos parâmetros em sua respectiva faixa, foram encontrados 611 casos de inconsistência. Para estes casos, foram verificados os valores dos parâmetros V_f, k_p, k_i e k_d como apresentado na Figura 6.3. Observou-se que a inconsistência ocorria nos casos em que a tensão de

campo $V_f < 75V$ e o ganho integral $k_i > 3,5V \cdot\ s/rad$.

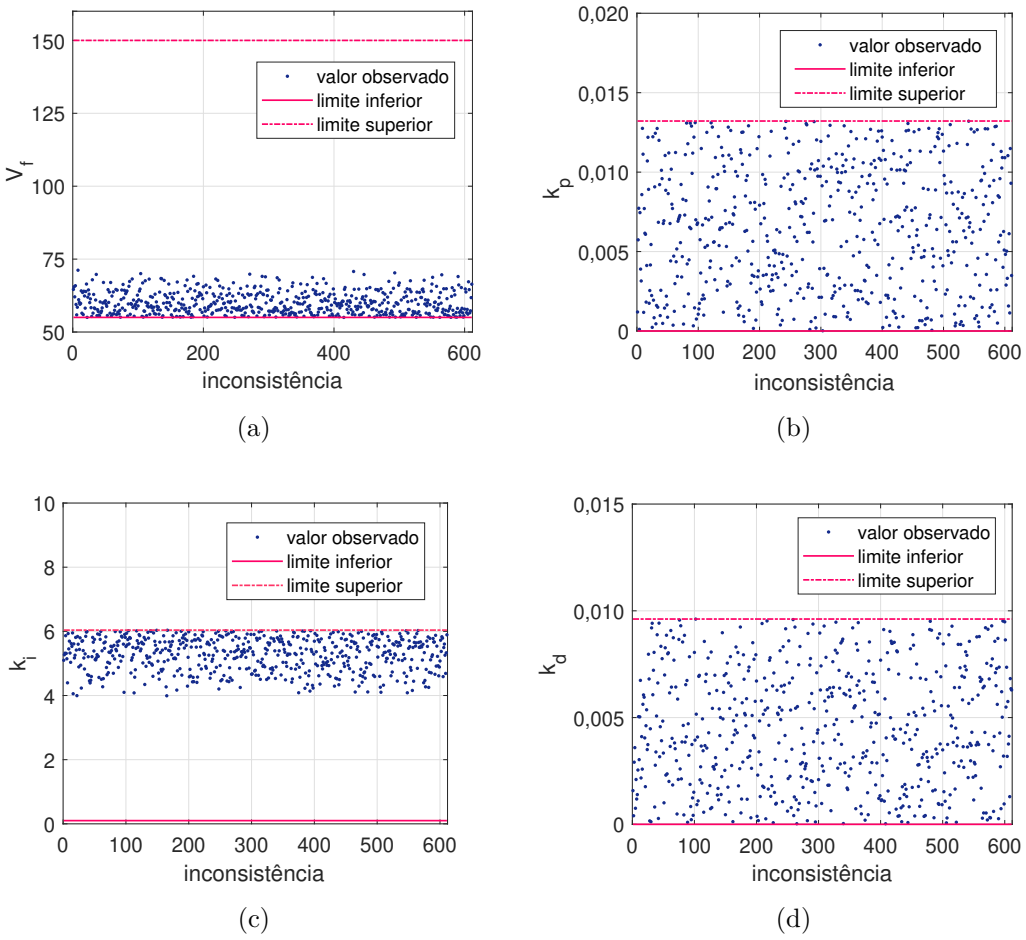

Figura 6.3 - Dispersão dos valores de entrada referente aos casos de inconsistência: (a) V_f, (b) k_p, (c) k_i e (d) k_d.

A partir da constatação de que as inconsistências ocorriam quando $V_f < 75V$ e $k_i > 3,5V \cdot\ s/rad$, decidiu-se tratar estes casos considerando tal restrição ao gerar valores aleatórios para os parâmetros V_f e k_i. Além disto, foi necessário definir o **número adequado de cenários** para aplicação dos métodos estatísticos. Foram analisados diferentes contextos de simulação como dispostos na Tabela 6.2 e na Tabela 6.3, com número de cenários variando de 50 a 50.000. A Tabela 6.2 dispõe as estatísticas da saída IAE, como média, desvio padrão, valores mínimo e máximo para os contextos de simulação. Da mesma forma, a Tabela 6.3 dispõe estas estatísticas para a saída eficiência energética η_e.

Com base nos dados dispostos na Tabela 6.2 e na Tabela 6.3, observou-se que a partir

Tabela 6.2 - Estatísticas da saída IAE para diferentes contextos de simulação.

número de cenários	média	desvio padrão	mínimo	máximo
50	$0,064$	$0,056$	$0,0191$	$0,289$
100	$0,077$	$0,057$	$0,0177$	$0,224$
500	$0,082$	$0,070$	$0,0175$	$0,489$
1.000	$0,081$	$0,067$	$0,0172$	$0,482$
3.000	$0,084$	$0,069$	$0,0171$	$0,472$
5.000	$0,084$	$0,067$	$0,0174$	$0,467$
10.000	$0,083$	$0,066$	$0,0171$	$0,517$
20.000	$0,082$	$0,066$	$0,0170$	$0,520$
50.000	$0,084$	$0,068$	$0,0170$	$0,523$

Tabela 6.3 - Estatísticas da saída eficiência energética η_e para diferentes contextos de simulação.

número de cenários	média	desvio padrão	mínimo	máximo
50	$0,9000$	$0,0278$	$0,8107$	$0,9222$
100	$0,9004$	$0,0245$	$0,7926$	$0,9219$
500	$0,8980$	$0,0305$	$0,7904$	$0,9222$
1.000	$0,8971$	$0,0301$	$0,7912$	$0,9222$
3.000	$0,8976$	$0,0298$	$0,7834$	$0,9222$
5.000	$0,8989$	$0,0292$	$0,7216$	$0,9222$
10.000	$0,8975$	$0,0303$	$0,6844$	$0,9222$
20.000	$0,8976$	$0,0302$	$0,7265$	$0,9281$
50.000	$0,8979$	$0,0301$	$0,0014$	$0,9450$

de 1.000 cenários, os valores de média variaram a partir da terceira casa decimal (saturaram), com desvio padrão aproximadamente $0,017$ para o IAE e de $0,030$ para η_e. Foi construído gráfico da média acumulada dos contextos de simulação, que corresponde à média das médias da saída do contexto em análise e dos anteriores a ele. Assim observou-se que o contexto de 10.000 cenários caracterizou o início do processo de saturação do número de cenários, como apresentado na Figura 6.4.

Com base na análise do número de cenários (Figura 6.4), decidiu-se utilizar 10.000 cenários para aplicação do método da variância condicional local em que todos os parâmetros assumiram valores aleatórios entre -100% e 100% dos valores-base, respeitando a respectiva faixa de operação (Tabela 6.1). Para aplicação do método da variância condicional global foram simulados 1.000.000 de cenários. Primeiramente, foram gerados 500 cenários com valores aleatórios dos parâmetros obtidos por distribuição uniforme, considerando a respectiva faixa de operação (Tabela 6.1). Posteriormente, para cada parâmetro, verificou-se valor aleatório com intuito de fixá-lo e gerou-se 500 cenários com os demais parâmetros variando, totalizando 250.000 cenários distintos por parâmetro.

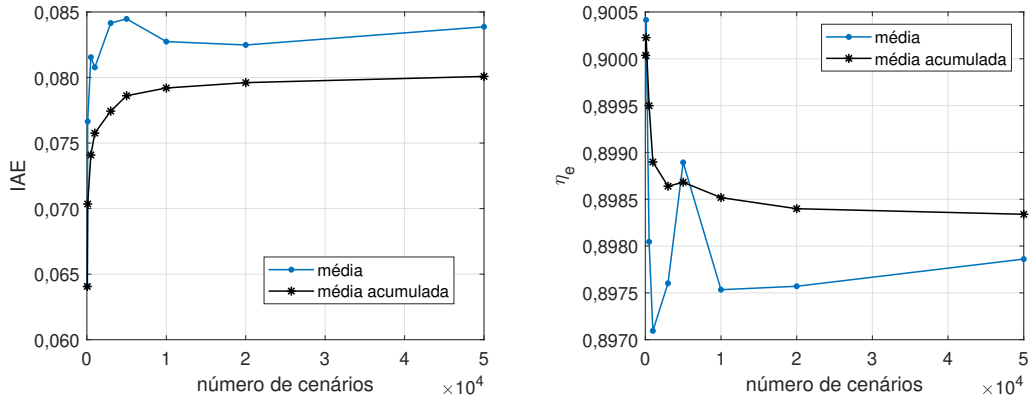

Figura 6.4 - Média e média acumulada das saídas do MCC com controlador PID × número de cenários: (a) IAE e (b) η_e.

A análise de sensibilidade utilizando o método da variância condicional local foi realizada em torno do ponto central correspondente ao cenário com os valores-base dos parâmetros. Os métodos analíticos (método da área e o da soma das diferenças) foram aplicados utilizando taxa de variação dos parâmetros de 10^{-2} a partir do valor-base, em que se variou um parâmetro por vez. Os índices de sensibilidade obtidos por todos os métodos estão dispostos na Tabela 6.4.

Tabela 6.4 - Índices de sensibilidade de V_f, k_p, k_i e k_d do MCC com controlador PID referente à saída IAE.

método	S_{V_f}	S_{k_p}	S_{k_i}	S_{k_d}
área	$0,4453$	$0,0012$	$0,5529$	$0,0006$
soma das diferenças	$0,8402$	$0,0004$	$0,1593$	$0,0001$
variância condicional local	$0,4759$	0	$0,5239$	$0,0002$
variância condicional global	$0,6453$	$0,0023$	$0,3498$	$0,0026$

Na Tabela 6.4, os índices correspondem à análise de sensibilidade de V_f, k_p, k_i e k_d para saída IAE, em que o método da área e da variância condicional local obtiveram valores semelhantes, sendo que k_i apresentou maior sensibilidade (com índices superiores a 50%) seguido de V_f (com índices entre 44% e 48%). Os métodos da soma das diferenças e da variância condicional global indicaram a tensão de campo V_f como o parâmetro mais sensível, com índice igual $84,02\%$ e $64,53\%$, seguido do ganho integral k_i, com índice igual $15,93\%$ e $34,98\%$, respectivamente.

O resultado da simulação para aplicação do método da variância condicional local

é apresentado na Figura 6.5. Inicialmente foram gerados valores aleatórios para os parâmetros a fim de compor 10.000 cenários, representados por $\times$ na cor cinza na Figura 6.5. Estes cenários foram alterados em quatro distintos contextos, fixando um parâmetro por vez.

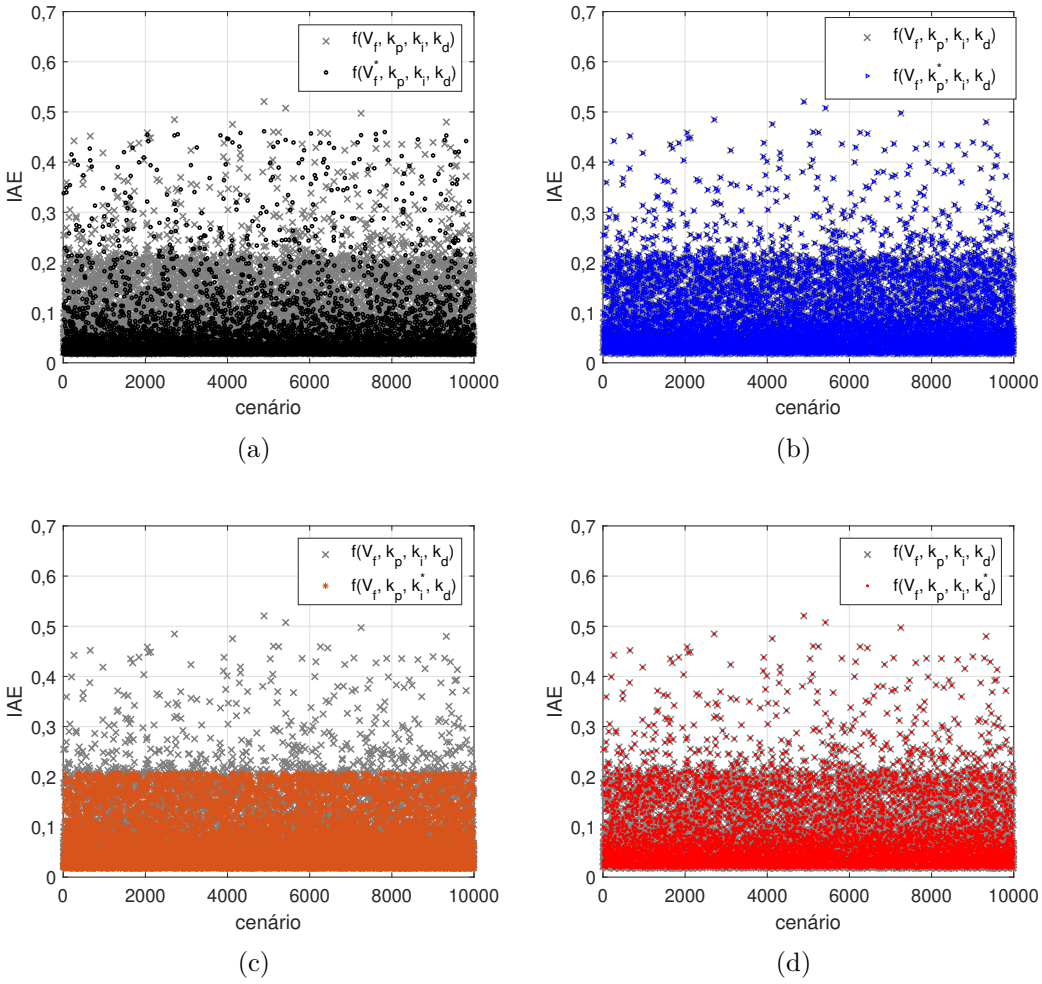

Figura 6.5 - Cenários do MCC com controlador PID para aplicação do método da variância local: (a) $V_f^* = 1,16 \cdot 10^2 V$, (b) $k_p^* = 6,61 \cdot 10^{-3} V \cdot s/rad$, (c) $k_i^* = 3,02 V \cdot s/rad$ e (d) $k_d^* = 4,81 \cdot 10^{-3} V \cdot s/rad$.

Observa-se na Figura 6.5(b) e na Figura 6.5(d) que ao fixar k_p e k_d, respectivamente, o valor da saída IAE mantém-se próximo do valor expresso por $\times$ na cor cinza (em que todos os parâmetros eram variáveis). Diferentemente, o ganho integral k_i ao ser fixado limitou o IAE a aproximadamente $0,2$, observado nos asteriscos na cor laranja da Figura 6.5(c). A tensão de campo V_f ao ser fixada também alterou a saída IAE, indicado pelos círculos na cor preta da Figura 6.5(a).

Esta análise gráfica corrobora a afirmação de que os parâmetros mais sensíveis são aqueles que ao ser fixados geram maior redução da variabilidade da saída. Ainda **visualmente**, pode-se observar a correlação entre estes parâmetros e a saída nos **diagramas de dispersão** apresentados na Figura 6.6. Os parâmetros V_f na Figura 6.6(a) e k_i na Figura 6.6(c) apresentaram formas específicas no diagrama de dispersão, que indicam maior correlação entre entrada e saída.

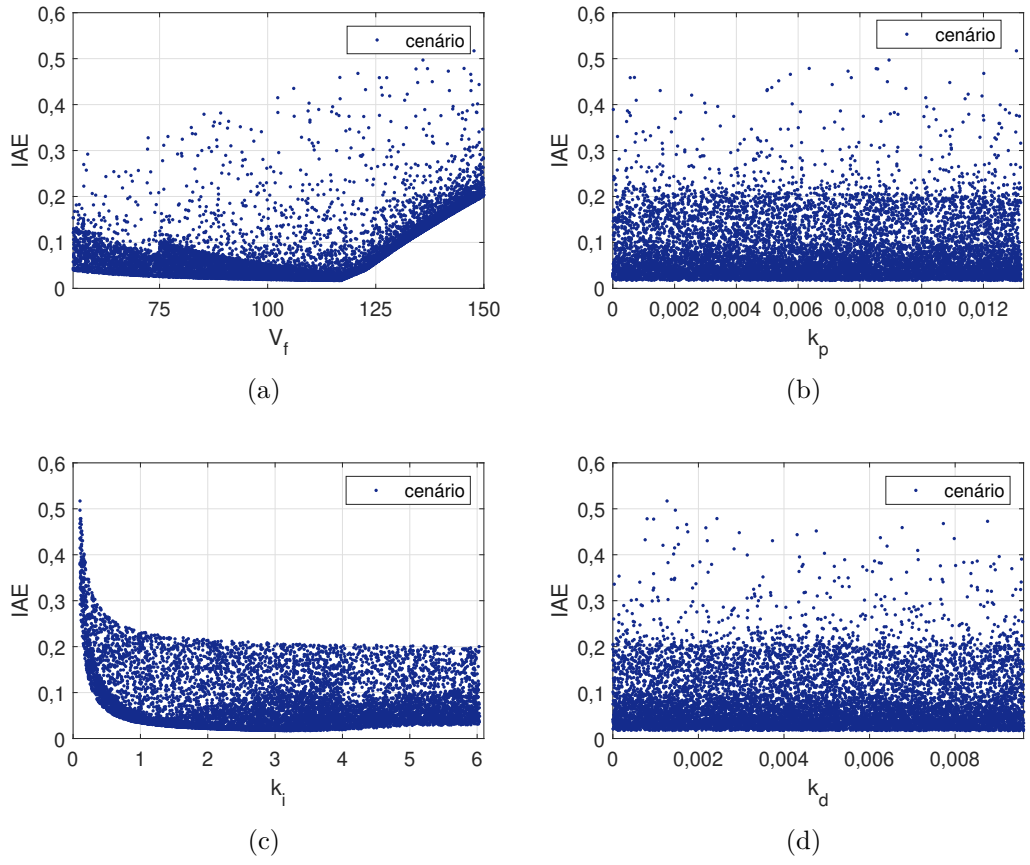

Figura 6.6 - Diagrama de dispersão para os parâmetros: (a) V_f, (b) k_p, (c) k_i e (d) k_d.

Com o intuito de verificar a sensibilidade dos parâmetros localmente para casos-base não otimizados, foram escolhidos dois contextos para investigação: i) caso-base correspondente ao valor otimizado reduzido em 40% e ii) caso-base correspondente ao valor otimizado acrescido em 40%. Assim, a partir do caso-base otimizado $\alpha_p^0 = (1,16{\cdot}10^2;\ 6,61{\cdot}10^{-3};\ 3,02;\ 4,81{\cdot}10^{-3})$ foram gerados os casos-base não otimizados: $\alpha_p^{-40\%} = (6,95 \cdot 10^1;\ 3,96 \cdot 10^{-3};\ 1,81;\ 2,88 \cdot 10^{-3})$ e $\alpha_p^{+40\%} = (1,50 \cdot 10^2;\ 9,25 \cdot 10^{-3};\ 4,23;\ 6,73{\cdot}10^{-3})$. Os diagramas-aranha destes dois contextos são apresentados na Figura 6.7.

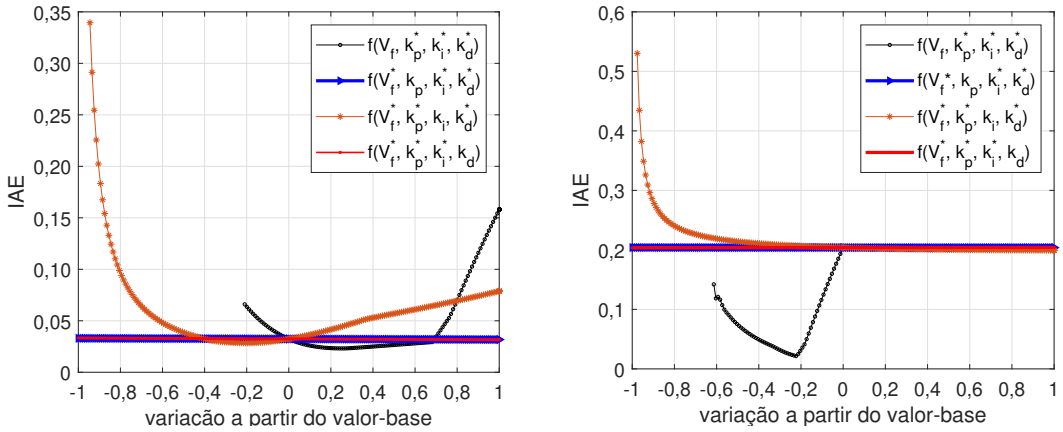

Figura 6.7 - Diagrama-aranha dos parâmetros do MCC com controlador PID referente a casos-base não otimizados: (a) $\alpha_p^{-40\%}$ e (b) $\alpha_p^{+40\%}$.

Os parâmetros k_p e k_d permaneceram menos sensíveis, aproximadamente igual ao IAE dos casos-base: $IAE = 0,03$ correspondente a $\alpha_p^{-40\%}$ na Figura 6.7(a) e $IAE = 0,2$ correspondente a $\alpha_p^{+40\%}$ na Figura 6.7(b). Em termos de desempenho do sistema, verifica-se que em ambos os casos houve prejuízo quanto ao controle de velocidade angular do motor comparado ao valor otimizado, $IAE = 0,018$ para α_p^0. Entretanto, no caso de acréscimo $(+40\%)$ o IAE obteve valor $11\times$ maior, enquanto no caso de redução (-40%) do valor dos parâmetros, o IAE foi $1,7\times$ maior que IAE correspondente a α_p^0.

Na Figura 6.7, verifica-se que a tensão de campo V_f e o ganho integral k_i geraram impacto considerável na saída quando variados, o que indica maior sensibilidade destes parâmetros, confirmada pelos valores dos índices dispostos na Tabela 6.5 e na Tabela 6.6.

Tabela 6.5 - Índices de sensibilidade de V_f, k_p, k_i e k_d do MCC com controlador PID referente à saída IAE com $\alpha_p^{-40\%}$.

método	S_{V_f}	S_{k_p}	S_{k_i}	S_{k_d}
área	0,3203	0,0076	0,6618	0,0103
soma das diferenças	0,6817	0,0033	0,3104	0,0046
variância condicional local	0,4666	0	0,5334	0

Com base no conhecimento de especialista, foram escolhidos mais dois contextos de análise em relação ao valor otimizado como caso-base. Em um contexto, foram

Tabela 6.6 - Índices de sensibilidade de V_f, k_p, k_i e k_d do MCC com controlador PID referente à saída IAE com $\alpha_p^{+40\%}$.

método	S_{V_f}	S_{k_p}	S_{k_i}	S_{k_d}
área	$0,7401$	$0,0005$	$0,2576$	$0,0018$
soma das diferenças	$0,8944$	$0,0002$	$0,1047$	$0,0007$
variância condicional local	$0,5916$	$0,0004$	$0,4062$	$0,0018$

analisados os parâmetros k_p, k_i e k_d para saída IAE e em outro contexto, foram analisados os parâmetros ω_{ref} e V_f para saída η_e, como apresentado na Figura 6.8. Para aplicar os métodos locais, primeiramente foram definidos os valores-base dos parâmetros, como disposto na Tabela 6.7 e na Tabela 6.8. Em seguida, foram gerados os diagramas-aranha destes contextos, como apresentados na Figura 6.9.

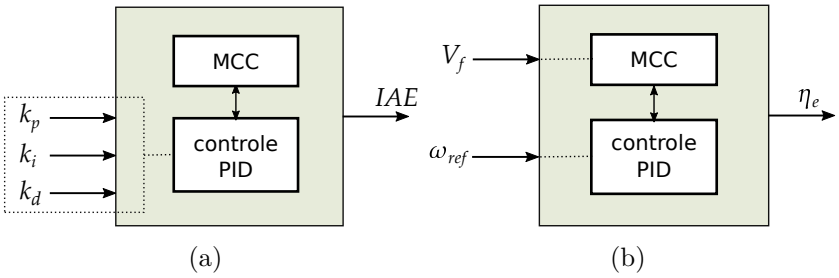

Figura 6.8 - Contextos para análise da sensibilidade do MCC com controlador PID para os parâmetros: (a) entrada k_p, k_i e k_d saída $\longrightarrow IAE$ e (b) entrada ω_{ref} e V_f saída $\longrightarrow \eta_e$.

Tabela 6.7 - Dados dos parâmetros k_p, k_i e k_d para análise de sensibilidade do MCC com controlador PID.

parâmetro	**faixa de variação**	**valor-base**
$k_p\ [V \cdot\ s/rad]$	$1,00 \cdot 10^{-8} - 1,32 \cdot 10^{-2}$	$6,61 \cdot 10^{-3}$
$k_i\ [V \cdot\ s/rad]$	$1,00 \cdot 10^{-1} - 6,04$	$3,02$
$k_d\ [V \cdot\ s/rad]$	$0 - 9,62 \cdot 10^{-3}$	$4,81 \cdot 10^{-3}$

Tabela 6.8 - Dados dos parâmetros ω_{ref} e V_f para análise de sensibilidade do MCC com controlador PID.

parâmetro	**faixa de variação**	**valor-base**
$\omega_{ref}\ [rad/s]$	$110 - 360$	$235,35$
$V_f\ [V]$	$55 - 150$	$115,92$

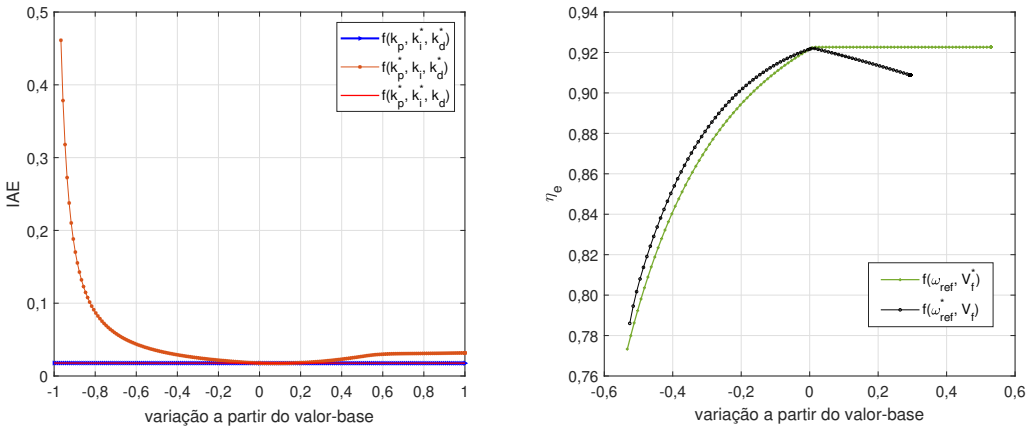

(a) (b)

Figura 6.9 - Diagrama-aranha dos parâmetros do MCC com controlador PID referente a caso-base otimizado: (a) $\alpha^0_{p_a} = (6,61 \cdot 10^{-3};\ 3,02;\ 4,81 \cdot 10^{-3})$ e (b) $\alpha^0_{p_b} = (2,35 \cdot 10^2;\ 1,16 \cdot 10^2)$.

Considerando a saída IAE (integral do módulo do erro), foram analisados os ganhos k_p, k_i e k_d por meio do diagrama-aranha da Figura 6.9(a), enquanto a velocidade angular de referência ω_{ref} e a tensão de campo V_f foram mantidas constantes no valor otimizado, $V_f = 115,92V$ e $\omega_{ref} = 235,35rad/s$. A Tabela 6.9 dispõe valores aproximadamente igual a um para k_i, ou seja, o aporte deste parâmetro quanto à variabilidade da saída IAE é praticamente total nesse contexto de análise.

Quanto à saída η_e (eficiência energética), foram mantidos constantes no valor otimizado os ganhos k_p, k_i e k_d, igual a $6,61 \cdot 10^{-3};\ 3,02;\ 4,81 \cdot 10^{-3}\ V \cdot\ s/rad$, respectivamente, a fim de analisar a resposta à variação de ω_{ref} e V_f. Verificou-se que a variação da velocidade angular de referência ω_{ref} e da tensão de campo V_f geraram impacto na saída. Ambas apresentaram sensibilidade considerável quando estes parâmetros assumiram valores inferiores ao seu respectivo valor-base. Para valores acima do valor-base, apenas a variação em V_f ocasionou decréscimo no valor da eficiência energética η_e, de $92,2\%$ para $90,9\%$.

Tabela 6.9 - Índices de sensibilidade de k_p, k_i e k_d do MCC com controlador PID referente à saída IAE.

método	S_{k_p}	S_{k_i}	S_{k_d}
área	0,0022	0,9968	0,0010
soma das diferenças	0,0022	0,9969	0,0009
variância condicional local	0	1,0000	0

O estudo realizado em relação à saída eficiência energética η_e permitiu analisar a sensibilidade da velocidade angular de referência ω_{ref} para o controle do sistema, juntamente com a tensão de campo V_f. Os índices obtidos estão dispostos na Tabela 6.10. De acordo com o método estatístico (da variância condicional local), pode-se observar que os dois parâmetros são igualmente sensíveis, índices iguais a 50%. Por meio da aplicação dos métodos analíticos, ambos parâmetros apresentaram índices de sensibilidade superiores a 40%, alternando a predominância da influência de ω_{ref} (pelo método da área) para V_f (pelo método da soma das diferenças).

Tabela 6.10 - Índices de sensibilidade de ω_{ref} e V_f do MCC com controlador PID referente à saída η_e.

método	$S_{\omega_{ref}}$	S_{V_f}
área	$0,5373$	$0,4627$
soma das diferenças	$0,4237$	$0,5763$
variância condicional local	$0,5000$	$0,5000$

Os dados da Tabela 6.10 podem ser melhor compreendidos pela análise do diagrama-aranha da Figura 6.9(b), em que o impacto nos valores de saída é expressivo para cenários em que os parâmetros possuem valores inferiores ao respectivo valor-base, ou seja, $\omega_{ref} < 235,35 rad/s$ e $V_f < 115,92 V$.

6.1.2 Análise de sensibilidade do sistema de desenvolvimento de *startups*

A sensibilidade do sistema de desenvolvimento de *startups* (SDS), também chamado aceleradora de negócios, foi analisada utilizando abordagem local e global. Os **parâmetros de entrada** estudados foram perfil dos empreendedores p_e, perfil das *startups* p_e, grau de maturidade e gestão de portfólio g_p. O grau de maturidade foi decomposto em duas variáveis: desempenho η_s e nota da banca de *pitch*[1] p_{ch}, obtidos ao final de cada mês. A **saída** do sistema foi mensurada por função de avaliação f_{aval} definida como a média ponderada dos parâmetros de entrada, de acordo com o contexto para análise, apresentado na Figura 6.10.

Os valores dos parâmetros foram gerados aleatoriamente por distribuição uniforme, em que o valor máximo de cada parâmetro correspondeu ao valor otimizado $\alpha_s = (6;\ 32;\ 1;\ 1;\ 60)$ e o valor mínimo foi igual a zero. Em situação real, os valores dos parâmetros são obtidos por metodologia proposta por Roman (2017), com base

[1] *Pitch* é apresentação sumária de 3 minutos a 5 minutos com objetivo de despertar o interesse da outra parte (investidor ou cliente) pelo negócio, em que se apresenta a oportunidade, o mercado, a solução, seus diferenciais e o que se está buscando (SPINA, 2012).

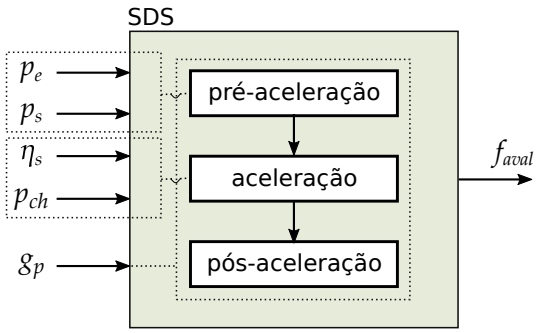

Figura 6.10 - Contexto para análise de sensibilidade do sistema de desenvolvimento de *startups*.

em questionários e na evolução da *startup* em relação a si e a demais *startups* da aceleradora.

O parâmetro grau de maturidade foi definido como a raiz quadrada da soma dos quadrados das variáveis desempenho e nota do *pitch*, consistindo na distância entre a origem $(0, 0)$ e o ponto que caracteriza a maturidade de cada empresa, de acordo com a Figura 6.11, adaptada de Roman (2017). As áreas na cor vermelha, cor amarela e cor verde indicam desempenho insatisfatório, regular e satisfatório, respectivamente. Para cálculo da função de avaliação, o grau de maturidade foi moderado pelos seguintes pesos: $0,15$ para área na cor vermelha, $0,30$ para a área na cor amarela e $0,55$ para área na cor verde.

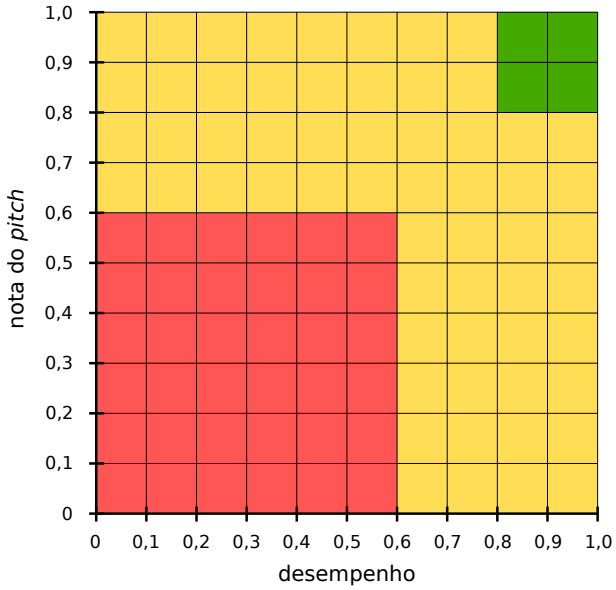

Figura 6.11 - Quadro de gestão à vista para as *startups* em aceleração.

O parâmetro gestão de portfólio foi moderado com pesos: $0,70$ para o Grupo A, $0,25$ para o Grupo B e $0,05$ para o Grupo C. As notas obtidas por meio da metodologia de gestão de portfólio > 48 definem o Grupo A, ≥ 36 e ≤ 48, o Grupo B e < 36, o Grupo C. De acordo com Roman (2017), as *startups* de maior potencial para aceleradora e com alta perspectiva de retorno pertencem ao Grupo A. No Grupo B estão as empresas com dificuldade de desenvolvimento, apesar de terem demonstrado potencial inicialmente. O Grupo C é composto por *startups* com elevada probabilidade de fracasso. Os critérios de avaliação para gerir o portfólio da aceleradora englobam equipe, tecnologia, mercado, finanças, estratégia, regulação e risco.

A partir do modelo, foi possível calcular os índices de sensibilidade utilizando métodos locais e global. Para aplicação dos métodos locais, o valor-base dos parâmetros foi definido como valor otimizado, dispostos na Tabela 6.11.

Tabela 6.11 - Dados dos parâmetros para análise de sensibilidade do sistema de desenvolvimento de *startups*.

parâmetro	**faixa de variação**	**valor-base**
p_e	$0-6$	6
p_s	$0-32$	32
η_s	$0-1$	1
p_{ch}	$0-1$	1
g_p	$0-60$	60

Os valores dos índices de sensibilidade calculados estão dispostos na Tabela 6.12. A abordagem local também foi representada visualmente por diagrama-aranha na Figura 6.12. O método da área e da soma das diferenças apresentaram resultados próximos: o índice de sensibilidade dos parâmetros perfil dos empreendedores p_e e perfil das *startups* p_s foi aproximadamente 19%, dos parâmetros desempenho η_s e *pitch* p_{ch}, 17% e do parâmetro gestão de portfólio g_p, 28%. Estes resultados são apresentados no diagrama-aranha da Figura 6.12, em que g_p é o parâmetro mais sensível, p_e e p_s possuem curvas sobrepostas, da mesma forma que η_s e p_{ch}.

Tabela 6.12 - Índices de sensibilidade de p_e, p_s, η_s, p_{ch} e g_p do sistema de desenvolvimento de *startups*.

método	S_{p_e}	S_{p_s}	S_{η_s}	$S_{p_{ch}}$	S_{g_p}
área	$0,1935$	$0,1935$	$0,1659$	$0,1659$	$0,2811$
soma das diferenças	$0,1991$	$0,1813$	$0,1717$	$0,1717$	$0,2762$
variância condicional local	$0,3844$	$0,2358$	$0,0033$	0	$0,3765$
variância condicional global	$0,2981$	$0,2485$	$0,0496$	$0,0506$	$0,3532$

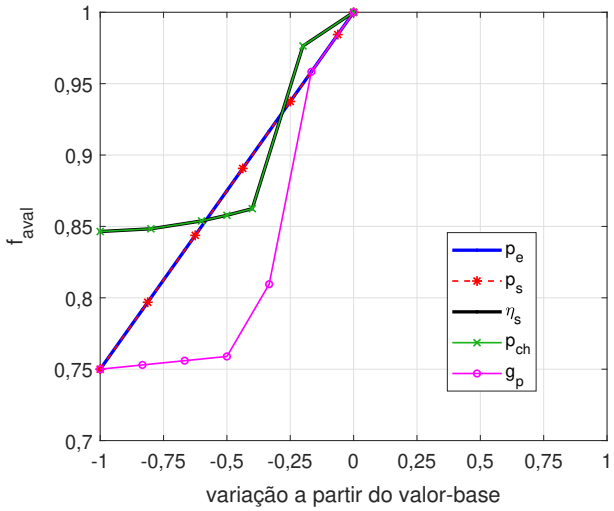

Figura 6.12 - Diagrama-aranha dos parâmetros do sistema de desenvolvimento de *startups*.

Utilizando o método da variância condicional local e global, o parâmetro gestão de portfólio g_p ainda obteve o maior índice, superior a 35%. Contudo o grau de maturidade obteve valores próximos de *zero*, tanto para desempenho η_s quanto para o *pitch* p_{ch}. O segundo parâmetro mais sensível foi o perfil dos empreendedores p_e, seguido do perfil das *startups* p_s. Estes resultados podem ser explicados, pois o sucesso da aceleradora depende da qualidade das empresas quando entram no processo de aceleração, observada pelo perfil dos empreendedores e pelo perfil das *startups*, e quando saem, observada pela gestão de portfólio.

6.1.3 Análise de sensibilidade do sistema de unidade de terapia intensiva

O modelo de unidade de terapia intensiva apresenta as principais conexões entre os elementos do sistema, em que o paciente estabelece uma conexão quando está na fila (com o próximo paciente ou com o médico intensivista no momento da admissão) e quatro conexões na UTI, com o leito, os insumos, a equipe médica e os eventos adversos (se ocorrer). A fim de realizar a simulação, estimou-se primeiramente o caso otimizado em que a estrutura disponível atende à demanda de serviços satisfatoriamente e a taxa de eventos adversos tende à taxa dos casos não-evitáveis.

A demanda de atendimento foi estimada empiricamente e corresponde à taxa de chegada de pacientes representada por distribuição normal com média de 36 horas e desvio padrão de 4 horas, $N(36, 4)$. Os pacientes que demandaram vagas na UTI foram classificados por prioridade, sendo: 35% Prioridade 1, 50% Prioridade 2, 7%

Prioridade 3, 7% Prioridade 4 e 1% Prioridade 5. A fila de espera foi do tipo FIFO (*first in, first out*), condicionada à ordenação por prioridade: de 1 a 5, do início ao fim da fila, respectivamente.

Quanto aos recursos, a configuração da UTI consistiu em 10 leitos, 100% do estoque de insumos (equipamentos e medicação) e 100% da carga de trabalho da equipe médica, com margem para acréscimo de 5%, considerando casos em que o profissional necessita estender sua jornada de trabalho, por exemplo: reanimação cardíaca próxima da mudança de turno. A taxa de recusa à admissão foi fixada em 10%. Para cada paciente admitido, foram alocados: um leito, de 6% a 12% do total de insumos e de 6% a 12% da carga horária da equipe médica, seguindo distribuição uniforme $U(6, 12)$ para insumos e equipe. O tempo médio de permanência na UTI, em dias, foi definido de acordo com a prioridade do paciente (CALDEIRA et al., 2010) seguindo distribuição normal igual a: $N(8, 3)$ para Prioridade 1, $N(5, 2)$ para Prioridade 2, $N(7, 1)$ para Prioridade 3, $N(7, 1)$ para Prioridade 4 e $N(30, 7)$ para Prioridade 5.

Com base na literatura médica (ROTHSCHILD et al., 2005; FORSTER et al., 2008; RAFTER et al., 2014), a taxa de eventos adversos foi definida em 12%, abrangendo os eventos não-evitáveis e evitáveis. Para cada ocorrência de evento adverso, o tempo de permanência do paciente foi acrescido de período entre 15 e 45 dias, representado por distribuição uniforme $U(15, 45)$. Independente da ocorrência de evento adverso, a taxa de óbito na UTI foi definida em 20%. A saída do paciente refere-se à alta por recuperação ou por óbito, situações em que os recursos reservados para o paciente são desalocados. Para os casos de recusa à admissão, o paciente sai do sistema antes de adentrar à sala da UTI. Para os casos em que os pacientes recebem os cuidados intensivos, ao deixar a UTI eles podem ser classificados como: i) recuperado sem histórico de evento adverso, ii) falecido sem histórico de evento adverso, iii) recuperado com histórico de evento adverso e iv) falecido com histórico de evento adverso.

Para medir o desempenho do sistema, foi desenvolvida métrica que relaciona número de admissões n_a, tempo de internação t_s, número de pacientes na fila n_f e número de leitos em uso n_l, dado por (5.10). Os valores das variáveis de referência $n_{a_{ref}}$, $t_{s_{ref}}$, $n_{f_{ref}}$ e $n_{l_{ref}}$ presentes em (5.10) foram determinados por análise do valor máximo que cada variável pode assumir.

Primeiramente, calculou-se a distribuição do tempo de permanência que representasse todos os pacientes ponderando os valores de média e desvio padrão de acordo com a prioridade do paciente, o que resultou em média de $6,58$ dias na UTI com

desvio padrão médio de $2,26$ dias. Assim assumiu-se que o tempo máximo é igual à média acrescida de três desvios, ou seja, aproximadamente 14 dias. Como 12% dos pacientes sofrem eventos adversos e seu tempo na UTI aumenta em média 30 dias, o tempo máximo foi recalculado, tendo em vista que 88% do total de pacientes permaneceriam internados 14 dias e 12% dos pacientes ficariam na UTI cerca de 44 dias, resultando em tempo máximo médio de $17,6$ dias.

Em seguida, o tamanho máximo da fila foi calculado, considerando taxas de chegada críticas, quais sejam: $N(4,4)$, $N(6,4)$ e $N(12,4)$. A média das médias dessas taxas de chegada resultou em $7,33h$, o que corresponderia à chegada de $3,27$ pacientes por dia em média e aproximadamente 1194 pacientes por ano (período simulado). Se fosse atendido número mínimo de pacientes durante o ano, ou seja, quando o tempo de permanência fosse máximo, o total de pacientes que entraria na UTI seria $207,4$, logo o tamanho máximo da fila seria aproximadamente 990 pacientes.

Para calcular o número máximo de pacientes admitidos, considerou-se o tempo de permanência médio, após ponderação para todas prioridades, $N(6,58; 2,26)$. Aplicando a ponderação dos pacientes acometidos por eventos adversos, tem-se: 88% do total de pacientes admitidos ficariam em média $6,58$ dias na UTI e 12% ficariam em média $36,58$ dias na UTI, assim o tempo de permanência médio seria igual a $10,18$ dias. Em um ano, seriam admitidos 360 pacientes aproximadamente na UTI com 10 leitos.

Quanto à referência para quantidade máxima de leitos em uso, adotou-se 85% do total de leitos, a fim de manter a disponibilidade de leitos dentro da faixa esperada para UTI de acordo com McManus et al. (2004). Como a UTI modelada dispõe de 10 leitos, sempre que a média de leitos em uso exceder $8,5$, o numerador da quarta parcela da métrica de desempenho é dado por (6.1), de forma que situações de lotação da UTI sejam penalizadas. Por se tratar de sistema de urgência, é importante que a UTI funcione com margem para receber paciente em estado crítico, fornecendo as condições necessárias para que sua saúde seja restabelecida.

$$\begin{cases} n_l & se \quad n_l < 8,5 \\ n_{l_{ref}} - 5 \cdot (n_l - n_{l_{ref}}) & se \quad n_l \geq 8,5 \end{cases} \tag{6.1}$$

Após a definição das distribuições probabilísticas e dos valores de referência para cálculo do desempenho do sistema, procedeu-se ao estudo de sensibilidade dos parâmetros da UTI: número de leitos n_{leitos}, percentual de insumos $n_{insumos}$, percentual

de equipe médica n_{equipe}, taxa de eventos adversos tx_{ea} e média da taxa de chegada $\mu_{chegada}$ (referente à distribuição normal com desvio padrão igual a 4 horas). O contexto de análise é apresentado na Figura 6.13.

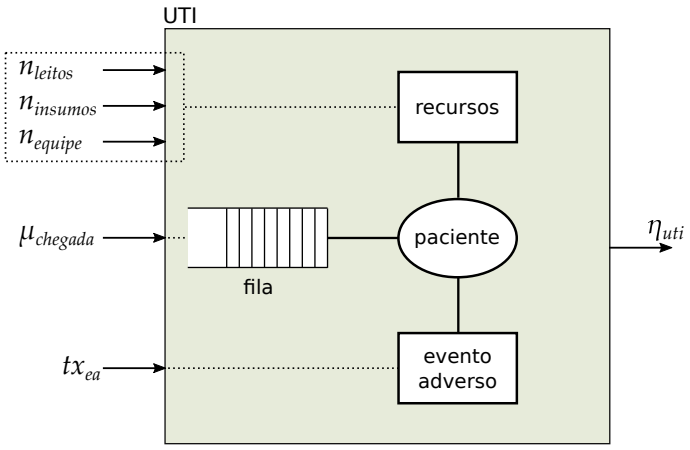

Figura 6.13 - Contexto para análise de sensibilidade da unidade de terapia intensiva.

A análise de sensibilidade foi desenvolvida utilizando o método da área, escolhido por apresentar resultados satisfatórios mediante baixo esforço computacional. Os parâmetros escolhidos para análise e seus respectivos valores referentes à sua faixa de variação e valor-base estão dispostos na Tabela 6.13. O valor-base dos parâmetros, dispostos na Tabela 6.13, refere-se a valor otimizado definido de forma empírica, considerando condições desejadas de funcionamento da UTI. A partir do valor otimizado para média da taxa de chegada, $36h$, foram definidos casos de sobrecarga e ociosidade, como disposto na Tabela 6.14.

Tabela 6.13 - Parâmetros e respectivos valores definidos para análise de sensibilidade do sistema de UTI.

parâmetro	**faixa de variação**	**valor-base**
n_{leitos}	$1 - 20$	10
$n_{insumos}$	$15\% - 200\%$	100%
n_{equipe}	$15\% - 200\%$	105%
tx_{ea}	$12\% - 24\%$	12%
$\mu_{chegada}$	$4h - 72h$	$36h$

Para o mesmo número de recursos disponíveis e a mesma taxa de eventos adversos, pode-se observar o impacto da alteração da taxa de chegada na Tabela 6.15. Observa-se que para o caso-base otimizado α_u^{36h}, $193,79$ pacientes foram admitidos,

Tabela 6.14 - Casos-base para análise de sensibilidade do sistema da UTI em condição de sobrecarga, regularidade e ociosidade.

caso-base	**condição**	n_{leitos}	$n_{insumos}$	n_{equipe}	tx_{ea}	$\mu_{chegada}$
α_u^{12h}	sobrecarga	10	100%	105%	12%	$12h$
α_u^{24h}	sobrecarga	10	100%	105%	12%	$24h$
α_u^{36h}	regularidade	10	100%	105%	12%	$36h$
α_u^{48h}	ociosidade	10	100%	105%	12%	$48h$
α_u^{60h}	ociosidade	10	100%	105%	12%	$60h$
α_u^{72h}	ociosidade	10	100%	105%	12%	$72h$

permanecendo cerca de $8,49$ dias na UTI, a fila de espera conteve em média $5,69$ pacientes, mantendo cerca de $8,67$ leitos em uso, logo o desempenho foi de 74%. Nas condições de ociosidade e de sobrecarga, o valor do desempenho foi inferior a 74%. Para taxas de chegadas próximas ao valor otimizado, α_u^{24h} e α_u^{48h}, o desempenho foi de 64% e 68%, respectivamente.

Tabela 6.15 - Dados de simulação das variáveis componentes do desempenho da UTI para os casos-base.

caso-base	**admissões** n_a	**tempo de internação** t_s[dias]	**tamanho da fila** n_f	**leitos em uso** n_l	**desempenho** η_{uti}
α_u^{12h}	179,64	9,75	244,09	9,31	0,56
α_u^{24h}	194,80	8,98	58,44	9,22	0,64
α_u^{36h}	193,79	8,49	5,69	8,67	0,74
α_u^{48h}	154,51	8,57	0,79	6,62	0,68
α_u^{60h}	124,40	8,56	0,51	5,14	0,62
α_u^{72h}	103,33	8,66	0,50	4,25	0,57

Os dados da Tabela 6.15 permitem análise dos cenários de sobrecarga e ociosidade. Nos casos de sobrecarga, α_u^{12h} e α_u^{24h}, o tamanho da fila n_f aumentou mais de 1000% e a UTI manteve-se lotada, uma vez que o número médio de leitos em uso n_l apresentou valor aproximado de $9,3$. Os casos de ociosidade, α_u^{48h}, α_u^{60h} e α_u^{72h}, foram caracterizados por diminuição de mais de 20% do número de admissões n_a, tamanho da fila n_f com valores próximos de *zero* e diminuição de mais de 20% do número de leitos em uso n_l. Considerando que a manutenção da estrutura da UTI requer alto investimento, a presença de 4 ou mais leitos ociosos conduz a valores de desempenho inferiores a 70%. Os valores dispostos na Tabela 6.15 são apresentados na Figura 6.14.

A análise de sensibilidade foi aplicada variando-se um parâmetro por vez a partir dos valores-base dispostos na Tabela 6.14. A Figura 6.15 apresenta o diagrama-

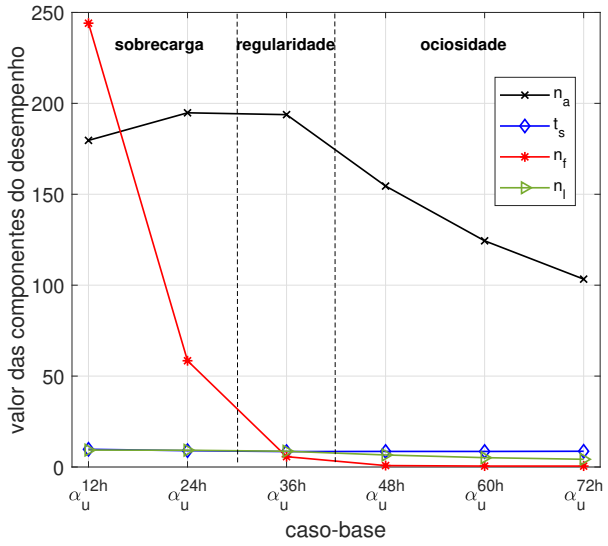

Figura 6.14 - Comportamento das variáveis componentes do desempenho da UTI para os casos-base.

aranha para caso-base com valores otimizados dos parâmetros, em que a condição de funcionamento da UTI é regular. Os casos referentes à condição de sobrecarga e de ociosidade são apresentados nas Figura 6.16 e Figura 6.17, respectivamente.

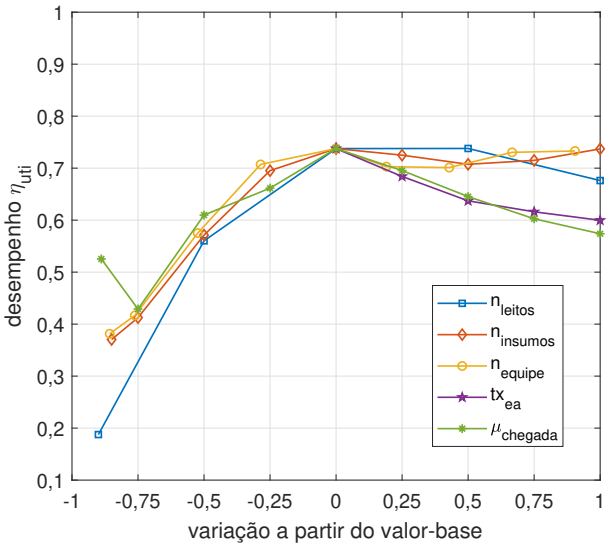

Figura 6.15 - Diagrama-aranha dos parâmetros da unidade de terapia intensiva referente ao caso-base otimizado α_u^{36h}.

Ao observar o diagrama-aranha da Figura 6.15, percebe-se que a variação do número de leitos n_{leitos} (na cor azul) gerou maior impacto no desempenho da UTI para

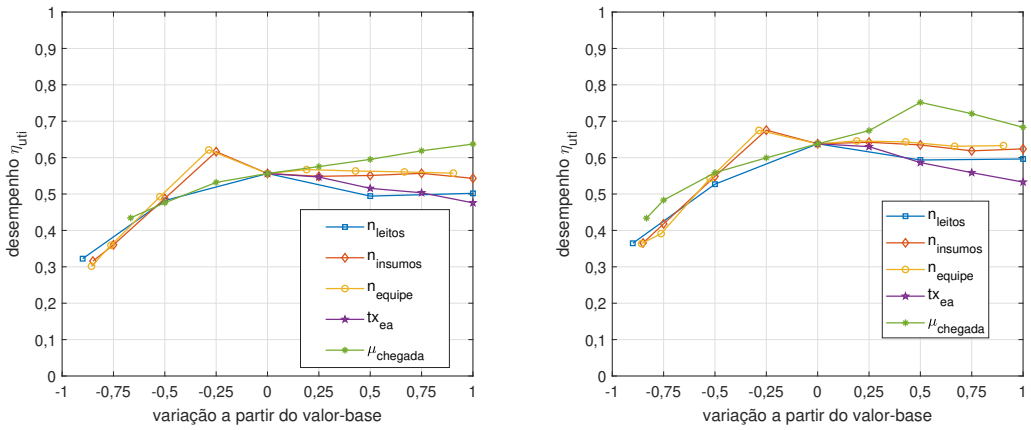

Figura 6.16 - Diagrama-aranha dos parâmetros da UTI referente aos casos-base: (a) α_u^{12h} e (b) α_u^{24h}.

variação negativa. Os parâmetros percentual de insumos $n_{insumos}$ (na cor laranja) e percentual de equipe médica n_{equipe} (na cor amarela) apresentaram comportamento próximo um do outro, com impacto expressivo para valores inferiores ao valor-base. A taxa de eventos adversos tx_{ea} (na cor roxa) somente foi variada de 0 a 100%, uma vez que o valor-base estimado refere-se aos eventos não-evitáveis, de forma que o valor-base assumiu o menor valor factível para o modelo em questão. O aumento da taxa de eventos adversos em 100% gerou queda do desempenho em mais de 10%. A variação do parâmetro média da taxa de chegada $\mu_{chegada}$ (na cor verde) conduziu a valores de desempenho menores em ambos contextos da análise (variação negativa e variação positiva).

Para os casos-base α_u^{12h} e α_u^{24h}, apresentados nas Figura 6.16(a) e Figura 6.16(b), respectivamente, as curvas tiveram comportamento semelhante, com valores de desempenho inferiores para situação de maior sobrecarga, quando a taxa de chegada do caso-base foi definida por distribuição normal $N(12, 4)$. Quando os insumos $n_{insumos}$ e a equipe médica n_{equipe} foram diminuídos em torno de 25%, o desempenho da UTI em relação aos casos-base aumentou, atingindo valores acima de 60%, o que pode ser justificado pela diminuição do número de leitos em uso, aproximadamente $7,2$ (ver Apêndice B). Neste caso, a UTI teria leitos vagos, o que seria adequado se houvesse também disponibilidade dos demais recursos, permitindo o atendimento de algum caso crítico. O aumento da média da taxa de chegada $\mu_{chegada}$ (na cor verde) foi acompanhada pelo aumento do desempenho, com pico apresentado na Figura 6.16(b), quando $\mu_{chegada}$ foi igual a +50% do valor-base, cuja configuração corresponde à configuração otimizada $\alpha_u^{36h} = (10;\ 1;\ 1,05;\ 0,12; 36)$.

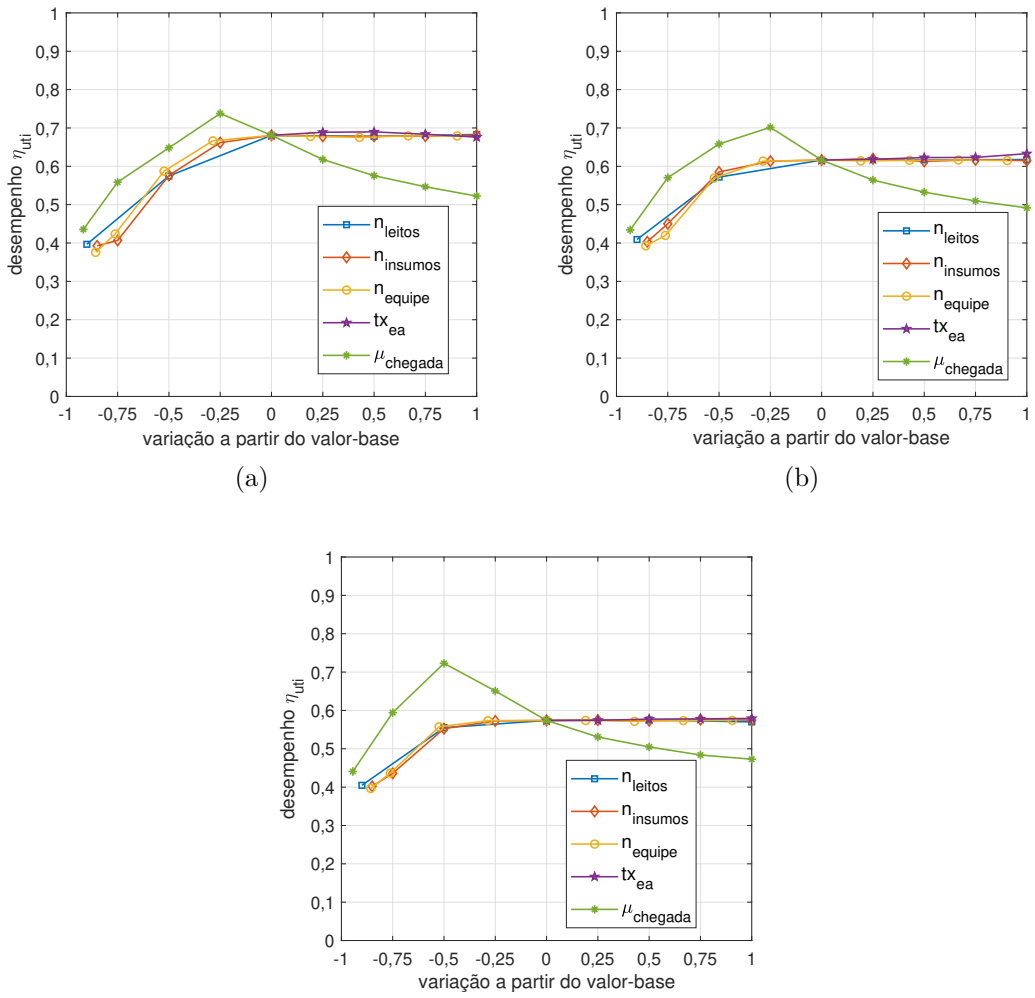

Figura 6.17 - Diagrama-aranha dos parâmetros da UTI referente aos casos-base: (a) α_u^{48h}, (b) α_u^{60h} e (c) α_u^{72h}.

Os casos-base em condição de ociosidade, α_u^{48h}, α_u^{60h} e α_u^{72h} apresentam desempenho igual 68%, 62% e 57%, respectivamente, como disposto na Tabela 6.15. Estes valores podem ser observados nos diagramas-aranha da Figura 6.17, os quais correspondem à variação a partir do valor-base igual *zero* e compõem par ordenado em que todos as curvas encontram-se. Os parâmetros n_{leitos}, n_{equipe}, $n_{insumos}$ e tx_{ea} possuem comportamento semelhante para casos de ociosidade do sistema, observados na Figura 6.17(a), Figura 6.17(b) e Figura 6.17(c), em que o desempenho da UTI decresce para variações negativas e mantém-se próximo do valor de desempenho do caso-base para variações positivas. O parâmetro $\mu_{chegada}$ possui pico de desempenho (igual ou superior a 70%) para variação em que o conjunto dos valores dos parâmetros se aproxima do caso otimizado, α_u^{36h}.

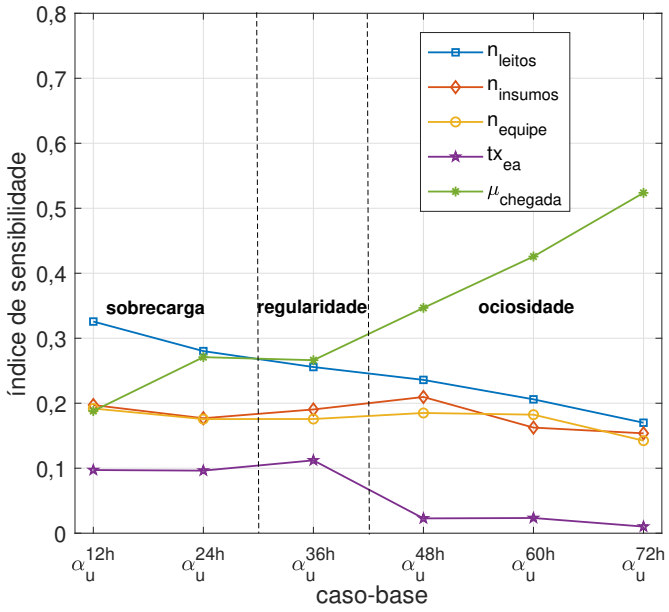

Figura 6.18 - Valores dos índices de sensibilidade para casos-base em condições de sobrecarga, regularidade e ociosidade.

A partir das medidas *one-at-a-time*, visualmente apresentadas nos diagramas-aranha das Figura 6.15, Figura 6.16 e Figura 6.17, aplicou-se o método da área para mensurar a sensibilidade dos parâmetros para cada caso-base. Os resultados obtidos estão dispostos na Tabela 6.16 e apresentados na Figura 6.18.

Tabela 6.16 - Índices de sensibilidade dos parâmetros da UTI referente à saída η_{uti} obtidos por meio do método da área.

caso-base	$S_{n_{leitos}}$	$S_{n_{insumos}}$	$S_{n_{equipe}}$	$S_{tx_{ea}}$	$S_{\mu_{chegada}}$
α_u^{12h}	0,3257	0,1972	0,1919	0,0972	0,1880
α_u^{24h}	0,2802	0,1769	0,1756	0,0963	0,2710
α_u^{36h}	0,2556	0,1904	0,1757	0,1121	0,2662
α_u^{48h}	0,2359	0,2096	0,1850	0,0228	0,3467
α_u^{60h}	0,2060	0,1625	0,1824	0,0234	0,4257
α_u^{72h}	0,1700	0,1537	0,1424	0,0102	0,5237

Ao analisar a Figura 6.18 e Tabela 6.16, observa-se que os parâmetros mais sensíveis são n_{leitos} e $\mu_{chegada}$, enquanto o parâmetro menos sensível é a taxa de eventos adversos tx_{ea}. Como tx_{ea} apresentou somente variação positiva a partir do valor-base, sua sensibilidade pode ter sido atenuada. Mesmo assim, para os casos de sobrecarga e para o caso otimizado, os índices de sensibilidade $S_{tx_{ea}}$ apresentaram valores próximos de 10%. Para o caso otimizado, todos os parâmetros impactam o desempenho

da UTI consideravelmente, uma vez que o parâmetro menos sensível, tx_{ea}, possui índice igual a $11,21\%$ e o mais sensível, $\mu_{chegada}$, possui índice igual a $26,62\%$, como disposto na Tabela 6.16.

Os índices de sensibilidade referentes aos casos de sobrecarga α_u^{12h} e α_u^{24h} mantiveram seus valores próximos dos obtidos para o caso otimizado α_u^{36h}, contudo o parâmetro n_{leitos} tornou-se mais sensível à medida que a média da taxa de chegada diminuiu, como apresentado na Figura 6.18. Quanto aos índices referentes aos casos de ociosidade α_u^{48h}, α_u^{60h} e α_u^{72h}, a sensibilidade dos parâmetros n_{leitos} e tx_{ea} diminuiu, ao passo que a sensibilidade do parâmetro $\mu_{chegada}$ aumentou consideravelmente: $34,67\%$ referente a α_u^{48h}, $42,57\%$ referente a α_u^{60h} e $52,37\%$ referente a α_u^{72h}, como disposto na Tabela 6.16.

Quando os leitos na UTI estavam vagos (nos casos de ociosidade), os eventos adversos tiveram impacto mínimo no desempenho do sistema, com índices $S_{tx_{ea}}$ próximos de *zero*, pois os recursos demandados por tempo prolongado estavam disponíveis, diferentemente dos casos de sobrecarga. Os parâmetros $n_{insumos}$ e n_{equipe} mantiveram seus valores entre 14% e 21%, considerando todos os casos analisados: ociosidade, regularidade e sobrecarga.

6.2 Análise da complexidade dos sistemas

A análise da complexidade consistiu na aplicação da métrica proposta ao motor de corrente contínua, sistema de desenvolvimento de *startups* e unidade de terapia intensiva. Tal métrica é formada por duas componentes: relevância e entropia das conexões internas dos sistemas. Como abstração das relações com ambiente, a relevância das conexões foi obtida por meio dos índices de sensibilidade dos parâmetros. Assim, a complexidade dos sistemas modelados pôde ser calculada e comparada à métrica desenvolvida por Paiva (2016).

6.2.1 Complexidade do sistema do motor de corrente contínua

A complexidade do MCC com sistema de controle PID foi obtida a partir das conexões modeladas e suas respectivas relevâncias. Primeiramente, foi necessário analisar a sensibilidade do sistema a variações nos parâmetros e calcular os respectivos índices de sensibilidade. Assim, a relevância de cada conexão pôde ser obtida e aplicada ao cálculo da complexidade do MCC com controlador PID.

O estudo de complexidade do motor de corrente contínua considerou a atuação do sistema de controle, logo os parâmetros analisados em termos de sensibilidade foram

a tensão de campo V_f e os ganhos k_p, k_i e k_d considerando o IAE como saída e a velocidade angular de referência ω_{ref} constante, fixa em $\omega_{ref} = 235,35\ rad/s$. O modelo desenvolvido com base nas conexões do MCC com controlador PID consistiu nos constituintes principais do motor acrescido do controle e da carga, como apresentado na Figura 6.19.

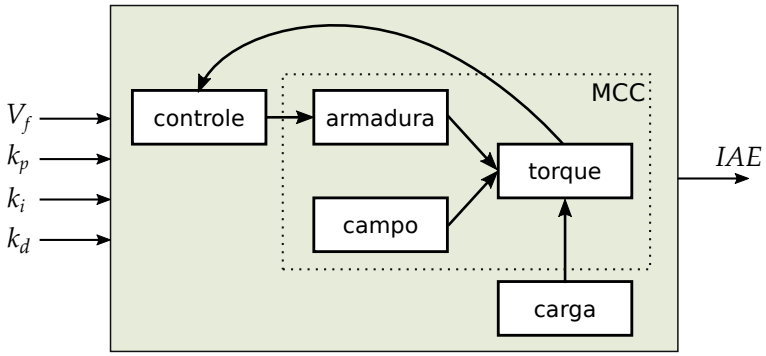

Figura 6.19 - Modelo das conexões do MCC com sistema de controle, parâmetros de entradas e variável de saída utilizados no cálculo de complexidade.

Os valores de relevância das conexões γ_c foram obtidos a partir dos índices de sensibilidade S_{V_f}, S_{k_p}, S_{k_i} e S_{k_d}, dispostos na Tabela 6.4. Após consultar especialista na área, foram definidos quais parâmetros exerciam influência direta em cada conexão apresentada na Figura 6.19, de forma que γ_c resultasse na soma dos índices de sensibilidade destes parâmetros, como disposto na Tabela 6.17.

Tabela 6.17 - Relevância γ_c das conexões do modelo do MCC com controlador PID.

conexão c	**relevância** γ_c
controle-armadura	$S_{k_p} + S_{k_i} + S_{k_d}$
armadura-torque	$S_{k_p} + S_{k_i} + S_{k_d}$
campo-torque	S_{V_f}
carga-torque	$S_{V_f} + S_{k_p} + S_{k_i} + S_{k_d}$
torque-controle	$S_{k_p} + S_{k_i} + S_{k_d}$

A probabilidade das conexões $P(c)$ do MCC foi definida como um, pois todas as conexões deviam ocorrer para que o sistema estivesse em operação. Logo, a segunda componente da métrica de complexidade, dada por (5.8), manteve-se igual a $zero$, uma vez que a entropia neste caso é nula. Assim a complexidade consistiu dos valores da relevância das conexões γ_c, que variaram de acordo com o método de análise de sensibilidade aplicado. Os valores de complexidade $\psi^{mcc}(c, \gamma_c)$ foram obtidos consi-

derando os distintos valores dos índices de sensibilidade e resultaram no disposto da Tabela 6.18.

Tabela 6.18 - Complexidade $\psi^{mcc}(c, \gamma_c)$ do MCC com controlador PID de acordo com método de análise de sensibilidade.

$\psi^{mcc}(c, \gamma_c)$	**método**
3,11	área
2,32	soma das diferenças
3,05	variância condicional local
2,71	variância condicional global

Considerando a sensibilidade observada em torno do caso-base otimizado, o método da área e o método da variância condicional local possuem maior representatividade que o método da soma das diferenças devido ao maior número de casos considerados para análise. Quando estes métodos foram utilizados, a complexidade $\psi^{mcc}(c, \gamma_c)$ atingiu valores aproximados a $3,1$. Quando o método global foi aplicado, obteve-se $\psi^{mcc}(c, \gamma_c)$ igual a $2,71$, uma vez que os parâmetros relacionados ao controle foram menos sensíveis na faixa de variação analisada (ver Tabela 6.1). Como havia mais conexões afetadas diretamente pelo sistema de controle em comparação com a tensão de campo V_f, a relevância destas conexões recebeu valores menores e, portanto, o valor da complexidade obtido foi menor.

A complexidade $\psi^{mcc}(c)$, obtida pela aplicação da métrica proposta por Paiva (2016), foi igual a *zero*. Como as conexões deviam estar ativas para que o sistema estivesse funcionando, a entropia calculada foi igual a *zero*, pois $P(c) = 1$. Este resultado justifica-se pela proposta das métricas $\psi^{mcc}(c)$ e $\psi^{mcc}(c, \gamma_c)$ de serem aplicadas a sistemas em operação. Assim a complexidade pode ser calculada somente a partir da dinâmica dos sistemas, ou seja, das conexões estabelecidas durante período de tempo.

6.2.2 Complexidade do sistema de desenvolvimento de *startups*

O sistema de desenvolvimento de *startups* (SDS) foi modelado como conjunto de classes das empresas nascentes, ou seja, empresas em pré-aceleração, aceleração e pós-aceleração (ou graduadas). As conexões estabelecidas por cada *startup* deste sistema foram definidas como: *startup*-diagnóstico para as empresas em pré-aceleração, *startup*-avaliação de desempenho e *startup*-avaliação de *pitch* para as empresas em aceleração e *startup*-acompanhamento para as empresas graduadas, como apresenta a Figura 6.20.

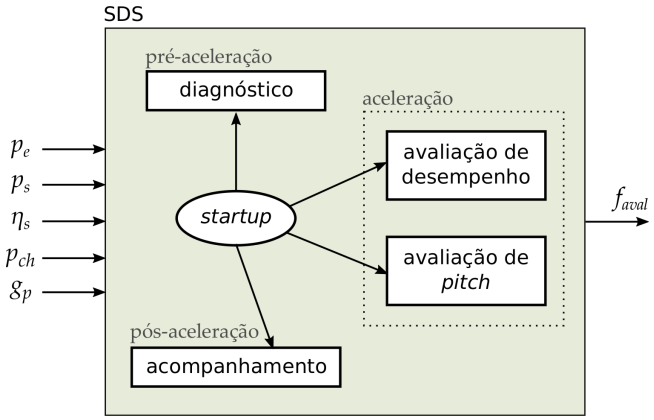

Figura 6.20 - Modelo das conexões do sistema de desenvolvimento de *startups*, parâmetros de entradas e variável de saída utilizados para cálculo de complexidade.

A fim de calcular a complexidade do SDS, as probabilidades das conexões $P(c)$ foram definidas com base nos estudos de Roman (2017). Considerou-se o número de empresas em cada classe do SDS em relação ao total de empresas de seu portfólio, de forma que os valores de $P(c)$ pudessem ser calculados e dispostos na Tabela 6.19.

Tabela 6.19 - Probabilidades das conexões $P(c)$ do sistema de desenvolvimento de *startups*.

conexão c	$P(c)$
startup-diagnóstico	0,770
startup-avaliação de desempenho	0,065
startup-avaliação de *pitch*	0,065
startup-acompanhamento	0,100

As *startups* que formaram o portfólio do SDS podiam estar em estágios diferentes de desenvolvimento. No sistema real, à medida que as *startups* avançam no processo de aceleração, elas requerem menos esforços da aceleradora, pois conquistam mercado e adquirem autonomia. Logo a relevância das conexões foi modelada a fim de compreender a sensibilidade de maior número de parâmetros nas conexões da pré-aceleração e menor, nas conexões da pós-aceleração, como disposto na Tabela 6.20.

Tabela 6.20 - Relevância γ_c das conexões do sistema de desenvolvimento de *startups*.

conexão c	**relevância** γ_c
startup-diagnóstico	$S_{p_e} + S_{p_s} + S_{g_p}$
startup-avaliação de desempenho	$S_{\eta_s} + S_{g_p}$
startup-avaliação de *pitch*	$S_{p_{ch}} + S_{g_p}$
startup-acompanhamento	S_{g_p}

Na Tabela 6.20, o índice de sensibilidade do parâmetro gestão de portfólio S_{g_p} está presente na relevância de todas as conexões. Os índices do perfil dos empreendedores S_{p_e} e perfil das *startups* S_{p_e} fazem parte da relevância da conexão *startup*-diagnóstico, enquanto os índices de sensibilidade do parâmetro desempenho S_{η_s} participa da relevância da conexão *startup*-avaliação de desempenho e do parâmetro nota da banca de *pitch* $S_{p_{ch}}$, da conexão *startup*-avaliação de *pitch*.

Como os índices de sensibilidade obtiveram valores distintos de acordo com o método aplicado, os valores de relevância das conexões também variaram. Consequentemente, a complexidade $\psi^{sds}(c, \gamma_c)$ foi diferente para cada método de análise de sensibilidade utilizado. A Tabela 6.21 dispõe a complexidade do SDS com 50, 100 e 300 *startups*. A complexidade $\psi^{sds}(c, \gamma_c)$ aumentou com o aumento do número de *startups*, pois as conexões foram modeladas por *startup*, individualmente, desconsiderando as conexões entre elas. O modelo refere-se à representação simplificada do sistema, podendo ser ajustado a fim de englobar o intercâmbio de informações, produtos, pessoas entre as empresas do SDS.

Tabela 6.21 - Complexidade do sistema de desenvolvimento de *startups* de acordo com método de análise de sensibilidade.

$\psi^{sds}(c, \gamma_c)$ 50 ***startups***	$\psi^{sds}(c, \gamma_c)$ 100 ***startups***	$\psi^{sds}(c, \gamma_c)$ 300 ***startups***	**método de análise de sensibilidade**
52,13	96,29	293,52	área
48,30	95,83	298,48	soma das diferenças
63,12	119,22	369,25	variância condicional local
57,76	117,16	349,33	variância condicional global

Na Tabela 6.21, a complexidade $\psi^{sds}(c, \gamma_c)$ obtida a partir da aplicação do método de variância condicional global apresentou valores menores que os obtidos pelo método da variância condicional local e maiores que os valores obtidos pelos métodos da área e da soma das diferenças. Dos métodos aplicados, o método de variância condicional global é o mais representativo, pois permite analisar casos em todo conjunto de pontos viáveis.

Os valores de complexidade com base em conexões ponderadas $\psi^{sds}(c, \gamma_c)$ foram comparados aos valores de complexidade com base em conexões $\psi^{sds}(c)$. Os valores de $\psi^{sds}(c)$ foram iguais a aproximadamente 16 para o sistema com 50 *startups*, 32, para o SDS com 100 *startups* e 97, para o sistema com 300 *startups*. Nos três casos, a complexidade com base em conexões ponderadas $\psi^{sds}(c, \gamma_c)$ foi aproximadamente $3,6\times$ maior que a complexidade com base em conexões $\psi^{sds}(c)$.

De forma hipotética, o sistema de desenvolvimento de *startups* podia ter apenas uma *startup*. Para este caso, os seguintes cenários podiam acontecer: a *startup* estar na fase de pré-aceleração, a *startup* estar na fase de aceleração ou estar graduada. Os resultados encontrados referentes à complexidade $\psi^{sds}(c, \gamma_c)$ destes cenários foram dispostos na Tabela 6.22, considerando o método de análise de sensibilidade aplicado.

Tabela 6.22 - Complexidade $\psi^{sds}(c, \gamma_c)$ do sistema de desenvolvimento de uma *startup* de acordo com método de análise de sensibilidade.

$\psi^{sds}(c, \gamma_c)$ **pré-aceleração**	$\psi^{sds}(c, \gamma_c)$ **aceleração**	$\psi^{sds}(c, \gamma_c)$ **pós-aceleração**	**método de análise de sensibilidade**
0,96	1,41	0,61	área
0,95	1,41	0,61	soma das diferenças
1,29	1,27	0,71	variância condicional local
1,19	1,32	0,69	variância condicional global

Com exceção dos valores encontrados pela aplicação do método de variância condicional local, o maior valor de complexidade calculado refere-se à classe aceleração, seguido dos valores referentes às classes de pré-aceleração e de pós-aceleração, respectivamente. Estes resultados são coerentes com as observações realizadas no sistema real, em que a aceleradora necessita dedicar considerável trabalho ao grupo de empresas em aceleração, por meio de mentorias, reuniões e bancas para avaliar mensalmente o desempenho e a evolução das empresas.

Quanto à classe pré-aceleração, a aceleradora condensa esforços em eventos de preparação e seleção das equipes que desejam formar *startups*. Nesta fase, o perfil dos empreendedores e a proposta de negócio são avaliados, analisando competências individuais, capacidade técnica e coesão da equipe, somadas ao domínio que a equipe possui em relação a tecnologia, mercado, recursos e planejamento do negócio proposto. As empresas da classe pós-aceleração necessitam apenas do acompanhamento da aceleradora, pois geralmente possuem receitas recorrentes.

6.2.3 Complexidade do sistema de unidade de terapia intensiva

O sistema de unidade de terapia intensiva foi simulado considerando demanda por leitos estimada a partir de dados reais, como apresentado no Apêndice C. A ocupação de leito na UTI depende do cumprimento de critérios regulados internacionalmente para realizar a devida classificação do quadro clínico do paciente. Assim, a entrada do paciente na UTI obedece fila de prioridades e somente ocorre quando há recursos disponíveis, ou seja, leito, insumos e equipe médica. A dinâmica da UTI segue regras e pode adaptar-se de acordo com a necessidade, atuando como sistema complexo.

A aplicação da métrica de complexidade requer a definição dos valores de probabilidade $P(c)$ e de relevância γ_c das conexões, de acordo com (5.8). O modelo de unidade de terapia intensiva, apresentado na Figura 6.21, exibe as conexões estabelecidas enquanto o paciente está na fila ou durante sua permanência na UTI. As probabilidades de conexão na fila foram definidas experimentalmente considerando a prioridade de cada paciente, como disposto na Tabela 6.23. Neste caso, a probabilidade experimental refere-se ao número de pacientes por prioridade na fila em cada instante analisado em relação ao total de pacientes na fila.

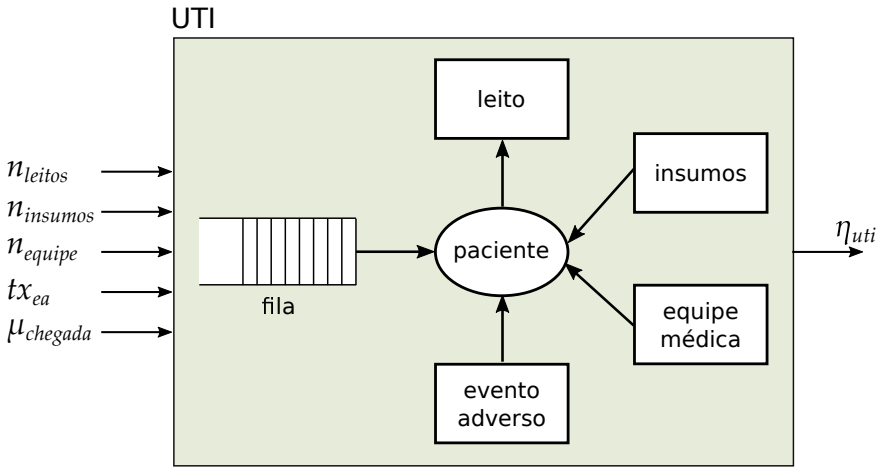

Figura 6.21 - Modelo das conexões do sistema de UTI, parâmetros de entradas e variável de saída utilizados para cálculo de complexidade.

Tabela 6.23 - Probabilidades das conexões $P(c)$ do sistema da unidade de terapia intensiva referente à fila para distintos casos-base.

conexão c	α_u^{12h} $P(c)$	α_u^{24h} $P(c)$	α_u^{36h} $P(c)$	α_u^{48h} $P(c)$	α_u^{60h} $P(c)$	α_u^{72h} $P(c)$
paciente prioridade 1-fila	0,11	0,02	0,06	0,21	0,33	0,34
paciente prioridade 2-fila	0,68	0,61	0,40	0,47	0,53	0,52
paciente prioridade 3-fila	0,10	0,16	0,19	0,14	0,07	0,06
paciente prioridade 4-fila	0,10	0,17	0,29	0,15	0,07	0,07
paciente prioridade 5-fila	0,01	0,04	0,06	0,03	0,01	0,01

Os valores das probabilidades referente aos recursos e aos eventos adversos, dispostos na Tabela 6.24, foram estabelecidos em consonância com a configuração do modelo, o qual dispõe de 10 leitos, 100% de insumos, 105% da carga de trabalho da equipe médica e taxa de eventos adversos igual a 12% para os casos-base α_u^{12h}, α_u^{24h}, α_u^{36h}, α_u^{48h}, α_u^{60h} e α_u^{72h} (ver Tabela 6.14), que diferem apenas pelo valor da taxa de chegada.

Como existem 10 leitos no modelo proposto, a probabilidade de conexão do paciente com um leito é $0,1$, requerendo em média $0,09$ dos recursos insumos e equipe. Este valor $0,09$ refere-se à esperança matemática da distribuição uniforme $U(6,12)$, encontrada empiricamente por meio de simulações do quantitativo de insumos ou de carga de trabalho da equipe requerido por cada paciente. Quanto aos eventos adversos, a probabilidade de conexão refere-se à taxa definida para o modelo e igual a $0,12$.

Tabela 6.24 - Probabilidades $P(c)$ das conexões do sistema da unidade de terapia intensiva referente aos recursos e eventos adversos.

conexão c	**probabilidade** $P(c)$
paciente-leito	0,10
paciente-insumos	0,09
paciente-equipe médica	0,09
paciente-eventos adversos	0,12

A relevância γ_c das conexões foi definida com base nos índices de sensibilidade dos parâmetros. Para tanto, procedeu-se à análise de qual ou quais parâmetros influenciavam diretamente a conexão em questão. A partir desta análise, γ_c recebeu o valor dos índices de sensibilidade de acordo com disposto na Tabela 6.25. Estes valores variam para os distintos casos-base, como disposto na Tabela 6.16.

Tabela 6.25 - Relevância γ_c das conexões do sistema da unidade de terapia intensiva.

conexão c	**relevância** γ_c
paciente-fila	$S_{\mu_{chegada}}$
paciente-leito	$S_{n_{leitos}}$
paciente-insumos	$S_{n_{insumos}}$
paciente-equipe médica	$S_{n_{equipe}}$
paciente-eventos adversos	$S_{tx_{ea}}$

Uma vez definidas a probabilidade $P(c)$ e a relevância γ_c das conexões, a complexidade $\psi^{uti}(c,\gamma_c)$ pôde ser calculada aplicando (5.8). Os resultados obtidos estão dispostos na Tabela 6.26, juntamente com os valores de complexidade $\psi^{uti}(c)$. Tanto $\psi^{uti}(c)$ quanto $\psi^{uti}(c,\gamma_c)$ são calculadas a partir da dinâmica do sistema no que se refere às conexões, contudo $\psi^{uti}(c,\gamma_c)$ atualiza $\psi^{uti}(c)$, pois baseia-se em conexões ponderadas por sua relevância γ_c, dada por índices de sensibilidade. Desta forma, a influência de alterações dos parâmetros no desempenho do sistema pode ser integrada à métrica de complexidade, tornando-a mais abrangente por considerar a

relação entre as partes e o todo.

Tabela 6.26 - Valores de complexidade com base em conexões $\psi^{uti}(c)$ e em conexões ponderadas $\psi^{uti}(c, \gamma_c)$ referente a distintas situações de demanda do sistema de UTI.

caso-base	$\psi^{uti}(c)$	$\psi^{uti}(c, \gamma_c)$
α_u^{12h}	100,47	153,42
α_u^{24h}	38,65	62,34
α_u^{36h}	13,06	20,30
α_u^{48h}	8,47	12,70
α_u^{60h}	6,67	9,63
α_u^{72h}	5,65	7,77

A complexidade ponderada por conexões $\psi^{uti}(c, \gamma_c)$ apresentou valores maiores que $\psi^{uti}(c)$, como disposto na Tabela 6.26 e apresentado na Figura 6.22. O comportamento de $\psi^{uti}(c)$ e $\psi^{uti}(c, \gamma_c)$ assemelha-se à curva exponencial, com aumento considerável para os casos de sobrecarga (até 670%) em relação ao caso de regularidade, α_u^{36h}, e diminuição gradativa para os casos de ociosidade (até 62%). Ressalta-se que a complexidade de cada caso-base corresponde à média dos valores de complexidade obtidos em 100 replicações da simulação.

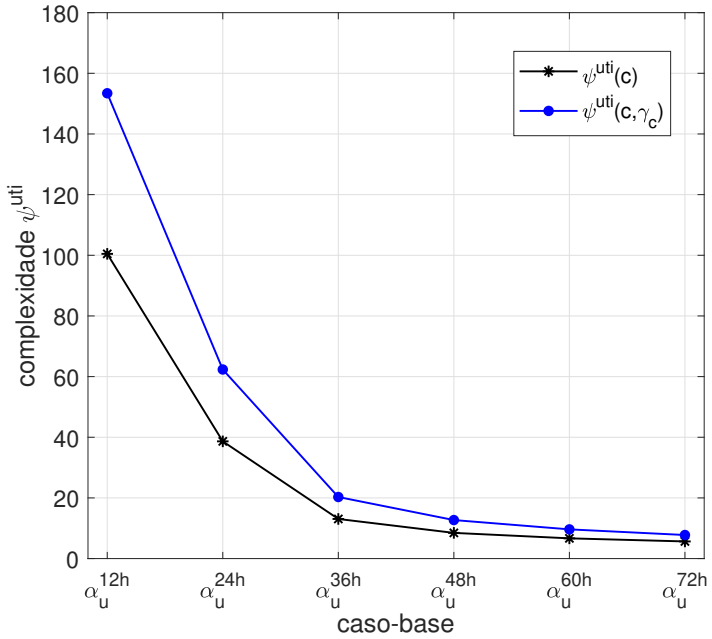

Figura 6.22 - Comparação entre medidas de complexidade com base em conexões $\psi^{uti}(c)$ e em conexões ponderadas $\psi^{uti}(c, \gamma_c)$ referente a distintas situações de demanda do sistema de UTI.

O valor de complexidade $\psi^{uti}(c, \gamma_c)$ foi obtido utilizando (5.8), em que a primeira componente cp_1 refere-se ao somatório das relevâncias das conexões γ_c e a segunda componente cp_2 refere-se ao somatório de $-P(c) \cdot \log_2 P(c)$, as quais correspondem à sensibilidade do sistema e à entropia, respectivamente. Os valores das duas componentes estão dispostos na Tabela 6.27.

Tabela 6.27 - Valores das componentes da complexidade $\psi^{uti}(c, \gamma_c)$ referente a distintas situações de demanda do sistema de UTI.

caso-base	cp_1	cp_2	$\psi^{uti}(c, \gamma_c)$	$\frac{cp_2}{cp_1}$
α_u^{12h}	52,95	100,47	153,42	1,90
α_u^{24h}	23,69	38,65	62,34	1,63
α_u^{36h}	7,24	13,06	20,30	1,80
α_u^{48h}	4,23	8,47	12,70	2,00
α_u^{60h}	2,96	6,67	9,63	2,25
α_u^{72h}	2,12	5,65	7,77	2,67

Na Tabela 6.27, o valor de cp_2 é maior que de cp_1 para todos os casos-base analisados. A componente cp_2 relativa à entropia é $1,90$ e $1,63$ vezes maior que a componente cp_1 relativa à sensibilidade no que tange a α_u^{12h} e α_u^{24h}, respectivamente, e $1,80$ vezes maior quando se analisa o caso-base otimizado, α_u^{36h}. Embora os valores da relação $\frac{cp_2}{cp_1}$ sejam próximos para o caso otimizado e os casos de sobrecarga, os valores de complexidade $\psi^{uti}(c, \gamma_c)$ distanciam-se. Para os casos-base de ociosidade, os valores de complexidade são próximos, contudo cp_2 é o dobro ou mais que o dobro de cp_1.

A relação $\frac{cp_2}{cp_1}$ representa o custo em termos de entropia para cada unidade de sensibilidade. Na Tabela 6.27, os menores valores de $\frac{cp_2}{cp_1}$ referem-se aos casos-base α_u^{24h} e α_u^{36h}, sendo que α_u^{36h} apresenta valores de cp_1 e cp_2 menores que os de α_u^{24h}, reforçando sua definição como caso-base otimizado. Contudo, considerando estudos realizados utilizando dados reais e apresentados no Apêndice C, a configuração do sistema de UTI assemelha-se a α_u^{24h}, em que 70 pacientes em média aguardam leito da UTI na fila, próximo ao valor simulado $n_f = 56,70$ para o caso-base α_u^{24h}, como disposto na Tabela B.2.

6.3 Avaliação dos sistemas com base na complexidade natural

A complexidade natural proposta neste trabalho consiste da totalidade do sistema em interação, tanto interna quanto externa, de forma coerente com a natureza dele. Assim, cada sistema deveria atuar em faixas adequadas de operação, evitando o ócio ou o excesso de trabalho. Com base nestas considerações, valores de complexi-

dade superiores ou inferiores à complexidade natural podem indicar sobrecarga ou ociosidade do sistema, respectivamente, como afirma a hipótese básica. Nos modelos analisados, o método da área apresentou-se razoável para cálculo dos índices de sensibilidade e, posteriormente, das relevâncias das conexões. Logo o valor de complexidade natural pôde ser obtido quando as análises de sensibilidade e de entropia do sistema foram realizadas a partir do caso-base otimizado.

De acordo com a Tabela 6.18, o sistema do motor de corrente contínua apresentou $\psi_n^{mcc}(c, \gamma_c) = 3,11$ referente ao caso-base α_p^0 e o sistema de desenvolvimento de *startups* apresentou $\psi_n^{sds}(c, \gamma_c) = 52,13$ para sistema com 50 *startups*, $\psi_n^{sds}(c, \gamma_c) = 96,29$ para sistema com 100 *startups* e $\psi_n^{sds}(c, \gamma_c) = 293,52$ para sistema com 300 *startups*, de acordo com Tabela 6.21, referente ao caso-base α_s. Para o sistema de UTI, a configuração otimizada corresponde ao caso-base α_u^{36h}, em que o sistema de UTI atuou em sua complexidade natural, $\psi_n^{uti}(c, \gamma_c) = 20,3$, de acordo com a Tabela 6.26.

O modelo do sistema de unidade de terapia intensiva foi escolhido para verificação da hipótese deste trabalho, por se tratar de modelo que simula sistema real e por ser condicionado a distintas demandas. Assim, os casos-base foram determinados conforme atividade do sistema: baixa, adequada e alta, caracterizando situações de ociocidade, regularidade e sobrecarga do sistema, respectivamente. Considerou-se que o sistema atuaria adequadamente quando sua configuração estivesse otimizada, logo valores abaixo ou acima da $\psi_n^{uti}(c, \gamma_c) = 20,3$ poderiam indicar desempenho insatisfatório da UTI.

A complexidade natural foi proposta como nível de complexidade do sistema em que ele exerce sua função com alto desempenho e atinge seu objetivo. Ao analisar a Figura 6.23, verifica-se que o desempenho máximo obtido, η_{uti} igual a 74%, refere-se ao cenário com taxa de chegada $N(36, 4)$, ou seja, a cada 36 horas em média chega um paciente à UTI com desvio padrão igual a 4. Para este caso, α_u^{36h}, a complexidade foi relativamente baixa. O comportamento do desempenho em relação à complexidade é apresentado na Figura 6.24.

Considerando a taxa de chegada da configuração otimizada como referência, se a demanda de atendimento na UTI aumentasse, o sistema ficaria sobrecarregado e se diminuisse, o sistema ficaria ocioso. Assim, para médias da taxa de chegada inferiores a $36h$, o valor de complexidade cresce consideravelmente devido ao aumento das conexões na fila e o desempenho decresce: 64% para α_u^{24h} e 56% para α_u^{12h}. Para médias da taxa de chegada superiores a $36h$, embora os valores de complexidade

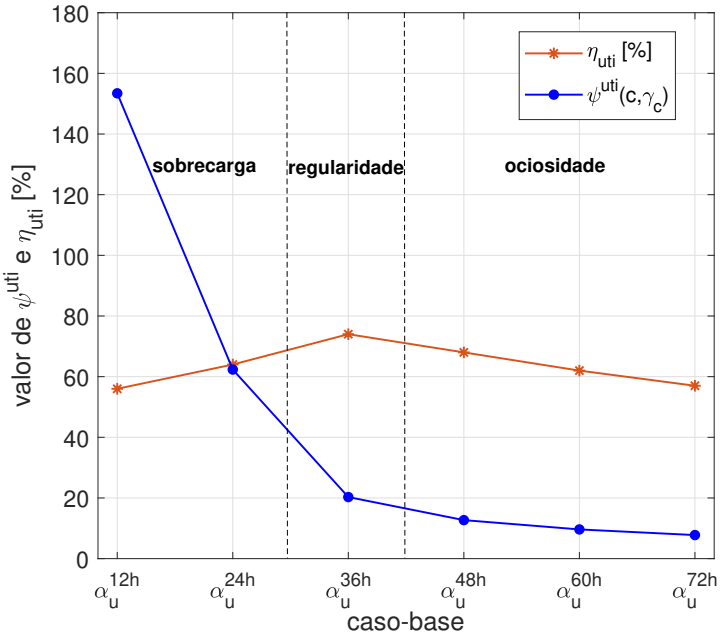

Figura 6.23 - Complexidade com base em conexões ponderadas $\psi^{uti}(c, \gamma_c)$ e desempenho da UTI η_{uti} referente a distintas situações de demanda do sistema.

diminuam, pode-se observar que os valores de desempenho também: 68% para α_u^{48h}, 62% para α_u^{60h} e 57% para α_u^{72h}. Nestes casos, parte dos recursos disponíveis não é utilizada, implicando em custo de manutenção.

Esta análise inicial dos resultados reforça a hipótese levantada de que se a **complexidade natural** representa nível de atividade adequado para o sistema, então o **sistema** está **ocioso** quando apresenta complexidade inferior à sua complexidade natural e está **sobrecarregado** quando apresenta complexidade superior à sua complexidade natural, dado por (6.2). A partir do teste de hipótese, as diferenças observadas em termos de complexidade quando a UTI atua fora da condição de regularidade foram verificadas.

$$\begin{cases} \psi < \psi_n & \Rightarrow \textit{ociosidade} \\ \psi > \psi_n & \Rightarrow \textit{sobrecarga} \end{cases} \tag{6.2}$$

Com base no comportamento das curvas apresentado nas Figura 6.18 e Figura 6.23, considerou-se que a sobrecarga, regularidade e ociosidade do sistema de UTI seria caracterizada por taxa de chegada de paciente entre i) $12h$ e $29h$, ii) $30h$ e $42h$ e iii) $43h$ e $72h$, respectivamente. A fim de gerar as amostras correspondentes a estes

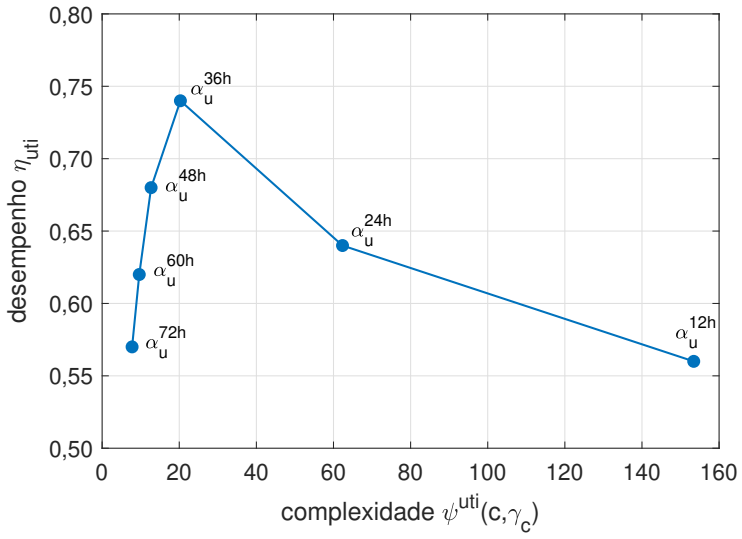

Figura 6.24 - Desempenho da UTI η_{uti} × complexidade com base em conexões ponderadas $\psi^{uti}(c, \gamma_c)$.

grupos, realizou-se interpolação cúbica que obteve o melhor ajuste, considerando o comportamento da curva na cor azul da Figura 6.23. O tamanho de cada amostra foi igual a 60, de forma que ao todo foram gerados 180 valores de complexidade no intervalo entre $7,76$ e $153,42$. As estatísticas descritivas de cada amostra estão dispostas na Tabela 6.28.

Tabela 6.28 - Estatística descritiva da complexidade das amostras referentes às condições de atividade do sistema de UTI.

estatística	$\psi^{uti}(c,\gamma_c)$ **ociosidade**	$\psi^{uti}(c,\gamma_c)$ **regularidade**	$\psi^{uti}(c,\gamma_c)$ **sobrecarga**
média	$10,41$	$21,94$	$87,91$
desvio padrão	$1,98$	$6,42$	$33,88$
mínimo	$7,76$	$14,21$	$39,37$
máximo	$13,78$	$35,74$	$153,42$

A fim de realizar teste estatístico paramétrico, inicialmente o teste de normalidade foi aplicado aos dados amostrais. Utilizando o teste de Kolmogorov-Smirnov, os valores de $\psi^{uti}(c, \gamma_c)$ em condição de ociosidade e de sobrecarga aproximaram-se de distribuição normal, pois o valor-p calculado foi igual a $0,165$ e $0,200$, respectivamente. Assim, a hipótese nula de que a distribuição dos dados aproxima-se de distribuição normal foi mantida. Os dados amostrais de $\psi^{uti}(c, \gamma_c)$ em condição de regularidade não se aproximaram de distribuição normal, pois o valor-p foi igual a $0,037$, ou seja, menor que $0,05$ e portanto a hipótese nula do teste de normalidade

foi rejeitada.

Com base nos resultados do teste de normalidade, realizou-se o Teste-t para uma amostra, a fim de comparar os dados em condição de ociosidade ou de sobrecarga com o valor de complexidade natural, $\psi_n^{uti}(c, \gamma_c) = 20,3$. A hipótese nula foi rejeitada para ambos os casos, com valor-p igual *zero*. Considerando nível de significância de $0,05$, o valor-t observado foi igual a $-38,62$ para o caso de ociosidade, enquanto o valor-t crítico é $-2,66$ e o valor-t observado foi igual a $15,46$ para o caso de sobrecarga, enquanto o valor-t crítico é $2,66$.

Como a amostra em condição de regularidade não se aproximou da distribuição normal e ao aplicar o teste de normalidade Shapiro-Wilk, somente a amostra em condição de sobrecarga aproximaria desta distribuição, considerou-se necessário aplicar teste estatístico não-paramétrico, o teste Mann Whitney. A comparação das amostras independentes de $\psi^{uti}(c, \gamma_c)$ em condição de regularidade e ociosidade resultou em valor-p igual a *zero*. O mesmo resultado foi encontrado quando comparada as amostras independentes de $\psi^{uti}(c, \gamma_c)$ em condição de regularidade e sobrecarga. Portanto, em ambos os casos, a hipótese nula foi rejeitada, corroborando a hipótese básica deste trabalho. Logo as diferenças dos valores de complexidade quando a UTI atua fora da condição de regularidade foram significativas.

6.4 Discussão

A métrica de complexidade $\psi(c, \gamma_c)$ proposta integra características diversas do sistema, como configuração, arranjo, desempenho e carga de trabalho. Ao utilizar os índices de sensibilidade para ponderar as conexões, o sistema é analisado com base na relação das partes com o todo, combinando aspectos da sua dinâmica interna (as conexões) e externa (variáveis de entrada). Além da métrica $\psi(c, \gamma_c)$, este trabalho propõe o conceito de **complexidade natural de sistema**, que se apresenta como referência justa e razoável para avaliar os sistemas: justa no sentido do sistema ser eficaz e razoável no sentido do sistema ser adequadamente eficiente, atuando sem sobrecarga.

Ao usar a complexidade natural como referência, verificou-se que a redução da complexidade $\psi(c, \gamma_c)$ ocorreu quando os recursos foram devidamente utilizados ou estavam ociosos e o aumento da complexidade $\psi(c, \gamma_c)$ decorreu de sobrecarga do sistema, dado por:

$$\begin{cases} \textit{complexidade} \downarrow & \textit{desempenho} \downarrow & \Rightarrow \textit{ociosidade} \\ \textit{complexidade} \downarrow & \textit{desempenho} \uparrow & \Rightarrow \textbf{complexidade natural} \\ \textit{complexidade} \uparrow & \textit{desempenho} \downarrow & \Rightarrow \textit{sobrecarga} \end{cases} \tag{6.3}$$

Observou-se que a complexidade saturou para cenários com baixa demanda dos recursos, indicando custo em manter o sistema ocioso. No sistema de UTI, o valor de $\psi_n^{uti}(c, \gamma_c) = 20,3$ constituiu o início de saturação da complexidade, o que nos conduz à hipótese de que a complexidade natural seja a **complexidade mínima do sistema** em atividade regular, nem ocioso e nem sobrecarregado.

Nos sistemas modelados por entidades, recursos e filas, o número de conexões ativas aumenta de acordo com a condição de operação do sistema: ociosidade, regularidade ou sobrecarga, nesta ordem. Assim a medida de complexidade com base em conexões ponderadas $\psi(c, \gamma_c)$ pode refletir: i) configurações com recursos ociosos, ii) configurações otimizadas, em que o sistema apresenta alto desempenho ou iii) configurações com escassez de recursos, uma vez que a capacidade de atuação do sistema não atende a demanda existente. Com base nos estudos realizados por Gomes et al. (2019), cada **configuração** pode ser avaliada pela aplicação da relação R_c, dada por:

$$R_c = \frac{desempenho}{complexidade} \tag{6.4}$$

no qual R_c representa o custo em termos de desempenho para cada unidade de complexidade do sistema.

Se o sistema não estiver sobrecarregado, o menor valor de R_c é indicativo de quantidade adequada de **recursos**. No sistema da UTI, os valores de desempenho para os casos de ociosidade e de sobrecarga foram inferiores ao valor do desempenho para o caso de regularidade, como apresentado na Figura 6.24. Assim, tanto cenários de sobrecarga quanto de ociosidade são indesejados, porém os casos de sobrecarga são mais preocupantes.

De forma geral, o estado de saúde dos pacientes que necessitam de cuidados intensivos exige atendimento rápido, pois suas vidas podem estar ameaçadas devido à gravidade do quadro clínico apresentado. Assim, a presença de fila expressiva de UTI pressupõe desempenho comprometido e aumento da complexidade do sistema. Quando há fila e consequentemente pressão para liberação de leitos, tende-se a dar

alta a pacientes prematuramente, o que aumenta o retorno de pacientes à UTI. A literatura indica que isto ocorre com maior frequência quando o uso dos leitos da UTI ultrapassar 80%, dado por: (5.10) e (6.1), na modelagem utilizada para cálculo de desempenho da UTI.

A métrica de complexidade $\psi(c, \gamma_c)$ abstrai aspectos relacionadas ao arranjo espacial do sistema, dado por interações espaço-temporais, de forma alternativa à métrica proposta por Koorehdavoudi e Bogdan (2016), definida como o produto entre emergência e auto-organização, ambas características calculadas com base na definição de informação em falta (ou entropia) de acordo com Shannon (1948). A métrica proposta $\psi(c, \gamma_c)$ captura o arranjo espacial em termos de **conexões** e utiliza a concepção de entropia para quantificar a influência da incerteza dentro do sistema, a qual é somada à influência da incerteza gerada por forças externas calculada por meio da análise de sensibilidade.

A análise de sensibilidade é indicada para integrar à métrica de complexidade, pois mesmo parâmetros considerados menos importantes pela análise de incerteza, devido à baixa variabilidade, podem conduzir a mudanças significativas na saída do modelo (HAMBY, 1994). Assim a métrica de complexidade que se baseia em conexões ponderadas por **índices de sensibilidade** é capaz de capturar o grau de complexidade do sistema como a combinação entre ordem e desordem, regularidade e aleatoriedade, como discutido por Kurths et al. (1994).

Por exemplo, a aplicação da métrica de complexidade $\psi(c, \gamma_c)$ utilizada no sistema do motor de corrente contínua com controlador PID, cujo modelo possui variáveis contínuas e tempo contínuo, observou-se que quando o motor estava em operação, todas as conexões estavam ativas com probabilidade de ocorrência igual a 1, de forma que a segunda parte da métrica $\psi(c, \gamma_c)$ em (5.8) era *zero*. Se qualquer conexão estivesse inativa, o sistema não funcionaria. Logo a **incerteza** no sistema foi atribuída à mudança nos parâmetros (tensão de campo e ganhos do controle), os quais foram avaliadas por meio da análise de sensibilidade.

Este exemplo do motor de corrente contínua indica que métricas como dimensão fractal não poderiam ser usadas neste caso, devido a ausência de padrões geométricos descritos no espaço de fase. Mesmo para outros tipos de sistemas, como o sistema de desenvolvimento de *startups* e a unidade de terapia intensiva, a dimensão fractal não seria efetiva, uma vez que os arranjos observáveis durante a simulação são abstrações realizadas do sistema em operação, que provavelmente não teriam auto-similaridade. Assim, a métrica proposta quantifica a complexidade relacionada à dinâmica do

sistema em diversos contextos.

A métrica de complexidade $\psi(c, \gamma_c)$ considera tanto a dificuldade de descrever o sistema como seu grau de organização. A configuração do sistema modelada em termos de conexões é utilizada para descrevê-lo, enquanto o grau de organização é definido pela **relevância das conexões**, dada por medidas de sensibilidade. Estas medidas podem ser calculadas por métodos locais ou globais. Embora os métodos propostos de análise de sensibilidade utilizem abordagem local, os índices de sensibilidade calculados distoaram nos resultados obtidos. Os índices calculados pelo método da variância condicional local foram os que mais se aproximaram dos valores encontrados pelo método global. Todavia o método da área apresentou-se adequado para indicar parâmetros mais ou menos sensíveis, além de ser aplicado a contextos com número reduzido de cenários para análise.

Considerando a diversidade de métodos de análise de sensibilidade existentes, somados às metodologias propostas, recomenda-se desenvolver pesquisa sobre qual método é mais indicado para compor a metodologia de cálculo da complexidade $\psi(c, \gamma_c)$. Se métodos globais forem aplicados, o tempo consumido na simulação dos sistemas pode ser considerável comparado à análise local, contudo esta análise não é indicada se os valores-base dos parâmetros estiverem na região de instabilidade do sistema. A análise de sensibilidade global pode resolver este problema, por compreender regiões de **instabilidade** e **estabilidade** do sistema analisado, de forma que o impacto da não-linearidade em toda região de operação do sistema seja considerada. Esta análise estende-se à complexidade natural do sistema $\psi_n(c, \gamma_c)$, que pode ser local ou global, dependendo do método de análise de sensibilidade utilizado.

Quando a complexidade natural calculada for local, é recomendado fazer estudo de **robustez** para avaliar quão insensível o sistema é à mudança nos parâmetros. No sistema de UTI, por exemplo, os índices de sensibilidade dos parâmetros apresentaram valores entre 11 e 25 quando o sistema atuou em sua complexidade natural. Estes valores indicam que todos os parâmetros são relativamente sensíveis, de forma balanceada. Neste caso, seria necessário avaliar se esta configuração do sistema é robusta bem como configurações distintas, porém próximas do ponto otimizado, a fim de definir região de robustez, que seria também a região de complexidade natural do sistema.

Embora a **métrica de complexidade** $\psi(c, \gamma_c)$ seja uma entre tantas outras, a concepção da complexidade natural dos sistemas destaca-se como tema para investigações futuras. As metodologias propostas e a utilização de $\psi_n(c, \gamma_c)$ como referência

apresentaram-se eficazes em sistemas a eventos discretos abertos, em que o tamanho da fila pode indicar carga de trabalho do sistema. Faz-se necessário verificar a hipótese básica em outros tipos de modelo, com variável e tempo contínuos, variável contínua e tempo discreto ou variável e tempo discretos. Entende-se que o problema de medir a complexidade seja análogo ao problema de descrever o eletromagnetismo antes das equações de Maxwell (LLOYD, 2001), contudo os estudos realizados poderão ser unidos por metodologia a ser desenvolvida. A ideia de complexidade natural, por exemplo, pode ser aplicada utilizando métricas distintas de complexidade de sistemas.

CAPÍTULO 7

CONCLUSÃO

O conceito de **complexidade natural de sistemas** foi proposto neste trabalho juntamente com métricas de análise de sensibilidade e de complexidade de sistema. Os sistemas estudados foram modelados em termos de conexões e analisados com base nos fluxos com o ambiente, a partir de variações nos parâmetros de entrada e consequente impacto nas variáveis de saída. Assim, utilizando índices de sensibilidade, cada conexão foi ponderada de acordo com sua relevância.

De forma geral, a análise de sensibilidade pode ser utilizada com intuito de: i) quantificar a sensibilidade dos parâmetros, ii) entender as relações entre os parâmetros de entrada e a saída e iii) verificar a robustez da solução otimizada. Neste caso, estudos sobre **robustez** podem contribuir para definir faixa de complexidade natural do sistema, de forma que o sistema atue com eficácia e eficiência mesmo sofrendo alguma alteração.

Verificou-se que a medida de complexidade com base em conexões ponderadas $\psi(c, \gamma_c)$ englobou diferentes aspectos do **sistema**: arranjo (dado pelas conexões), configuração (obtida por meio do ajuste dos parâmetros), desempenho (utilizado como saída no cálculo dos índices de sensibilidade que compuseram a relevância das conexões) e carga de trabalho (verificada pelo número de conexões).

Considerando a carga de trabalho do sistema como um todo, a hipótese básica de que o sistema estaria ocioso ou sobrecarregado se estivesse com nível de complexidade diferente da complexidade natural $\psi_n(c, \gamma_c)$ foi corroborada. Complexidade inferior à $\psi_n(c, \gamma_c)$ indicou ociosidade e complexidade superior à $\psi_n(c, \gamma_c)$ foi indicativo de sobrecarga do sistema. Com base no nível de saturação da complexidade, pôde-se afirmar que a **complexidade** natural é a **mínima** necessária para manter o sistema em atividade regular e com desempenho elevado.

7.1 Contribuições do trabalho

As contribuições deste trabalho podem ser descritas em termos de publicações durante o período de doutoramento.

Artigos publicados em revista:

GOMES, VIVIANE M.; PAIVA, JOAO R. B.; REIS, MARCIO R. C.; WAI-

NER, GABRIEL A.; CALIXTO, WESLEY P.. Mechanism for Measuring System Complexity Applying Sensitivity Analysis. COMPLEXITY, v. 2019, p. 1-12, 2019. DOI: http://dx.doi.org/10.1155/2019/1303241

PAIVA, J. R. B.; **GOMES, VIVIANE M.**; RODRIGUES, B. A.; SILVA, L. F. A.; ANICETO, B. C. M.; FURRIEL, G. P.; CALIXTO, W.P.. Metric for Calculation of System Complexity based on its Connections. Transactions on Environment and Electrical Engineering, v. 2, p. 67, 2016. DOI: http://teee.eu/index.php/TEEE/article/view/80

Artigos publicados em congresso:

PAIVA, JOAO R.B.; **GOMES, VIVIANE M.**; REIS, MARCIO R.C.; WAINER, GABRIEL; CALIXTO, WESLEY P.. Relationship Between Risk and Complexity in System Using Connection Based Metric. In: 2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), 2018, Palermo. 2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), 2018. p. 1. DOI: http://dx.doi.org/10.1109/eeeic.2018.8493772

SARAIVA, JULYANA P.; LIMA, BEATRIZ S.; **GOMES, VIVIANE M.**; FLORES, PAULO H. R.; GOMES, FLAVIO A.; ASSIS, ALFREDO O.; REIS, MARCIO R. C.; ARAUJO, WANDERSON R. H.; ABRENHOSA, CALEBE; CALIXTO, WESLEY P.. Calculation of sensitivity index using one-at-a-time measures based on graphical analysis. In: 2017 18th International Scientific Conference on Electric Power Engineering (EPE), 2017, Kouty nad Desnou. 2017 18th International Scientific Conference on Electric Power Engineering (EPE), 2017. p. 1. DOI: http://dx.doi.org/10.1109/epe.2017.7967329

GOMES, VIVIANE M.; ASSIS, ALFREDO O.; MATIAS, CALEBE A.; SARAIVA, JULYANA P.; GOMES, FLAVIO A.; WAINER, GABRIEL A.; LIMA, BEATRIZ S.; MAGALHAES, ALANA S.; CALIXTO, WESLEY P.; FLORES, PAULO H. R.; BULHOES, JUNIO S.. Analytical method for calculating the sensitivity index of system parameters. In: 2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2017, Pucon. 2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2017. p. 1-762. DOI: https://ieeexplore.ieee.org/document/8229723

MAGALHAES, ALANA S.; BULHOES, JUNIO S.; MATIAS, CALEBE A.; SILVA, ALAN H. F.; FURRIEL, GEOVANNE P.; REIS, MARCIO R. C.; WAINER, GABRIEL A.; **GOMES, VIVIANE M.**; CALIXTO, WESLEY P.; ALVES, AYLTON J.. Sensitivity analysis of the synchronous generation repowering system in parallel with induction generator. In: 2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2017, Pucon. 2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2017. p. 1. DOI: https://ieeexplore.ieee.org/document/8229726

PAIVA, JOAO R. B.; **GOMES, VIVIANE M.**; OLIVEIRA, SOSTENES G. M.; DOMINGUES, ELDER G.; ALVES, AYLTON J.; DA CRUZ, GELSON; CALIXTO, WESLEY P.. Calculation of system complexity based on the connections: Methodology and applications. In: 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016, Florence. 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC). p. 1. DOI: https://ieeexplore.ieee.org/document/7555582

SANTOS, LUCIANO; SILVA, CLEBES; PAIVA, JOAO; **GOMES, VIVIANE**; OLIVEIRA, SOSTENES; ALVES, AYLTON; CALIXTO, WESLEY. A methodology for calculation of complexity in systems: Case study. In: 2015 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2015, Santiago. 2015 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON). p. 83-88. DOI: https://ieeexplore.ieee.org/document/7400357

GOMES, VIVIANE M.; PAIVA, JOAO R. B.; FURRIEL, GEOVANNE P.; ANICETO, BRUNO C. M.; SILVA, LAIS F. A.; CALIXTO, WESLEY P.; DOMINGUES, ELDER G.; CRUZ JUNIOR, GELSON; RODRIGUES, BERNARDO A.. COMPLEXITY METRIC APPLIED TO DISCRETE EVENTS SYSTEMS. In: 6th International Conference on Nonlinear Science and Complexity, 2015, São José dos Campos - SP. DOI: 10.20906/CPS/NSC2016-0077

7.2 Demais trabalhos publicados durante o período do doutoramento

GOMES, F. A.; CALIXTO, W.P.; **GOMES, V. M.**. Otimização aplicada à identificação de sistemas. 1. ed. Novas Edições Acadêmicas, 2018. 116p .

OLIVEIRA, K. C.; CASTRO, M. A.; SOUZA, M. A. R.; SOUSA, M. S.; LAGE,

M. M.; ARBEX, Q. P. F.; SOUZA, R. R.; **GOMES, V. M.**. Centro de Inovação Tecnológica e alguns recortes da produção intelectual no IFG: cenários, perspectivas e desafios. In: Walmir Barbosa; Ruberley Rodrigues de Souza; Mara Rúbia Souza Rodrigues Morais. (Org.). Instituto Federal de Goiás: História, Reconfigurações e Perspectivas. 1ed. Goiânia: Editora IFG, 2016, v. 3, p. 181-210.

ANICETO, BRUNO C. M.; VILELA, WAGNER A.; NETO, JOAO CAETANO; RODRIGUES, BRUNO U.; CARARO, JOSE A. G.; **GOMES, VIVIANE M.**; SILVA, ALAN H. F.; FREITAS, JOSE L.; SILVA, DANIEL C.; GOMES, FLAVIO A.; SANTOS, PAULO V.; NIELSON, RAFAEL; REIS, MARCIO R. C.; GALVAO, NATALIA K. M.; ALVES, AYLTON J.; SILVA, LAIS F. A.; CALIXTO, WESLEY P.. Calculation and analysis of voltage violation problem on electricity distribution networks. In: 2017 18th International Scientific Conference on Electric Power Engineering (EPE), 2017, Kouty nad Desnou. 2017 18th International Scientific Conference on Electric Power Engineering (EPE), 2017. p. 1.

RODRIGUES, B. A.; PAIVA, J. R. B.; **GOMES, V. M.**; MORRIS, C.; CALIXTO, W.P.. Passfault: an Open Source Tool for Measuring Password Complexity and Strength. In: The 8th International Multi-Conference on Complexity, Informatics and Cybernetics, 2017, Orlando, Florida, USA. The 8th International Multi-Conference on Complexity, Informatics and Cybernetics, 2017.

CASTRO JUNIOR, A. P.; CALIXTO, W.P.; **GOMES, V. M.**; SILVA, L.F.A.; CAMPOS, P. H. M.; VEIGA, E. F.. Ontology to Mining Judicial Sentence's Big Data. In: ICAEEdu 2017 International Conference on Alive Engineering Education, 2017, Rio de Janeiro, Brazil. ICAEEdu 2017 International Conference on Alive Engineering Education, 2017.

SILVA, LAIS F. A.; DA SILVA, MICHELLE C.; ALVES, AYLTON J.; REIS, MARCIO R. C.; BULHOES, JUNIO S.; COSTA, RODRIGO E.; SILVA, BRUNNA C. R.; ALEIXO, EVERTON L.; **GOMES, VIVIANE M.**; CALIXTO, WESLEY P.. Socioeconomic, scientific and technological indicators as parameters for prediction model. In: 2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2017, Pucon. 2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2017. p. 1.

CASTRO, ANTONIO P.; CALIXTO, WESLEY P.; **GOMES, VIVIANE M.**; VEIGA, ERNESTO F.; SILVA, LAIS F. A.; CASTRO, LAYZA L. OLIVEIRA P.;

BARBOSA, JOSE LUIZ FERRAZ; CAMPOS, PEDRO H. M.. Ontology applied in the judicial sentences. In: 2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2017, Pucon. 2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2017. p. 1.

GOMES, FLAVIO A.; **GOMES, VIVIANE M.**; ASSIS, ALFREDO DE O.; REIS, MARCIO R. DA C.; DA CRUZ, GELSON; CALIXTO, WESLEY P.. Heuristic regression method for descriptive data analysis. In: 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016, Florence. 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016. p. 1.

DE LIMA, RODRIGO ALVES; COIMBRA, A. C. PAULO; ALMEIDA, TONY; **GOMES, VIVIANE MARGARIDA**; PEREIRA, THIAGO MARTINS; ALVES, AYLTON JOSE; CALIXTO, WESLEY PACHECO. Influence of slot geometry on air gap magnetic flux density of rotating machines. In: 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016, Florence. 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC). p. 1.

PEREIRA, THIAGO MARTINS; DE LIMA, RODRIGO ALVES; **GOMES, VIVIANE MARGARIDA**; GUTEMBERGUE, SOSTENES; ALVES, AYLTON JOSE; CALIXTO, WESLEY PACHECO. Soil resistivity study and simulation with finite elements method. In: 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016, Florence. 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016. p. 1.

OLIVEIRA, DIOGO N.; SILVA, CARLOS L.B.; CALIXTO, WESLEY P.; ALVES, AYLTON J.; **GOMES, VIVIANE**; DOMINGOS, JOSE LUIS. Heuristic methodology for horizontal multilayer soil stratification. In: 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016, Florence. 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016. p. 1.

CALIXTO, W. P.; NOBRE, F. S.; ALVES, A. J.; DOMINGUES, E. G.; DOMINGOS, J. L.; PIRES, T. G.; FERRAZ, R. S.; **GOMES, V. M.**. Methodology for 3D mapping soil electrical conductivity: A case study. In: 2015 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies

(CHILECON), 2015, Santiago. 2015 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON), 2015. p. 511-516.

SILVA, L.F.A.; **GOMES, V. M.**; SILVA, M. C.; VEIGA, E. F.; OLIVEIRA FILHO, R. M.; COSTA, R. E.; CALIXTO, W.P.. Patentes e Inovação: Fatores de Impacto para o Desenvolvimento Socioeconômico e Sustentável. In: IX ENAPID - Encontro Acadêmico de Propriedade Intelectual, Inovação e Desenvolvimento, 2016, Florianópolis, Brasil. IX ENAPID, 2016.

7.3 Trabalhos futuros

Com base nos resultados deste trabalho, verificaram-se lacunas a serem respondidas em trabalhos futuros, quais sejam:

- a complexidade natural é a complexidade mínima do sistema em atividade regular para distintos sistemas,
- existe correlação entre os picos e vales de complexidade e os parâmetros mais sensíveis,
- o monitoramento do sistema utilizando a complexidade natural como referência conduz a ações de intervenção que modificam sua organização ou configuração,
- além de sistemas a eventos discretos, outros tipos de modelo (com variável e tempo contínuos, variável contínua e tempo discreto ou variável e tempo discretos) apresentam diferenças significativas dos valores de complexidade quando o sistema atua em sua complexidade natural comparado a quando está ocioso ou sobrecarregado,
- a modelagem em termos de conexões é capaz de apreender características internas dos elementos do sistema,
- a região de robustez da solução otimizada define a faixa de complexidade natural do sistema,
- as diferenças dos índices obtidos pelos métodos propostos de análise de sensibilidade são significativas,
- qual método de análise de sensibilidade é indicado para compor a metodologia de cálculo da complexidade $\psi(c, \gamma_c)$,

- além do desempenho, quais aspectos do sistema podem ser utilizados como variável de saída para realizar análise de sensibilidade e posterior cálculo da relevância de cada conexão do sistema,
- como a aplicação de diferentes distribuições de probabilidade nos modelos influencia na análise de complexidade,
- a métrica de complexidade $\psi(c, \gamma_c)$ retorna resultados coerentes tanto se aplicada a sistemas naturais quanto produzidos por humanos,
- a métrica de desempenho do sistema de unidade de terapia intensiva deve penalizar a lotação de cada unidade.

APÊNDICE A

Estudos anteriores às metodologias propostas

A.1 Motivação para proposta da complexidade natural dos sistemas

Estudos preliminares sobre complexidade de sistemas conduziram à metodologia deste trabalho, particularmente à proposta de nível de complexidade que seja natural para cada sistema. Utilizando simulação a eventos discretos, a complexidade foi medida em dois modelos distintos: i) centro de distribuição e ii) centro médico, retirados do trabalho de Paiva (2016). As medições foram realizadas a partir de modelagem que se baseia em conexões (Seção 3.4.1) e em quantidade de informação (Seção 3.4.2).

Como parte da análise desenvolvida, a sensibilidade dos parâmetros foi calculada em torno do ponto dado pelo menor valor da relação entre complexidade e desempenho. A partir dos resultados obtidos, a métrica com base em conexões pôde ser atualizada, tendo sua acurácia melhorada por meio da análise de sensibilidade.

A.1.1 Estudo de caso 1: centro de distribuição

O modelo do centro de distribuição consiste da logística de entrega de produtos. Os produtos vendidos são separados em quantidade adequada de carga para transporte no caminhão, que corresponde a uma ordem de entrega. Durante a operação do centro de distribuição, os seguintes passos são executados: 1) as ordens de entrega são geradas e mantidas em fila, 2) quando o carregamento é liberado, o caminhão estaciona na doca e o grupo de trabalhadores coloca a carga no caminhão, 3) encerrado o carregamento, a doca e o grupo de trabalhadores são desalocados e o caminhão realiza o transporte dos produtos ao destino, 4) o caminhão retorna ao centro de distribuição.

O duração de cada passo corresponde às distribuições de probabilidade: $Z_1 \sim Exp(120)$, $Z_2 \sim N(100, 30)$, $Z_3 \sim U(120, 240)$ e $Z_4 \sim U(120, 240)$, respectivamente. A quantidade de recursos usados na simulação variam de 1 a 10 docas, 1 a 15 caminhões e 1 a 10 grupos de trabalhadores, compondo 1500 cenários. A simulação foi executada para 180 dias por cenário, considerando 24 horas diariamente de operação. Nos cenários simulados, a complexidade com base em conexões $\psi(c)^{cd}$ e o tempo de entrega t_e foram calculados, em que t_e corresponde ao tempo decorrido desde o momento que a ordem de entrega foi gerada até o momento em que os produtos são entregues ao cliente.

Os valores normalizados de t_e e $\psi(c)^{cd}$ para todos os cenários são apresentados na Figura A.1. Cada cenário representa dada configuração do sistema, caracterizado pela combinação dos recursos (docas, caminhões e grupos de trabalhadores), nesta ordem. Na Figura A.1, os picos de t_e (em azul) correspondem às combinações em que havia apenas um caminhão. A cada mudança no número de docas, um caminhão era usado durante 10 cenários, levando aos maiores valores de t_e e $\psi(c)^{cd}$ (em vermelho). As oscilações que ocorrem entre valores de $0,1$ e $0,3$ de $\psi(c)^{cd}$ decorrem de alterações no número de caminhões, indicando maior sensibilidade neste parâmetro do sistema.

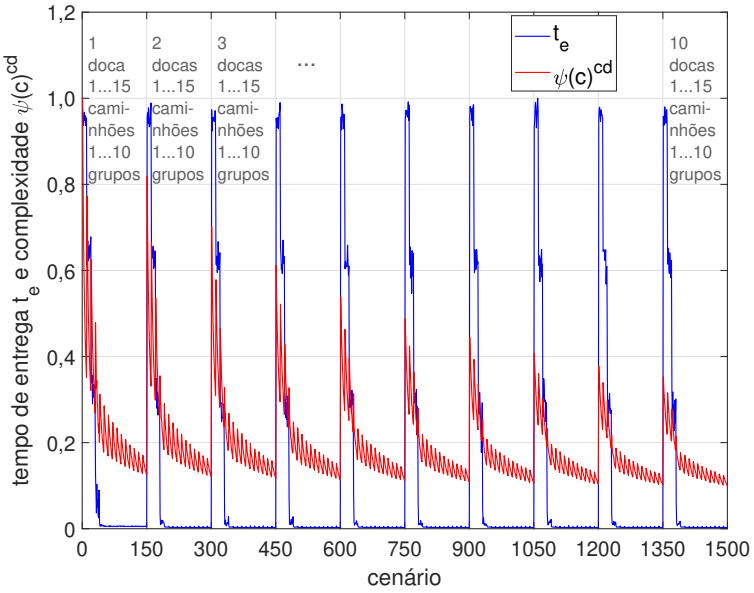

Figura A.1 - Medidas do tempo de entrega t_e e de complexidade $\psi(c)^{cd}$ relacionadas aos cenários do centro de distribuição.

Ao analisar a Figura A.1, observa-se que quando o número de caminhões é > 6, os valores de t_e se aproximam de *zero*. Nos 1500 cenários, a menor complexidade é $\psi(c)^{cd} = 0,2768$, que corresponde ao menor tempo de entrega e ao cenário com o número máximo de recursos disponíveis, conforme disposto na Tabela A.1. O maior tempo de entrega é $t_e \approx 340\times$ maior que o menor tempo e corresponde à maior complexidade e ao menor número de recursos.

A medida de complexidade é caracterizada pela observação do sistema como todo, uma vez que as conexões são computadas nos diversos estados do sistema. Desta forma, verificou-se que a relação R_c^{cd} entre a medida de desempenho e a complexidade, expressa por (A.1), pode sinalizar configurações ótimas ou otimizadas.

$$R_c^{cd} = \frac{t_e}{\psi(c)^{cd}} \tag{A.1}$$

Tabela A.1 - Índice R_c^{cd} como relação entre tempo de entrega t_e e complexidade $\psi(c)^{cd}$.

t_e	$\psi(c)^{cd}$	R_c^{cd}	n_{doca}	$n_{caminhão}$	n_{grupo}
$2,81 \cdot 10^2$	0,277	0,007	10	15	10
$3,15 \cdot 10^2$	0,686	0,003	2	6	2
$9,46 \cdot 10^4$	2,778	0,222	1	1	1
$9,46 \cdot 10^4$	0,617	1	10	1	10

Os valores mínimos (em azul) e máximos (em vermelho) de t_e, $\psi(c)^{cd}$ e R_c^{cd} normalizado estão dispostos na Tabela A.1 seguidos da respectiva configuração, dada pelo número de docas n_{doca}, número de caminhões $n_{caminhão}$ e o número de grupo de trabalhadores n_{grupo}. O menor valor de R_c^{cd} refere-se a $t_e = 3,15 \cdot 10^2$, apenas $1,12\times$ o valor mínimo de t_e, enquanto o montante de recursos foi aproximadamente 72% inferior ao cenário com t_e mínimo. O desempenho do sistema foi $300\times$ maior do que o pior caso e apenas $0,11\times$ menor do que no melhor caso. Isso mostra que o uso de recursos foi otimizado, uma vez que o valor da razão R_c^{cd} indica o menor custo em termos de complexidade para cada minuto de permanência das entidades (ordens de entrega) no sistema.

Na Tabela A.1, observa-se que o maior tempo de entrega t_e refere-se aos cenários com apenas um caminhão para entrega dos produtos, mesmo quando a quantidade dos outros recursos (doca e grupo de trabalhadores) foi máxima: configuração verificada para R_c^{cd} máximo. Este resultado conduziu à análise de sensibilidade do sistema, pois a escassez do recurso caminhão ocasionou impacto considerável em t_e e $\psi(c)^{cd}$.

A fim de realizar a análise de sensibilidade, assume-se que a configuração dada pelo menor valor de R_c^{cd} corresponde ao caso-base, como apresentado na Tabela A.2. Os parâmetros do sistema são os recursos: doca, caminhão e grupo de trabalhadores. O intervalo escolhido para variação dos parâmetros limitou-se a valores entre -100% a 100% do valor-base, dispostos na Tabela A.2. A complexidade $\psi(c)^{cd}$ foi a saída considerada para calcular os índices de sensibilidade.

Tabela A.2 - Dados para análise de sensibilidade do centro de distribuição.

parâmetro	**faixa de variação**	**valor-base**
n_{doca}	$1-4$	2
$n_{caminhão}$	$1-12$	6
n_{grupo}	$1-4$	2

Os índices de sensibilidade foram calculados utilizando o método da área (Seção 5.1.1), que mede quanto a área entre a curva do parâmetro (dada pelo diagrama-aranha) e o eixo-base representa em relação à soma das áreas de todos os parâmetros. Antes de aplicar este método, dois intervalos foram escolhidos para análise. O primeiro intervalo possui curvas de variação de -100% a 100% e o segundo, refere-se ao intervalo em que todos os parâmetros variam em torno dos valores-base.

O diagrama-aranha do centro de distribuição é apresentado na Figura A.2, em que a saída do modelo é a complexidade $\psi(c)^{cd}$. Como observado no diagrama-aranha, quanto menor a quantidade do recurso caminhão, maior a sensibilidade do sistema às alterações neste parâmetro, especialmente entre -100% e -30%.

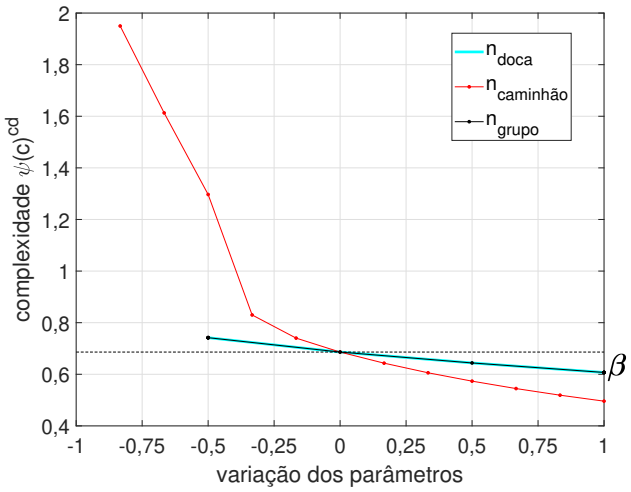

Figura A.2 - Diagrama-aranha do centro de distribuição para saída $\psi(c)^{cd}$.

De acordo com os valores apresentados na Tabela A.3, o recurso caminhão apresentou o maior índice de sensibilidade, igual a 82% para o intervalo $[-1; 1]$ e 64% para o intervalo $[-0,5; 1]$, onde há variação de todos os parâmetros. A alteração de valores deste parâmetro inferior a -30% do valor-base ocasionou alto impacto no desempenho do sistema, situação em que havia menos de cinco caminhões no centro de distribuição.

Tabela A.3 - Índice de sensibilidade dos parâmetros do centro de distribuição para a saída $\psi(c)^{cd}$.

intervalo	S^a_{doca}	$S^a_{caminhão}$	S^a_{grupo}
$[-1; 1]$	$0,09$	$0,82$	$0,09$
$[-0,5; 1]$	$0,18$	$0,64$	$0,18$

Os recursos doca e grupo de trabalhadores apresentaram os mesmos valores para índices de sensibilidade, igual a 9% para o intervalo $[-0,83;1]$ e 18% para o intervalo $[-0,5;1]$. Como pode ser observado na Figura A.2, estes recursos têm impacto pouco expressivo na saída do modelo e apresentam comportamento linear. Isto ocorre devido à dinâmica do centro de distribuição basear-se, majoritariamente, no uso do recurso caminhão.

O caso-base para o centro de distribuição, ou seja, 2 docas, 6 caminhões e 2 grupos de trabalhadores, pode ser considerado uma solução otimizada e robusta para a mudança de parâmetros entre -15% e 15%. Nesta faixa, a complexidade apresentou baixa variação, $0,64 \leq \psi(c)^{cd} \leq 0,74$, ou seja, o aumento ou a diminuição de recursos em uma unidade manteve os níveis de operação adequada do sistema.

Utilizando o modelo do centro de distribuição, aplicou-se ainda a métrica que se baseia na quantidade de informação (Seção 3.4.2). A Tabela A.4 apresenta a matriz resposta do sistema com as ações (entradas) e os objetivos (saídas), em que r_{ij}^{cd} corresponde à frequência de uso dos recursos do centro de distribuição, as ações referem-se à utilização dos recursos e os objetivos referem-se a fases de operação do centro de distribuição.

Tabela A.4 - Matriz resposta para o centro de distribuição.

ação/objetivo	**carregamento**	**transporte**
utilizar doca	r_{11}^{cd}	0
utilizar caminhão	r_{21}^{cd}	r_{22}^{cd}
utilizar grupo de trabalhadores	r_{31}^{cd}	0

Todos os recursos (doca, caminhão e grupo de trabalhadores) estão envolvidos na realização do objetivo carregamento. Diferentemente do objetivo transporte, em que apenas o recurso caminhão participa desta fase. Por isso, as frequências de uso dos recursos doca e grupo de trabalhadores referente ao objetivo transporte são nulas.

A Figura A.3 apresenta os valores normalizados de complexidade para 1500 cenários de simulação do centro de distribuição obtidos pela métrica de complexidade com base em conexões $\psi(c)^{cd}$ e em quantidade de informação $\psi(H)^{cd}$.

Pode-se observar na Figura A.3 que a complexidade dada por $\psi(c)^{cd}$ apresenta-se mais adequada, pois estabelece padrão a cada ciclo de 150 cenários e como um todo, diferentemente de $\psi(H)^{cd}$. No padrão de comportamento da medida de complexidade com base em conexões $\psi(c)^{cd}$, verifica-se decréscimo dos valores de picos de

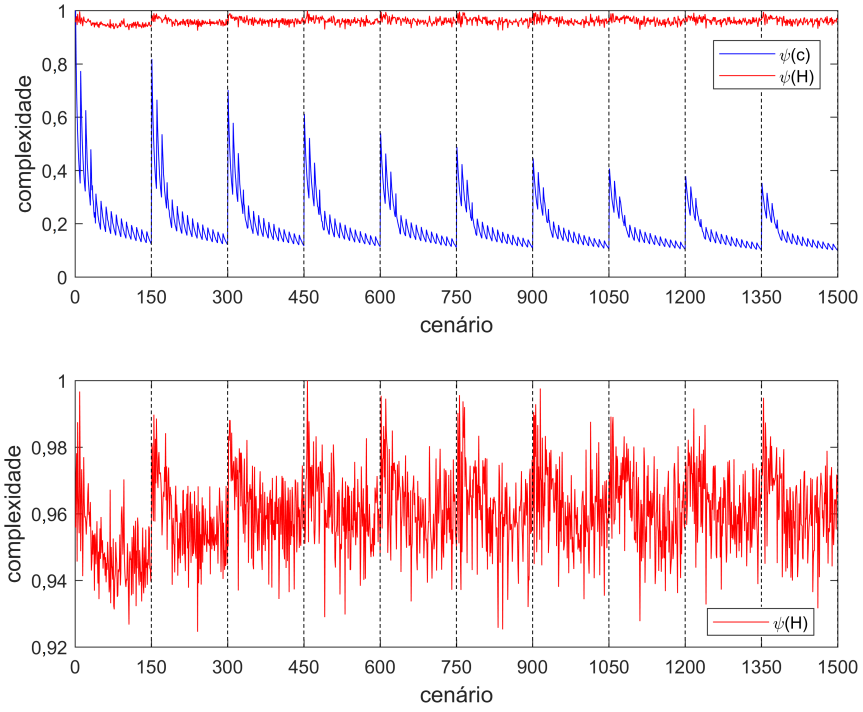

Figura A.3 - Comparação entre medidas de complexidade $\psi(c)^{cd}$ e $\psi(H)^{cd}$ para o centro de distribuição.

complexidade à medida que o número de recursos aumenta, em que casa ciclo corresponde a certa quantidade de docas combinada a configurações de 1 a 15 caminhões e de 1 a 10 grupos de trabalhadores.

A.1.2 Estudo de caso 2: centro médico

O centro médico consiste no processo de cuidados médicos e procedimentos básicos que segue o seguinte fluxo: 1) os pacientes chegam ao centro médico, 2) os pacientes aguardam consulta, 3) os pacientes recebem o atendimento médico, 4) após a consulta, alguns pacientes são liberados e outros encaminhados para 5) realizar procedimentos básicos (receber medicação ou fazer exames), 6) após medicação ou exames, alguns pacientes são liberados, outros, realizam novos exames ou tomam mais medicamentos, retornando ao passo 5, e alguns deles esperam na fila para voltar ao médico, 7) após nova consulta médica, alguns pacientes são encaminhados para exames complementares ou medicação retornando ao passo 5, enquanto os demais deixam o centro médico.

A simulação do centro médico foi realizada de acordo com a dinâmica de fluxo de pacientes, em que eles: 1) chegam ao centro médico seguindo distribuição probabi-

lística $Z_5 \sim Exp(5)$, 2) aguardam consulta médica na fila Q_1, 3) são atendidos pelo médico por período dado por distribuição $Z_6 \sim N(15, 5)$, 4) depois da consulta, 1% dos pacientes são liberados e 99% são encaminhados para 5) receber cuidados básicos, em que 5a) 40% deles aguardam na fila Q_2 para receber medicação e 5b) 60% deles aguardam na fila Q_3 para fazer exames médicos, 6) depois da medicação ou exames, 10% destes pacientes são liberados, 40%, são submetidos a novos exames ou tomam mais medicação retornando ao passo 5 e 50%, esperam na fila Q_4 para retornar ao médico; 7) após consulta, 40% dos pacientes são encaminhados a exames ou medicacão adicionais retornando ao passo 5 e os outros 60% deixam o centro médico. O tempo de medicação segue distribuição probabilística de $Z_7 \sim N(20, 5)$, a duração dos exames segue distribuição $Z_8 \sim N(15, 5)$ e a consulta de retorno ao médico dura $Z_9 \sim N(10, 5)$. Os valores de tempo são dados em minutos.

O número de médicos, técnicos e enfermeiros utilizados na simulação variou de 3 a 8, 2 a 10 e 5 a 15, respectivamente, compondo 594 cenários diferentes. A simulação foi realizada por 180 dias por cenário, considerando 24 horas diárias de operação. O tempo gasto dentro do centro médico pelo paciente t_p (em minutos) e a complexidade $\psi(c)^{cm}$ do sistema foram calculados para todos os cenários.

A menor complexidade obtida em todos os cenários, $\psi(c)^{cm} = 0,2407$, ocorreu quando o número máximo de recursos foi utilizado, ou seja, 8 médicos, 10 técnicos e 15 enfermeiros. A maior complexidade, $\psi(c)^{cm} = 0,8105$, ocorreu quando havia o número mínimo de recursos, ou seja, 3 médicos, 2 técnicos e 5 enfermeiros, consequentemente, longos tempos de espera.

A Figura A.4 apresenta os valores percentuais de utilização de recursos e a medida de complexidade normalizada para todos os cenários. Pode-se observar que nos 200 cenários iniciais, onde havia menos de 5 médicos, a utilização deste recurso obteve valores entre $0,9$ e 1. Os picos de complexidade ocorreram sempre que o número de médicos foi aumentado, mas o número de enfermeiros e o número de técnicos foram mínimos, causando aumento no tamanho das filas Q_2 e Q_3.

No cenário de menor complexidade, o tempo que os pacientes ficaram no centro médico foi de aproximadamente $14,9$; $58,7$; $71,13$ e $74,07$ minutos para aqueles que saíram: i) sem exame ou medicação, ii) depois de fazer os exames e/ou tomar medicação, iii) após retorno ao médico e 4) após todos os procedimentos, respectivamente. Para o cenário com maior complexidade, os tempos foram de $774,68$; $1032,20$; $1191,25$ e $1128,28$ minutos, respectivamente, devido ao tempo nas filas.

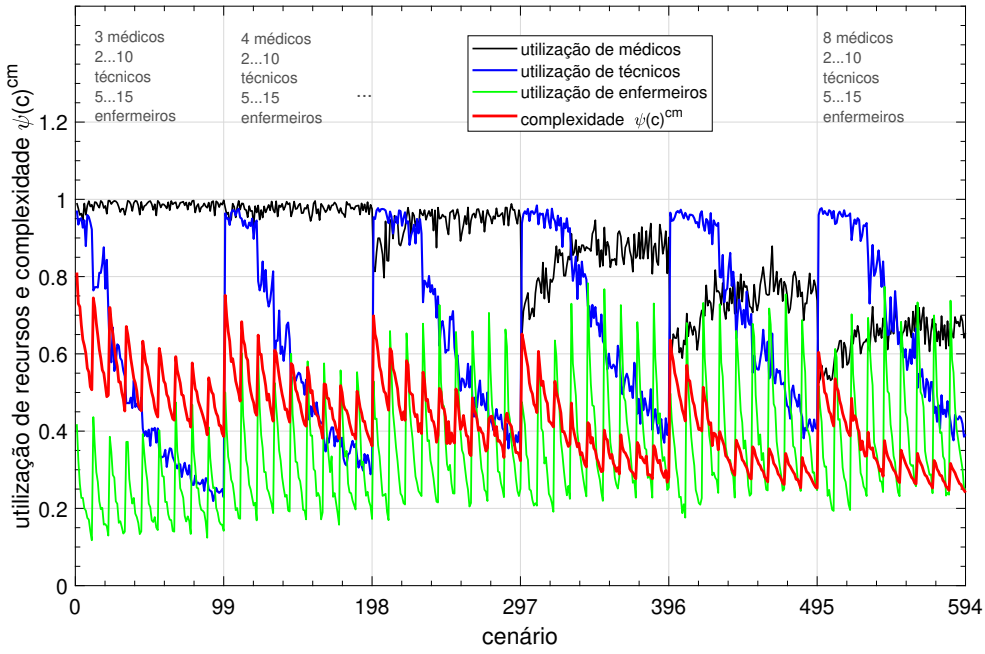

Figura A.4 - Utilização de recursos e a complexidade $\psi(c)^{cm}$ relacionados aos cenários do centro médico.

Considerando a relação entre as medidas de desempenho e de complexidade para o centro médico, dada por (A.2), os valores mínimo (em azul) e máximo (em vermelho) de t_p, $\psi(c)^{cm}$ e R_c^{cm} normalizado foram obtidos e estão dispostos na Tabela A.5.

$$R_c^{cm} = \frac{t_p}{\psi(c)^{cm}} \tag{A.2}$$

Tabela A.5 - Índice R_c^{cm} como relação entre tempo no centro médico t_p e complexidade $\psi(c)^{cm}$.

t_p	$\psi(c)^{cm}$	R_c^{cm}	$n_{médico}$	$n_{técnico}$	$n_{enfermeiro}$
$5,34 \cdot 10^1$	0,252	0,082	8	10	13
$5,59 \cdot 10^1$	0,241	0,089	8	10	15
$5,82 \cdot 10^1$	0,359	0,062	7	7	5
$1,16 \cdot 10^3$	0,493	0,908	3	3	15
$1,03 \cdot 10^3$	0,811	0,490	3	2	5
$1,06 \cdot 10^3$	0,410	1	3	8	15

Na Tabela A.5, observa-se que o valor mínimo de R_c^{cm}, igual a $0,062$, representa quantidade reduzida de recursos comparado a outros cenários com valores míni-

mos de t_p and $\psi(c)^{cm}$. Mesmo com menos recursos, o sistema atingiu desempenho satisfatório, apenas $0,089\times$ maior que t_p mínimo. A complexidade mínima foi obtida quando o número de recursos foi máxima e a complexidade máxima, quando o número de recursos foi mínima. Os maiores valores de todas as variáveis foram encontrados quando o número de médicos foi mínimo, indicando este parâmetro como o mais sensível no sistema.

A indicação deste parâmetro como mais sensível pode ser verificada pela análise de sensibilidade. Assumiu-se a configuração dada pelo menor valor de R_c^{cm} como caso-base, tomado como referência para determinação da faixa de variação dos parâmetros: valores entre -100% a 100% do valor-base de cada parâmetro, como disposto na Tabela A.6. O cálculo dos índices de sensibilidade foi realizado considerando a complexidade $\psi(c)^{cm}$ como saída do modelo.

Tabela A.6 - Dados para análise de sensibilidade do centro médico.

parâmetro	**faixa de variação**	**valor-base**
$n_{médico}$	$3-8$	7
$n_{técnico}$	$2-10$	7
$n_{enfermeiro}$	$5-10$	5

A análise de sensibilidade foi desenvolvida a partir da aplicação do método da área (Seção 5.1.1). Os intervalos analisados foram definidos de acordo com os seguintes critérios: i) intervalo compreendendo variação dos parâmetros de -100% a 100%, ii) intervalo abrangendo variação de mais de um parâmetro e iii) intervalo em que todos os parâmetros variam.

Com base na simulação do centro médico, a Figura A.5 apresenta o diagrama-aranha com a saída do sistema igual à complexidade $\psi(c)^{cm}$. Ao observar a Figura A.5, pode-se ver que todas as curvas têm comportamento semelhante, isto é, à medida que o número de recursos aumenta, os valores de $\psi(c)^{cm}$ diminuem.

Como apresentado na Tabela A.7, o recurso médico obteve os maiores índices de sensibilidade quando dois ou três parâmetros sofreram variação no intervalo escolhido. O índice $S^a_{médico}$ foi igual a 58% para o intervalo $[-0,57; 0,43]$ no qual mais de um parâmetro variou e 46% para o intervalo $[0; 0,14]$, referente à região de variação de todos parâmetros. No intervalo de -100% a 100%, $S^a_{médico}$ foi igual a 40%, inferior ao índice $S^a_{técnico}$, igual a 46%. Contudo, observa-se que a área da curva do parâmetro $n_{técnico}$ é maior que do parâmetro $n_{médico}$ devido ao alto impacto ocasionado no sistema quando número de técnicos $n_{técnico}$ foi mínimo.

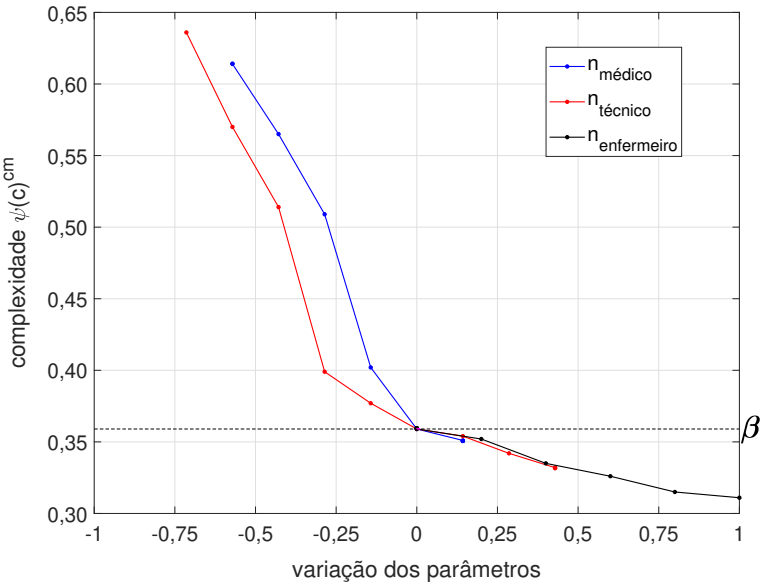

Figura A.5 - Diagrama-aranha do centro médico para saída $\psi(c)^{cm}$.

Tabela A.7 - Índice de sensibilidade dos parâmetros do centro médico para saída $\psi(c)^{cm}$.

intervalo	$S^a_{médico}$	$S^a_{técnico}$	$S^a_{enfermeiro}$
$[-1, 1]$	$0,40$	$0,46$	$0,14$
$[-0,57; 0,43]$	$0,58$	$0,39$	$0,03$
$[0; 0,14]$	$0,46$	$0,29$	$0,25$

De acordo com a análise de sensibilidade, o recurso técnico é o segundo parâmetro mais sensível, com valores dos índices $S^a_{técnico}$ iguais a 46%, 39% e 29% para os três contextos, respectivamente. Quanto ao parâmetro $n_{enfermeiro}$, pode-se observar os menores índices de sensibilidade, em que $S^a_{enfermeiro}$ obteve valores inferiores a 26%. Isto pode ser justificado pelo fato da faixa de variação do parâmetro $n_{enfermeiro}$ ser iniciada em seu valor-base, podendo variar apenas de 0% a 100%, assim não foi analisada situação de escassez do recurso enfermeiro.

Entre -15% e 20% de variação dos parâmetros, foi observado baixo impacto na saída, $0,35 \leq \psi(c)^{cm} \leq 0,40$, indicando robustez da configuração dada pelo menor R^{cm}_c, ou seja, 7 médicos, 7 técnicos e 5 enfermeiros. No entanto, quando o número de médicos foi mínimo, a complexidade foi quase o dobro do valor β (valor da saída correspondente ao caso-base).

APÊNDICE B

Medidas para análise de sensibilidade do Sistema de UTI

Os dados apresentados referem-se às medidas das variáveis: número de admissões n_a, tempo médio de internação t_s, número de pacientes na fila n_f, número de leitos em uso n_l e desempenho da UTI η_{uti}. Estas medidas foram obtidas por meio de simulação, considerando período de um ano.

Tabela B.1 - Medidas *one-at-a-time* para caso-base $\alpha_u^{12h} = (10;\ 1;\ 1,05;\ 0,12;\ 12)$.

n_{leitos}	$n_{insumos}$ [percentual]	n_{equipe} [percentual]	tx_{ea} [percentual]	$\mu_{chegada}$ [hora]	n_a	t_s [dia]	n_f	n_l	η_{uti}
1	1,00	1,05	0,12	12	35,06	10,32	336,44	1,00	0,32
5	1,00	1,05	0,12	12	102,84	10,24	294,89	4,43	0,48
10	1,00	1,05	0,12	12	175,91	9,45	246,33	9,31	0,56
15	1,00	1,05	0,12	12	198,27	9,94	233,30	9,82	0,49
20	1,00	1,05	0,12	12	195,95	9,95	232,06	9,76	0,50
10	**0,15**	1,05	0,12	12	37,23	10,19	334,19	0,64	0,32
10	**0,25**	1,05	0,12	12	44,86	9,80	328,17	1,74	0,36
10	**0,50**	1,05	0,12	12	103,00	10,08	288,86	4,49	0,49
10	**0,75**	1,05	0,12	12	153,01	9,70	259,39	7,24	0,62
10	**1,00**	1,05	0,12	12	180,36	9,75	243,35	9,30	0,56
10	**1,25**	1,05	0,12	12	177,05	9,89	241,12	9,34	0,55
10	**1,50**	1,05	0,12	12	178,92	9,78	240,83	9,34	0,55
10	**1,75**	1,05	0,12	12	183,13	9,55	241,38	9,34	0,56
10	**2,00**	1,05	0,12	12	174,00	10,09	244,89	9,34	0,54
10	1,00	**0,15**	0,12	12	35,37	11,04	334,50	0,62	0,30
10	1,00	**0,25**	0,12	12	43,40	9,76	327,88	1,72	0,36
10	1,00	**0,50**	0,12	12	105,18	9,67	288,09	4,40	0,49
10	1,00	**0,75**	0,12	12	155,23	9,48	257,04	7,22	0,62
10	1,00	**1,05**	0,12	12	185,17	9,94	240,81	9,30	0,56
10	1,00	**1,25**	0,12	12	186,30	9,40	236,64	9,31	0,57
10	1,00	**1,50**	0,12	12	185,18	9,48	241,59	9,32	0,56
10	1,00	**1,75**	0,12	12	182,88	9,57	241,86	9,31	0,56
10	1,00	**2,00**	0,12	12	180,25	9,68	241,34	9,31	0,56
10	1,00	1,05	**0,12**	12	176,41	9,94	246,62	9,31	0,55
10	1,00	1,05	**0,15**	12	173,13	10,09	243,98	9,31	0,55
10	1,00	1,05	**0,18**	12	153,99	11,30	258,91	9,29	0,52
10	1,00	1,05	**0,21**	12	147,41	11,88	262,95	9,28	0,50
10	1,00	1,05	**0,24**	12	131,90	13,21	269,98	9,25	0,48
10	1,00	1,05	0,12	**4**	181,40	9,70	723,62	9,33	0,43
10	1,00	1,05	0,12	**6**	177,61	9,87	543,04	9,32	0,48
10	1,00	1,05	0,12	**9**	182,62	9,57	352,80	9,32	0,53
10	1,00	1,05	0,12	**12**	180,36	9,69	243,35	9,31	0,56
10	1,00	1,05	0,12	**15**	178,63	9,75	169,66	9,30	0,58
10	1,00	1,05	0,12	**18**	180,67	9,69	120,18	9,27	0,60
10	1,00	1,05	0,12	**21**	188,98	9,22	83,60	9,25	0,62
10	1,00	1,05	0,12	**24**	191,68	9,11	57,76	9,20	0,64

Tabela B.2 - Medidas *one-at-a-time* para caso-base $\alpha_u^{24h} = (10;\ 1;\ 1,05;\ 0,12;\ 24)$.

n_{leitos}	$n_{insumos}$ [percentual]	n_{equipe} [percentual]	tx_{ea} [percentual]	$\mu_{chegada}$ [hora]	n_a	t_s [dia]	n_f	n_l	η_{uti}
1	1,00	1,05	0,12	24	34,31	10,49	156,73	1,00	0,36
5	1,00	1,05	0,12	24	102,85	10,23	115,59	4,42	0,53
10	1,00	1,05	0,12	24	194,13	9,36	56,70	9,20	0,63
15	1,00	1,05	0,12	24	221,88	8,67	42,18	9,71	0,59
20	1,00	1,05	0,12	24	221,59	8,74	46,24	9,67	0,60
10	**0,15**	1,05	0,12	24	38,11	9,86	154,42	0,61	0,37
10	**0,25**	1,05	0,12	24	48,12	9,17	147,03	1,76	0,42
10	**0,50**	1,05	0,12	24	110,36	9,37	110,74	4,50	0,55
10	**0,75**	1,05	0,12	24	161,33	9,00	78,34	7,16	0,68
10	**1,00**	1,05	0,12	24	197,38	9,11	57,40	9,23	0,64
10	**1,25**	1,05	0,12	24	200,37	8,61	56,46	9,25	0,64
10	**1,50**	1,05	0,12	24	197,60	8,75	55,69	9,28	0,63
10	**1,75**	1,05	0,12	24	182,68	9,48	61,66	9,24	0,62
10	**2,00**	1,05	0,12	24	186,67	9,28	59,86	9,24	0,62
10	1,00	**0,15**	0,12	24	37,67	10,01	151,98	0,62	0,36
10	1,00	**0,25**	0,12	24	41,73	10,67	149,97	1,75	0,39
10	1,00	**0,50**	0,12	24	107,64	9,60	108,13	4,48	0,54
10	1,00	**0,75**	0,12	24	161,78	9,12	76,98	7,17	0,67
10	1,00	**1,05**	0,12	24	186,18	8,94	65,08	9,22	0,63
10	1,00	**1,25**	0,12	24	196,97	8,80	56,55	9,20	0,65
10	1,00	**1,50**	0,12	24	195,26	8,87	58,91	9,19	0,64
10	1,00	**1,75**	0,12	24	188,59	9,22	62,75	9,20	0,63
10	1,00	**2,00**	0,12	24	191,11	9,12	61,31	9,22	0,63
10	1,00	1,05	**0,12**	24	198,94	8,72	55,63	9,21	0,65
10	1,00	1,05	**0,15**	24	189,20	9,20	61,39	9,22	0,63
10	1,00	1,05	**0,18**	24	162,80	10,65	77,74	9,22	0,59
10	1,00	1,05	**0,21**	24	145,13	11,95	86,79	9,19	0,56
10	1,00	1,05	**0,24**	24	132,23	13,03	92,04	9,19	0,53
10	1,00	1,05	0,12	**4**	180,04	9,73	723,11	9,32	0,43
10	1,00	1,05	0,12	**6**	182,35	9,61	538,45	9,33	0,48
10	1,00	1,05	0,12	**12**	181,06	9,63	242,29	9,31	0,56
10	1,00	1,05	0,12	**18**	184,40	9,47	118,86	9,28	0,60
10	1,00	1,05	0,12	**24**	197,38	8,78	57,40	9,22	0,64
10	1,00	1,05	0,12	**30**	193,85	8,82	24,28	9,04	0,67
10	1,00	1,05	0,12	**36**	185,06	8,81	7,60	8,49	0,75
10	1,00	1,05	0,12	**42**	172,52	8,56	1,93	7,56	0,72
10	1,00	1,05	0,12	**48**	156,58	8,47	0,66	6,61	0,68

Tabela B.3 - Medidas *one-at-a-time* para caso-base $\alpha_u^{36h} = (10;\ 1;\ 1,05;\ 0,12;\ 36)$.

n_{leitos}	$n_{insumos}$ [percentual]	n_{equipe} [percentual]	tx_{ea} [percentual]	$\mu_{chegada}$ [hora]	n_a	t_s [dia]	n_f	n_l	η_{uti}
1	1,00	1,05	0,12	36	35,62	10,06	95,59	1,00	0,19
5	1,00	1,05	0,12	36	110,76	9,36	53,86	4,41	0,56
10	1,00	1,05	0,12	36	192,04	8,38	6,16	8,63	0,74
15	1,00	1,05	0,12	36	199,21	8,62	2,48	8,69	0,74
20	1,00	1,05	0,12	36	198,03	9,01	4,78	9,06	0,68
10	**0,15**	1,05	0,12	36	36,65	10,48	94,28	0,60	0,37
10	**0,25**	1,05	0,12	36	42,65	10,31	89,84	1,76	0,41
10	**0,50**	1,05	0,12	36	114,53	8,96	47,33	4,44	0,57
10	**0,75**	1,05	0,12	36	165,96	8,60	19,07	7,02	0,70
10	**1,00**	1,05	0,12	36	195,94	8,63	4,96	8,76	0,72
10	**1,25**	1,05	0,12	36	187,74	8,74	7,43	8,70	0,72
10	**1,50**	1,05	0,12	36	184,91	8,94	10,16	8,79	0,71
10	**1,75**	1,05	0,12	36	186,99	8,86	8,03	8,76	0,71
10	**2,00**	1,05	0,12	36	190,62	8,59	5,97	8,65	0,74
10	1,00	**0,15**	0,12	36	38,14	9,79	94,34	0,60	0,38
10	1,00	**0,25**	0,12	36	43,27	9,96	89,64	1,72	0,42
10	1,00	**0,50**	0,12	36	117,19	8,87	47,05	4,46	0,58
10	1,00	**0,75**	0,12	36	173,72	8,34	16,02	7,09	0,71
10	1,00	**1,05**	0,12	36	194,40	8,52	5,51	8,67	0,74
10	1,00	**1,25**	0,12	36	188,34	8,87	9,76	8,84	0,70
10	1,00	**1,50**	0,12	36	188,58	8,84	9,13	8,86	0,70
10	1,00	**1,75**	0,12	36	191,48	8,57	6,11	8,70	0,73
10	1,00	**2,00**	0,12	36	192,71	8,53	6,13	8,70	0,73
10	1,00	1,05	**0,12**	36	190,64	8,59	6,87	8,71	0,73
10	1,00	1,05	**0,15**	36	176,19	9,45	12,43	8,85	0,68
10	1,00	1,05	**0,18**	36	164,15	10,31	18,25	9,02	0,64
10	1,00	1,05	**0,21**	36	159,27	10,68	22,05	9,10	0,62
10	1,00	1,05	**0,24**	36	146,69	11,68	28,53	9,04	0,60
10	1,00	1,05	0,12	**4**	178,50	9,89	353,18	9,31	0,53
10	1,00	1,05	0,12	**9**	176,62	9,92	726,49	9,31	0,43
10	1,00	1,05	0,12	**18**	189,66	9,19	116,12	9,27	0,61
10	1,00	1,05	0,12	**27**	201,66	8,56	34,87	9,17	0,66
10	1,00	1,05	0,12	**36**	195,94	8,33	4,96	8,61	0,75
10	1,00	1,05	0,12	**45**	162,44	8,32	0,81	6,82	0,70
10	1,00	1,05	0,12	**54**	139,39	8,36	0,55	5,68	0,65
10	1,00	1,05	0,12	**63**	117,48	8,68	0,50	4,90	0,60
10	1,00	1,05	0,12	**72**	103,23	9,07	0,50	4,45	0,57

Tabela B.4 - Medidas *one-at-a-time* para caso-base $\alpha_u^{48h} = (10;\ 1;\ 1,05;\ 0,12;\ 48)$.

n_{leitos}	$n_{insumos}$ [percentual]	n_{equipe} [percentual]	tx_{ea} [percentual]	$\mu_{chegada}$ [hora]	n_a	t_s [dia]	n_f	n_l	η_{uti}
1	1,00	1,05	0,12	48	36,63	9,96	66,15	1,00	0,40
5	1,00	1,05	0,12	48	114,35	9,02	22,25	4,38	0,57
10	1,00	1,05	0,12	48	154,10	8,10	0,68	6,23	0,68
15	1,00	1,05	0,12	48	155,16	8,50	0,51	6,48	0,68
20	1,00	1,05	0,12	48	155,20	8,83	0,58	6,81	0,68
10	**0,15**	1,05	0,12	48	39,97	9,67	64,14	0,62	0,39
10	**0,25**	1,05	0,12	48	38,57	10,84	62,30	1,68	0,41
10	**0,50**	1,05	0,12	48	112,53	8,85	19,86	4,37	0,58
10	**0,75**	1,05	0,12	48	147,56	8,68	3,07	6,22	0,66
10	**1,00**	1,05	0,12	48	155,12	8,32	0,85	6,44	0,68
10	**1,25**	1,05	0,12	48	152,88	8,62	0,71	6,60	0,68
10	**1,50**	1,05	0,12	48	152,88	8,66	0,72	6,63	0,68
10	**1,75**	1,05	0,12	48	153,52	8,56	0,73	6,57	0,68
10	**2,00**	1,05	0,12	48	153,00	8,78	0,74	6,79	0,68
10	1,00	**0,15**	0,12	48	35,19	10,58	65,33	0,61	0,38
10	1,00	**0,25**	0,12	48	44,08	10,11	59,67	1,76	0,42
10	1,00	**0,50**	0,12	48	118,35	8,46	17,82	4,40	0,59
10	1,00	**0,75**	0,12	48	150,22	8,41	1,88	6,17	0,67
10	1,00	**1,05**	0,12	48	155,55	8,58	0,63	6,57	0,68
10	1,00	**1,25**	0,12	48	154,64	8,39	0,64	6,45	0,68
10	1,00	**1,50**	0,12	48	155,27	8,04	0,60	6,17	0,68
10	1,00	**1,75**	0,12	48	153,74	8,65	0,88	6,64	0,68
10	1,00	**2,00**	0,12	48	154,57	8,57	0,59	6,57	0,68
10	1,00	1,05	**0,12**	48	152,64	8,93	0,94	6,93	0,68
10	1,00	1,05	**0,15**	48	154,03	9,19	0,78	7,21	0,69
10	1,00	1,05	**0,18**	48	149,88	9,99	1,39	7,74	0,69
10	1,00	1,05	**0,21**	48	140,54	11,15	3,61	8,33	0,68
10	1,00	1,05	**0,24**	48	136,46	11,79	5,40	8,50	0,68
10	1,00	1,05	0,12	**4**	179,97	9,82	717,10	9,31	0,44
10	1,00	1,05	0,12	**12**	180,78	9,73	239,70	9,31	0,56
10	1,00	1,05	0,12	**24**	201,76	8,61	55,51	9,22	0,65
10	1,00	1,05	0,12	**36**	189,23	8,67	7,91	8,63	0,74
10	1,00	1,05	0,12	**48**	155,12	8,91	0,85	6,97	0,69
10	1,00	1,05	0,12	**60**	123,08	9,17	0,52	5,52	0,62
10	1,00	1,05	0,12	**72**	104,25	8,69	0,50	4,30	0,58
10	1,00	1,05	0,12	**84**	89,60	8,42	0,50	3,54	0,55
10	1,00	1,05	0,12	**96**	78,47	8,47	0,50	3,00	0,52

Tabela B.5 - Medidas *one-at-a-time* para caso-base $\alpha_u^{60h} = (10;\ 1;\ 1,05;\ 0,12;\ 60)$.

n_{leitos}	$n_{insumos}$ [percentual]	n_{equipe} [percentual]	tx_{ea} [percentual]	$\mu_{chegada}$ [hora]	n_a	t_s [dia]	n_f	n_l	η_{uti}
1	1,00	1,05	0,12	60	37,70	9,48	46,81	1,00	0,41
5	1,00	1,05	0,12	60	110,06	9,11	6,59	4,29	0,57
10	1,00	1,05	0,12	60	124,64	8,52	0,50	5,08	0,62
15	1,00	1,05	0,12	60	124,78	8,58	0,50	5,16	0,62
20	1,00	1,05	0,12	60	125,34	8,55	0,50	5,16	0,62
10	**0,15**	1,05	0,12	60	40,79	9,27	45,33	0,61	0,40
10	**0,25**	1,05	0,12	60	49,65	8,90	37,57	1,74	0,45
10	**0,50**	1,05	0,12	60	115,07	8,31	5,53	4,23	0,59
10	**0,75**	1,05	0,12	60	122,75	8,80	0,71	5,20	0,61
10	**1,00**	1,05	0,12	60	125,03	8,64	0,52	5,18	0,62
10	**1,25**	1,05	0,12	60	124,30	8,95	0,51	5,44	0,62
10	**1,50**	1,05	0,12	60	122,94	8,49	0,50	5,03	0,61
10	**1,75**	1,05	0,12	60	125,31	8,39	0,50	5,06	0,62
10	**2,00**	1,05	0,12	60	124,38	8,42	0,50	5,03	0,61
10	1,00	**0,15**	0,12	60	38,40	9,94	46,30	0,63	0,39
10	1,00	**0,25**	0,12	60	41,31	10,47	42,90	1,72	0,42
10	1,00	**0,50**	0,12	60	106,41	9,01	7,77	4,25	0,57
10	1,00	**0,75**	0,12	60	123,23	8,66	0,62	5,12	0,61
10	1,00	**1,05**	0,12	60	122,91	8,54	0,51	5,16	0,62
10	1,00	**1,25**	0,12	60	123,05	8,62	0,50	5,13	0,61
10	1,00	**1,50**	0,12	60	123,69	8,65	0,51	5,18	0,62
10	1,00	**1,75**	0,12	60	124,00	8,51	0,50	5,13	0,62
10	1,00	**2,00**	0,12	60	124,00	8,52	0,50	5,09	0,61
10	1,00	1,05	**0,12**	60	124,37	8,64	0,50	5,18	0,62
10	1,00	1,05	**0,15**	60	124,09	9,09	0,50	5,48	0,62
10	1,00	1,05	**0,18**	60	123,30	9,85	0,52	6,01	0,62
10	1,00	1,05	**0,21**	60	120,89	10,44	0,58	6,37	0,62
10	1,00	1,05	**0,24**	60	122,33	11,55	0,83	7,21	0,63
10	1,00	1,05	0,12	**4**	179,55	9,74	717,01	9,33	0,43
10	1,00	1,05	0,12	**15**	176,28	9,95	176,02	9,29	0,57
10	1,00	1,05	0,12	**30**	194,34	8,86	25,37	9,15	0,66
10	1,00	1,05	0,12	**45**	165,01	8,50	0,69	7,06	0,70
10	1,00	1,05	0,12	**60**	125,03	8,49	0,52	5,11	0,62
10	1,00	1,05	0,12	**75**	98,19	9,04	0,50	4,22	0,56
10	1,00	1,05	0,12	**90**	83,66	9,01	0,50	3,48	0,53
10	1,00	1,05	0,12	**105**	71,37	8,74	0,50	2,87	0,51
10	1,00	1,05	0,12	**120**	62,02	8,68	0,50	2,44	0,49

Tabela B.6 - Medidas *one-at-a-time* para caso-base $\alpha_u^{72h} = (10;\ 1;\ 1,05;\ 0,12;\ 72)$.

n_{leitos}	$n_{insumos}$ [percentual]	n_{equipe} [percentual]	tx_{ea} [percentual]	$\mu_{chegada}$ [hora]	n_a	t_s [dia]	n_f	n_l	η_{uti}
1	1,00	1,05	0,12	72	36,11	9,90	36,64	1,00	0,40
5	1,00	1,05	0,12	72	98,68	9,09	2,54	3,94	0,56
10	1,00	1,05	0,12	72	104,24	8,44	0,50	4,12	0,57
15	1,00	1,05	0,12	72	103,96	9,06	0,50	4,46	0,57
20	1,00	1,05	0,12	72	101,80	8,54	0,50	4,09	0,57
10	**0,15**	1,05	0,12	72	39,22	9,46	34,23	0,60	0,40
10	**0,25**	1,05	0,12	72	43,93	9,66	29,28	1,70	0,44
10	**0,50**	1,05	0,12	72	97,42	9,21	2,91	3,95	0,55
10	**0,75**	1,05	0,12	72	103,29	8,66	0,50	4,21	0,57
10	**1,00**	1,05	0,12	72	102,69	8,66	0,50	4,25	0,57
10	**1,25**	1,05	0,12	72	104,22	8,54	0,50	4,20	0,57
10	**1,50**	1,05	0,12	72	103,64	8,33	0,50	4,06	0,57
10	**1,75**	1,05	0,12	72	104,90	8,27	0,50	4,10	0,58
10	**2,00**	1,05	0,12	72	104,49	8,33	0,50	4,09	0,57
10	1,00	**0,15**	0,12	72	38,49	9,91	34,57	0,65	0,40
10	1,00	**0,25**	0,12	72	44,31	9,71	28,48	1,73	0,44
10	1,00	**0,50**	0,12	72	98,80	9,02	2,39	3,98	0,56
10	1,00	**0,75**	0,12	72	102,66	8,95	0,51	4,38	0,57
10	1,00	**1,05**	0,12	72	103,49	8,81	0,50	4,37	0,58
10	1,00	**1,25**	0,12	72	103,67	8,85	0,50	4,33	0,57
10	1,00	**1,50**	0,12	72	102,43	8,58	0,50	4,15	0,57
10	1,00	**1,75**	0,12	72	103,51	8,73	0,50	4,27	0,57
10	1,00	**2,00**	0,12	72	103,55	8,67	0,50	4,24	0,57
10	1,00	1,05	**0,12**	72	103,56	8,75	0,50	4,30	0,57
10	1,00	1,05	**0,15**	72	103,25	8,85	0,50	4,35	0,57
10	1,00	1,05	**0,18**	72	103,23	9,71	0,50	4,87	0,58
10	1,00	1,05	**0,21**	72	103,16	10,34	0,51	5,20	0,58
10	1,00	1,05	**0,24**	72	101,34	11,86	0,52	6,02	0,58
10	1,00	1,05	0,12	**4**	183,73	9,56	716,05	9,32	0,44
10	1,00	1,05	0,12	**18**	180,93	9,66	122,02	9,27	0,59
10	1,00	1,05	0,12	**36**	185,89	8,86	8,95	8,69	0,72
10	1,00	1,05	0,12	**54**	137,13	9,37	0,69	6,40	0,65
10	1,00	1,05	0,12	**72**	102,69	8,62	0,50	4,18	0,57
10	1,00	1,05	0,12	**90**	82,40	9,30	0,50	3,59	0,53
10	1,00	1,05	0,12	**108**	69,32	8,69	0,50	2,72	0,50
10	1,00	1,05	0,12	**126**	58,84	8,73	0,50	2,27	0,48
10	1,00	1,05	0,12	**144**	52,48	8,41	0,50	1,90	0,47

APÊNDICE C

Dados da demanda de vagas de unidade de terapia intensiva

Com intuito de verificar a demanda de vagas de unidade de terapia intensiva, realizou-se levantamento de dados das solicitações de vagas pelo Sistema Único de Saúde (SUS) em UTI localizadas em Goiânia, capital do Estado de Goiás. Durante os meses de abril, maio, junho e julho de 2019, dados reais foram coletados diariamente do sítio da Secretaria Municipal de Saúde de Goiânia-GO[1] referente à quantidade de pacientes que aguardam por leito de UTI de acordo com a especialidade demandada e o Município e Estado de origem do paciente.

Em média, a quantidade de pacientes demandando vaga em UTI neonatal, pediátrica e adulto foi $7,41$; $10,08$ e $70,72$. A média total referente às três especialidades foi de $88,21$ pacientes em fila. A série histórica da demanda pode ser vista na Figura C.1. A análise dos dados reafirma a importância da definição de prioridade no momento da triagem dos pacientes encaminhados aos cuidados intensivos, pois o número de leitos existentes não atende à atual demanda. Em alguns casos, o paciente evolui à óbito enquanto aguarda um leito na UTI.

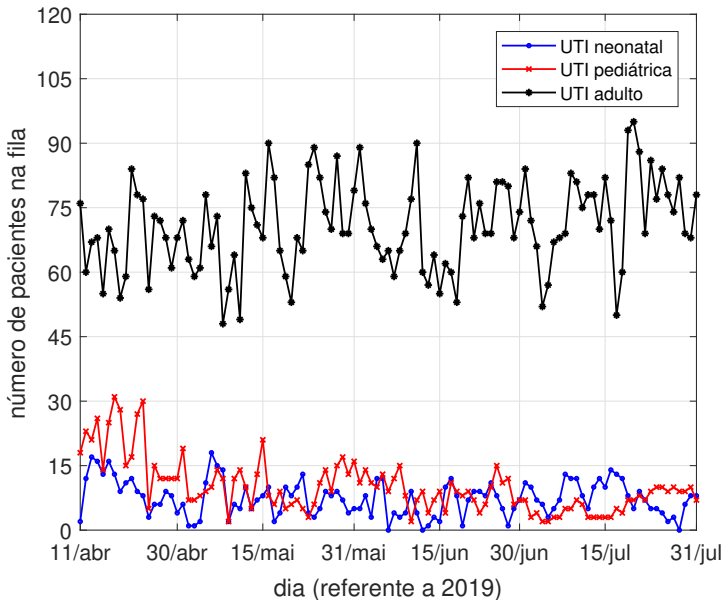

Figura C.1 - Demanda de vagas em UTI localizadas na cidade de Goiânia de abril a julho de 2019.

[1]Dados coletados entre 7:30 e 8:00 relativos à quantidade de pacientes aguardando vagas de UTI divulgada no sítio da Secretaria Municipal de Saúde de Goiânia-GO: http://www.saude.goiania.go.gov.br.

O maior número de pacientes aguardando vagas refere-se às cidades de Goiânia e Aparecida de Goiânia, as duas maiores cidades de Goiás, e ao Complexo Regulador Estadual[2](CRE). A demanda por leito em UTI neonatal, pediátrica e adulto destas cidades/CRE pode ser verificada por meio da Figura C.2.

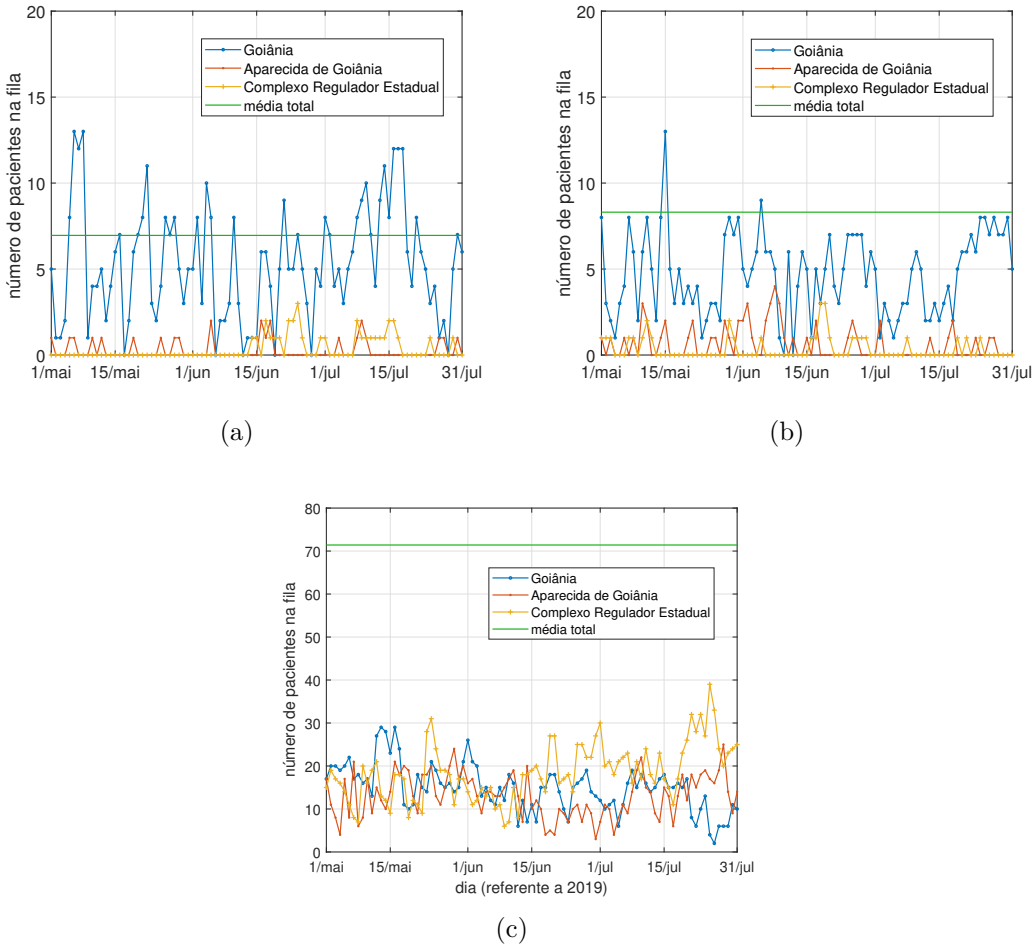

Figura C.2 - Origem da demanda de vagas em UTI localizadas em Goiânia de maio a julho de 2019: (a) UTI Neonatal, (b) UTI Pediátrica e (c) UTI Adulto.

Quanto às solicitações de vagas de UTI neonatal e pediátrica, observa-se que a cidade de Goiânia possui demanda próxima da média total, resultante da demanda apresentada por diversos municípios durante o período analisado. No que tange

[2]Complexo Regulador Estadual é o órgão da Secretaria de Estado da Saúde de Goiás que tem a função de regular e/ou intermediar os serviços do Sistema Único de Saúde, como as vagas em leitos de internação, consultas e exames. O sítio do Complexo Regulador Estadual está disponível em: http://crego.org.br.

aos pacientes aguardando leito em UTI adulto, as cidades de Goiânia e Aparecida de Goiânia e o CRE apresentaram quantitativo predominantemente entre 10 e 30, enquanto a média total foi de $70,72$.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDALLAH, S. A.; PLUMBLEY, M. D. A measure of statistical complexity based on predictive information with application to finite spin systems. **Physics Letters A**, Elsevier, v. 376, n. 4, p. 275–281, 2012. 34

ARBONA, A.; BONA, C.; MIÑANO, B.; PLASTINO, A. Statistical complexity measures as telltale of relevant scales in emergent dynamics of spatial systems. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 410, p. 1–8, 2014. 34

AY, N.; MULLER, M.; SZKOLA, A. Effective complexity and its relation to logical depth. **IEEE transactions on information theory**, IEEE, v. 56, n. 9, p. 4593–4607, 2010. 34

BAK, P. **How nature works: The science of self-organized criticality**. 1. ed. New York: Copernicus Books, 1996. 33, 44, 53, 55, 58, 59, 60

BALABAN, V.; LIM, S.; GUPTA, G.; BOEDICKER, J.; BOGDAN, P. Quantifying emergence and self-organisation of enterobacter cloacae microbial communities. **Scientific reports**, Nature Publishing Group, v. 8, n. 1, p. 12416, 2018. 34

BAR-YAM, Y. **Complexity rising: From human beings to human civilization, a complexity profile**. Massachusetts: [s.n.], 12 1997. NECSI Report. 33, 44, 55, 67

_____. **Dynamics of complex systems**. [S.l.]: Addison-Wesley Reading, MA, 1997. 37, 57, 60, 63

_____. General features of complex systems. **Encyclopedia of Life Support Systems (EOLSS), UNESCO, EOLSS Publishers, Oxford, UK**, 2002. 43, 59, 60

BARANGER, M. Chaos, complexity, and entropy. **New England Complex Systems Institute, Cambridge**, 2000. 35

BARROS NETO, B.; SCARMINIO, I. S.; BRUNS, R. E. **Como fazer experimentos: pesquisa e desenvolvimento na ciência e na indústria**. [S.l.]: Editora Unicamp, 2001. 70, 76, 77, 78

BASTIDAS, L. A.; HOGUE, T. S.; SOROOSHIAN, S.; GUPTA, H.; SHUTTLEWORTH, W. Parameter sensitivity analysis for different complexity land surface models using multicriteria methods. **Journal of Geophysical Research: Atmospheres**, Wiley Online Library, v. 111, n. D20, 2006. 36, 82

BATTY, M.; MORPHET, R.; MASUCCI, P.; STANILOV, K. Entropy, complexity, and spatial information. **Journal of geographical systems**, Springer, v. 16, n. 4, p. 363–385, 2014. 34

BENNETT, C. H. Logical depth and physical complexity. **The Universal Turing Machine A Half-Century Survey**, Springer, p. 207–235, 1995. 63

BERTALANFFY, L. V. General system theory: foundations, development, applications (revised edition). George Braziller Inc., 1969. 33, 39, 42, 53, 54, 56

BERTSIMAS, D.; SIM, M. The price of robustness. **Operations Research**, v. 52, n. 1, p. 35–53, 2004. 81

BIEK, R.; FUNK, W. C.; MAXELL, B. A.; MILLS, L. S. What is missing in amphibian decline research: insights from ecological sensitivity analysis. **Conservation Biology**, Wiley Online Library, v. 16, n. 3, p. 728–734, 2002. 81

BILLINGS, S. A. **Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains**. [S.l.]: John Wiley & Sons, 2013. 56

BUNGE, M. **Emergence and convergence: Qualitative novelty and the unity of knowledge**. [S.l.]: University of Toronto Press, 2003. 43

CALDEIRA, V. M. H.; JUNIOR, J. M. S.; OLIVEIRA, A. M. R. R. de; REZENDE, S.; ARAÚJO, L. A. G. de; SANTANA, M. R. d. O.; AMENDOLA, C. P.; REZENDE, E. Critérios para admissão de pacientes na unidade de terapia intensiva e mortalidade. **Rev Assoc Med Bras**, SciELO Brasil, v. 56, n. 5, p. 528–34, 2010. 116

CAMAZINE, S. **Self-organization in biological systems**. [S.l.]: Princeton University Press, 2003. 58

CASSANDRAS, C. G.; LAFORTUNE, S. **Introduction to discrete event systems**. [S.l.]: Springer Science & Business Media, 2009. 64

CHALMERS, D. J. Strong and weak emergence. **The reemergence of emergence**, p. 244–256, 2006. 57

CHAN, Y.-H.; CORREA, C. D.; MA, K.-L. The generalized sensitivity scatterplot. **IEEE transactions on visualization and computer graphics**, IEEE, v. 19, n. 10, p. 1768–1781, 2013. 75

CHO, K.-H.; SHIN, S.-Y.; KOLCH, W.; WOLKENHAUER, O. Experimental design in systems biology, based on parameter sensitivity analysis using a monte carlo method: A case study for the tnfα-mediated nf-κ b signal transduction pathway. **Simulation**, Sage Publications, v. 79, n. 12, p. 726–739, 2003. 80

CHWIF, L.; MEDINA, A. C. **Modelagem e simulação de eventos discretos**. 4. ed. [S.l.]: Elsevier, 2015. 46, 47, 49

CORBIT, J. D.; GARBARY, D. J. Fractal dimension as a quantitative measure of complexity in plant development. **Proceedings of the Royal Society of London. Series B: Biological Sciences**, The Royal Society London, v. 262, n. 1363, p. 1–6, 1995. 34

CRUTCHFIELD, J. P.; YOUNG, K. Inferring statistical complexity. **Physical Review Letters**, APS, v. 63, n. 2, p. 105, 1989. 63

DEACON, T.; KOUTROUFINIS, S. Complexity and dynamical depth. **Information**, Multidisciplinary Digital Publishing Institute, v. 5, n. 3, p. 404–423, 2014. 34, 61, 63

DONAUBAUER, P. J.; HINRICHSEN, O. A monte-carlo-based sensitivity analysis of multicomponent diffusion in porous catalysts. **Chemical Engineering Science**, Elsevier, 2018. 81

ESCHENBACH, T. G.; MCKEAGUE, L. S. Exposition on using graphs for sensitivity analysis. **The Engineering Economist**, v. 34, n. 4, p. 313–333, 1989. 73

FADLALLAH, B.; CHEN, B.; KEIL, A.; PRÍNCIPE, J. Weighted-permutation entropy: A complexity measure for time series incorporating amplitude information. **Physical Review E**, APS, v. 87, n. 2, p. 022911, 2013. 82

FAN, W.; JIANG, X. Conceptual development and economic evaluation of multilevel premium highways. **Research in Transportation Economics**, Elsevier, 2018. 81

FELDMAN, D. P.; CRUTCHFIELD, J. P. Measures of statistical complexity: Why? **Physics Letters A**, Elsevier, v. 238, n. 4-5, p. 244–252, 1998. 34

FITZGERALD, A. E.; JR, C. K.; UMANS, S. **Máquinas Elétricas: Com introdução à eletrônica de potência**. [S.l.]: Porto Alegre: Bookman, 2006. 91

FORSTER, A. J.; KYEREMANTENG, K.; HOOPER, J.; SHOJANIA, K. G.; WALRAVEN, C. van. The impact of adverse events in the intensive care unit on hospital mortality and length of stay. **BMC health services research**, BioMed Central, v. 8, n. 1, p. 259, 2008. 116

FREY, H. C.; PATIL, S. R. Identification and review of sensitivity analysis methods. **Risk Analysis**, v. 22, n. 3, p. 553–578, 2002. 69, 72, 74, 75, 78, 80

FU, G.; KAPELAN, Z.; REED, P. Reducing the complexity of multiobjective water distribution system optimization through global sensitivity analysis. **Journal of Water Resources Planning and Management**, American Society of Civil Engineers, v. 138, n. 3, p. 196–207, 2011. 82

GANOPOLSKI, A.; PETOUKHOV, V.; RAHMSTORF, S.; BROVKIN, V.; CLAUSSEN, M.; ELISEEV, A.; KUBATZKI, C. Climber-2: a climate system model of intermediate complexity. part ii: model sensitivity. **Climate Dynamics**, Springer, v. 17, n. 10, p. 735–751, 2001. 36, 82

GELL-MANN, M. Simplicity and complexity in the description of nature. **Engineering and Science**, California Institute of Technology, v. 51, n. 3, p. 2–9, 1988. 35, 36, 46, 54

GELL-MANN, M.; LLOYD, S. Information measures, effective complexity, and total information. **Complexity**, Wiley Online Library, v. 2, n. 1, p. 44–52, 1996. 34

GERSHENSON, C.; FERNÁNDEZ, N. Complexity and information: Measuring emergence, self-organization, and homeostasis at multiple scales. **Complexity**, Wiley Online Library, v. 18, n. 2, p. 29–44, 2012. 58

GLASSERMAN, P.; TAYUR, S. Sensitivity analysis for base-stock levels in multiechelon production-inventory systems. **Management Science**, INFORMS, v. 41, n. 2, p. 263–281, 1995. 81

GOMES, V. M.; ASSIS, A. O.; MATIAS, C. A.; SARAIVA, J. P.; GOMES, F. A.; WAINER, G. A.; LIMA, B. S.; MAGALHÃES, A. S.; CALIXTO, W. P.; FLORES, P. H. et al. Analytical method for calculating the sensitivity index of system parameters. In: IEEE. **Electrical, Electronics Engineering,**

Information and Communication Technologies (CHILECON), 2017 CHILEAN Conference on. [S.l.], 2017. p. 1–6. 73, 81, 85

GOMES, V. M.; PAIVA, J. R.; REIS, M. R.; WAINER, G. A.; CALIXTO, W. P. Mechanism for measuring system complexity applying sensitivity analysis. **Complexity**, Hindawi, v. 2019, 2019. 34, 35, 138

GOMES, V. M.; PAIVA, J. R. B.; FURRIEL, G. P.; ANICETO, B. C. M.; SILVA, L. F. A.; DOMINGUES, E. G.; JUNIOR, G. C.; RODRIGUES, B. A.; CALIXTO, W. P. Complexity metric applied to discrete events systems. In: INPE. **6th International Conference On Nonlinear Science And Complexity**. [S.l.], 2015. 36

GRAHAM, C.; TALAY, D. **Stochastic simulation and Monte Carlo methods: mathematical foundations of stochastic simulation**. [S.l.]: Springer Science & Business Media, 2013. 50

HAMBY, D. M. A review of techniques for parameter sensitivity analysis of environmental models. **Environmental Monitoring and Assessment**, v. 32, n. 2, p. 135–154, 1994. 36, 70, 72, 75, 139

_____. A comparison of sensitivity analysis techniques. **Health Physics**, v. 68, n. 2, p. 195–204, 1995. 70

HELTON, J. C. Uncertainty and sensitivity analysis techniques for use in performance assessment for radioactive waste disposal. **Reliability Engineering & System Safety**, Elsevier, v. 42, n. 2-3, p. 327–367, 1993. 81

HIERONYMI, A. Understanding systems science: a visual and integrative approach. **Systems research and behavioral science**, Wiley Online Library, v. 30, n. 5, p. 580–595, 2013. 40, 41

HLADÃK, M. Robust optimal solutions in interval linear programming with forall-exists quantifiers. **European Journal of Operational Research**, v. 254, n. 3, p. 705–714, 2016. 81

HOLLAND, J. H. Studying complex adaptive systems. **Journal of Systems Science and Complexity**, Springer, v. 19, n. 1, p. 1–8, 2006. 46

_____. **Complexity: A very short introduction**. [S.l.]: OUP Oxford, 2014. 34, 35, 44, 46, 49, 53, 56, 57, 59, 60

HOMMA, T.; SALTELLI, A. Importance measures in global sensitivity analysis of nonlinear models. **Reliability Engineering & System Safety**, v. 52, n. 1, p. 1–17, 1996. 69

HOUAISS, A. Houaiss: Dicionário eletrônico da língua portuguesa. **Rio de Janeiro: Objetiva**, 2009. 36

IMAN, R. L.; CONOVER, W. J. Small sample sensitivity analysis techniques for computer-models, with an application to risk assessment. **Communications in Statistics Part A - Theory and Methods**, v. 9, n. 17, p. 1749–1842, 1980. 69

IMAN, R. L.; HELTON, J. C. An investigation of uncertanty and sensitivity analysis techniques for computer-models. **Risk Analysis**, v. 8, n. 1, p. 71–90, 1988. 69

JACOBSON, H. Information, reproduction and the origin of life. **American Scientist**, JSTOR, v. 43, n. 1, p. 119–127, 1955. 35

KANNAMPALLIL, T. G.; SCHAUER, G. F.; COHEN, T.; PATEL, V. L. Considering complexity in healthcare systems. **Journal of biomedical informatics**, Elsevier, v. 44, n. 6, p. 943–947, 2011. 95

KLIR, G. J. **Facets of systems science**. [S.l.]: Springer Science & Business Media, 2013. 40

KOLMOGOROV, A. N. Three approaches to the quantitative definition ofinformation'. **Problems of information transmission**, v. 1, n. 1, p. 1–7, 1965. 63

KOOREHDAVOUDI, H.; BOGDAN, P. A statistical physics characterization of the complex systems dynamics: Quantifying complexity from spatio-temporal interactions. **Scientific reports**, Nature Publishing Group, v. 6, p. 27602, 2016. 34, 35, 139

KURTHS, J.; WITT, A.; ATMANSPACHER, H.; FEUDEL, F.; SCHEINGRABER, H.; WACKERBAUER, R. General remarks on complexity. In: **Inside Versus Outside**. [S.l.]: Springer, 1994. p. 219–234. 61, 139

LAW, A. M.; KELTON, W. D.; KELTON, W. D. **Simulation modeling and analysis**. [S.l.]: McGraw-Hill New York, 2007. 76

LAWRIE, J.; HEARNE, J. Reducing model complexity via output sensitivity. **ecological modelling**, Elsevier, v. 207, n. 2-4, p. 137–144, 2007. 82

LEVINE, R.; RENELT, D. A sensitivity analysis of cross-country growth regressions. **The American economic review**, JSTOR, p. 942–963, 1992. 81

LI, J.; DU, Q.; SUN, C. An improved box-counting method for image fractal dimension estimation. **Pattern Recognition**, Elsevier, v. 42, n. 11, p. 2460–2469, 2009. 34

LINDENSCHMIDT, K.-E. The effect of complexity on parameter sensitivity and model uncertainty in river water quality modelling. **Ecological Modelling**, Elsevier, v. 190, n. 1-2, p. 72–86, 2006. 36, 82

LLOYD, S. Measures of complexity: a nonexhaustive list. **IEEE Control Systems Magazine**, v. 21, n. 4, p. 7–8, 2001. 34, 61, 141

LLOYD, S.; PAGELS, H. Complexity as thermodynamic depth. **Annals of physics**, Elsevier, v. 188, n. 1, p. 186–213, 1988. 63

LÖÖF, H.; HESHMATI, A. On the relationship between innovation and performance: A sensitivity analysis. **Economics of Innovation and New Technology**, Taylor & Francis, v. 15, n. 4-5, p. 317–344, 2006. 81

LOUCKS, D. P.; BEEK, E. V. **Water Resources Systems Planning and Management**. [S.l.]: Unesco, 2005. 69, 81

LUTZ, A. E.; KEE, R. J.; MILLER, J. A. **SENKIN: A FORTRAN program for predicting homogeneous gas phase chemical kinetics with sensitivity analysis**. [S.l.: s.n.], 1988. 81

MAIER, M. W. Architecting principles for systems-of-systems. In: WILEY ONLINE LIBRARY. **INCOSE International Symposium**. [S.l.], 1996. v. 6, n. 1, p. 565–573. 33, 39

MAINZER, K.; CHUA, L. **The universe as automaton: From simplicity and symmetry to complexity**. [S.l.]: Springer Science & Business Media, 2011. 34, 53

MARINO, S.; HOGUE, I. B.; RAY, C. J.; KIRSCHNER, D. E. A methodology for performing global uncertainty and sensitivity analysis in systems biology. **Journal of Theoretical Biology**, v. 254, n. 1, p. 178–196, 2008. 69, 80

MARSHALL, J. C.; BOSCO, L.; ADHIKARI, N. K.; CONNOLLY, B.; DIAZ, J. V.; DORMAN, T.; FOWLER, R. A.; MEYFROIDT, G.; NAKAGAWA, S.; PELOSI, P.; VINCENT, J.-L.; VOLLMAN, K.; ZIMMERMAN, J. What is an

intensive care unit? a report of the task force of the world federation of societies of intensive and critical care medicine. **Journal of critical care**, Elsevier, v. 37, p. 270–276, 2017. 95

MCMANUS, M. L.; LONG, M. C.; COOPER, A.; LITVAK, E. et al. Queuing theory accurately models the need for critical care resources. **Anesthesiology**, American Society of Anesthesiologists, v. 100, n. 5, p. 1271–1276, 2004. 96, 117

MEED, W. Complexity science and the social world. In: KEMPF-LEONARD, K. (Ed.). **Encyclopedia of Social Measurement**. Salford, Greater Manchester, United Kingdom: Elsevier, 2005. p. 399–403. 33

MITCHELL, M. **Complexity: A guided tour**. [S.l.]: Oxford University Press, 2009. 34, 44, 53, 61, 63

MOBUS, G. E.; KALTON, M. C. **Principles of systems science**. [S.l.]: Springer, 2015. 36, 39, 40, 41, 42, 43, 49, 60, 61

MOKHTARI, A.; FREY, H. C.; ZHENG, J. Evaluation and recommendation of sensitivity analysis methods for application to stochastic human exposure and dose simulation models. **Journal of Exposure Science and Environmental Epidemiology**, Nature Publishing Group, v. 16, n. 6, p. 491, 2006. 81

MORIN, E. **Introdução ao pensamento complexo**. [S.l.]: Sulina Porto Alegre, 2005. 35

MOSLEH, M.; LUDLOW, P.; HEYDARI, B. Distributed resource management in systems of systems: An architecture perspective. **Systems Engineering**, Wiley Online Library, v. 19, n. 4, p. 362–374, 2016. 33

NEUBERT, M. G.; CASWELL, H. Demography and dispersal: calculation and sensitivity analysis of invasion speed for structured populations. **Ecology**, Wiley Online Library, v. 81, n. 6, p. 1613–1628, 2000. 81

NEWMAN, M. **Networks: an introduction**. [S.l.]: Oxford university press, 2010. 43

NISE, N. S. **Engenharia de sistemas de controle**. 5. ed. [S.l.]: LTC, 2009. 92

NOHARA, T.; HOSOE, S.; ITO, M. Approximation of linear systems with internal connections. **International Journal of Systems Science**, Taylor & Francis, v. 20, n. 4, p. 649–662, 1989. 33

PAGE, S. E. **Diversity and complexity**. [S.l.]: Princeton University Press, 2010. 43, 53, 55, 59, 60, 95

PAIVA, J. R. B. d. Métrica de complexidade em sistemas a eventos discretos (dissertação). Universidade Federal de Goiás, 2016. 48, 63, 65, 87, 124, 126, 151

PAIVA, J. R. B. de; GOMES, V. M.; RODRIGUES, B. A.; SILVA, L. F. A.; ANICETO, B. C. M.; FURRIEL, G. P.; CALIXTO, W. P. Metric for calculation of system complexity based on its connections. **Transactions on Environment and Electrical Engineering**, v. 2, n. 1, p. 67–73, 2017. 34, 36, 63

PANDIS, S. N.; SEINFELD, J. H. Sensitivity analysis of a chemical mechanism for aqueous-phase atmospheric chemistry. **Journal of Geophysical Research: Atmospheres**, Wiley Online Library, v. 94, n. D1, p. 1105–1126, 1989. 81

PANNEL, D. J. Sensitivity analysis: strategies, methods, concepts, examples. **University of Western Australia, Crawley**, 2009. 69, 73, 81

PETROPOULOS G. IRELAND, H. M. G. M. C. K. P. I.-K. G. P.; KALIVAS, D. P. Extending the global sensitivity analysis of the simsphere model in the context of its future exploitation by the scientific community. **Water**, v. 7, n. 5, p. 2101–2141, 2015. 71

PRADO, E. F. S. Três concepções de complexidade. **Economia, Complexidade e Dialética. São Paulo: IPE/USP**, 2009. 53

RABITZ, H.; KRAMER, M.; DACOL, D. Sensitivity analysis in chemical kinetics. **Annual review of physical chemistry**, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 34, n. 1, p. 419–461, 1983. 81

RAFTER, N.; HICKEY, A.; CONDELL, S.; CONROY, R.; O'CONNOR, P.; VAUGHAN, D.; WILLIAMS, D. Adverse events in healthcare: learning from mistakes. **QJM: An International Journal of Medicine**, Oxford University Press, v. 108, n. 4, p. 273–277, 2014. 96, 116

REIS, M. R. d. C. Análise comparativa de métodos de otimização aplicados à sintonia do controlador pi (dissertação). Universidade Federal de Goiás, 2014. 91, 92

REPPERGER, D. W.; ROBERTS, R. G.; KOEPKE, C. G. **Quantitative measurements of system complexity**. [S.l.]: Google Patents, ago. 14 2012. US Patent 8,244,503. 61, 65, 66

REZEK, I.; ROBERTS, S. J. Stochastic complexity measures for physiological signal analysis. **IEEE Transactions on Biomedical Engineering**, IEEE, v. 45, n. 9, p. 1186–1191, 1998. 82

ROMAN, V. B. Estruturação do sistema de desenvolvimento de *startups* em uma aceleradora por intermédio de gestão de portfólio (dissertação). Universidade Federal de Minas Gerais, 2017. 93, 95, 112, 113, 114, 127

ROSSO, O. A.; CARPI, L. C.; SACO, P. M.; RAVETTI, M. G.; PLASTINO, A.; LARRONDO, H. A. Causality and the entropy–complexity plane: Robustness and missing ordinal patterns. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 391, n. 1, p. 42–55, 2012. 34

ROTHSCHILD, J. M.; LANDRIGAN, C. P.; CRONIN, J. W.; KAUSHAL, R.; LOCKLEY, S. W.; BURDICK, E.; STONE, P. H.; LILLY, C. M.; KATZ, J. T.; CZEISLER, C. A. et al. The critical care safety study: The incidence and nature of adverse events and serious medical errors in intensive care. **Critical care medicine**, LWW, v. 33, n. 8, p. 1694–1700, 2005. 96, 116

SALTELLI, A.; ANNONI, P. How to avoid a perfunctory sensitivity analysis. **Environmental Modelling & Software**, v. 25, n. 12, p. 1508–1517, 2010. 69

SALTELLI, A.; RATTO, M.; ANDRES, T.; CAMPOLONGO, F.; CARIBONI, J.; GATELLI, D.; SAISANA, M.; TARANTOLA, S. **Global sensitivity analysis: the primer**. [S.l.]: John Wiley & Sons, 2008. 70, 71, 74, 75, 76, 79, 80

SALTELLI, A.; RATTO, M.; TARANTOLA, S.; CAMPOLONGO, F. Sensitivity analysis for chemical models. **Chemical reviews**, ACS Publications, v. 105, n. 7, p. 2811–2828, 2005. 81

SALTELLI, A.; TARANTOLA, S.; CAMPOLONGO, F.; RATTO, M. **Sensitivity analysis in practice: a guide to assessing scientific models**. [S.l.]: John Wiley & Sons, 2004. 69

SALTELLI, A.; TARANTOLA, S.; CHAN, K. P. S. A quantitative model-independent method for global sensitivity analysis of model output. **Technometrics**, v. 41, n. 1, p. 39–56, 1999. 70, 76

SANTOS, F. C.; PINHEIRO, F. L.; LENAERTS, T.; PACHECO, J. M. The role of diversity in the evolution of cooperation. **Journal of theoretical biology**, Elsevier, v. 299, p. 88–96, 2012. 59

SARAIVA, J. P.; LIMA, B. S.; GOMES, V. M.; FLORES, P. H. R.; GOMES, F. A.; ASSIS, A. O.; REIS, M. R. C.; ARAUJO, W. R. H.; ABRENHOSA, C.; CALIXTO, W. P. Calculation of sensitivity index using one-at-a-time measures based on graphical analysis. **18th International Scientific Conference on Eletric Power Engineering (EPE**, 2017. 73, 81

SARRAZIN, F.; PIANOSI, F.; WAGENER, T. Global sensitivity analysis of environmental models: convergence and validation. **Environmental Modelling & Software**, Elsevier, v. 79, p. 135–152, 2016. 79

SAVI, M. A. **Dinâmica não-linear e caos**. [S.l.]: Editora E-papers, 2006. 57

SAYED-MOUCHAWEH, M. **Discrete Event Systems: Diagnosis and Diagnosability**. [S.l.]: Springer Science & Business Media, 2014. 49

SHANNON, C. E. A mathematical theory of communication. **The Bell System Technical Journal**, Nokia Bell Labs, v. 27, n. 3, p. 379–423, 1948. 61, 63, 139

SIMAR, L.; WILSON, P. W. Sensitivity analysis of efficiency scores: How to bootstrap in nonparametric frontier models. **Management science**, INFORMS, v. 44, n. 1, p. 49–61, 1998. 81

SIMON, H. A. The architecture of complexity. **Proceedings of the American philosophical society**, JSTOR, v. 106, n. 6, p. 467–482, 1962. 33, 43, 53, 54, 63

SIMONE, A. D. Sensitivity analysis of the scattering-based sarbm3d despeckling algorithm. **Sensors**, v. 16, n. 7, p. 971, 2016. 81

SOLSVIK, J.; JAKOBSEN, H. A. A numerical study of a two property catalyst/sorbent pellet design for the sorption-enhanced steam–methane reforming process: modeling complexity and parameter sensitivity study. **Chemical engineering journal**, Elsevier, v. 178, p. 407–422, 2011. 36, 82

SPINA, C. **Como Elaborar um pitch (quase) perfeito**. Endeavor: [s.n.], 08 2012. 112

STACEY, R. D. **Strategic management and organisational dynamics: The challenge of complexity to ways of thinking about organisations**. [S.l.]: Pearson education, 2007. 48

TARANTOLA, S.; GATELLI, D.; KUCHERENKO, S.; MAUNTZ, W. et al. Estimating the approximation error when fixing unessential factors in global

sensitivity analysis. **Reliability Engineering & System Safety**, Elsevier, v. 92, n. 7, p. 957–960, 2007. 40, 46, 47

THEILER, J. Estimating fractal dimension. **JOSA A**, Optical Society of America, v. 7, n. 6, p. 1055–1073, 1990. 63

TIAN, W. A review of sensitivity analysis methods in building energy analysis. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 20, p. 411–419, 2013. 81

VERRELST N. SABATER, J. P. R. J. M.-M. J. V. G. C.-V. J.; MORENO, J. Emulation of leaf, canopy and atmosphere radiative transfer models for fast global sensitivity analysis. **Remote Sensing**, v. 8, n. 8, p. 673, 2016. 71

VLADISLAVLEVA, E. J.; SMITS, G. F.; HERTOG, D. D. Order of nonlinearity as a complexity measure for models generated by symbolic regression via pareto genetic programming. **IEEE Transactions on Evolutionary Computation**, IEEE, v. 13, n. 2, p. 333–349, 2009. 82

WAINER, G. A. **Discrete-event modeling and simulation: a practitioner's approach**. [S.l.]: CRC press, 2009. 46, 47, 48, 49, 50, 64

WALDROP, M. M. **Complexity: The emerging science at the edge of order and chaos**. [S.l.]: Simon and Schuster, 1993. 44, 45, 55, 60

WANG, K.; BJØRKET, O. A general efficient approach to dynamic analysis of interconnected mechanical systems using the theory of connections. **International Journal of Systems Science**, v. 25, n. 7, p. 1157–1178, 1994. 33

WANG, T.; LIANG, F.; ZHOU, Z.; QI, X. Global sensitivity analysis of hepatic venous pressure gradient (hvpg) measurement with a stochastic computational model of the hepatic circulation. **Computers in Biology and Medicine**, Elsevier, 2018. 81

WATKINS, N. W.; FREEMAN, M. P. Natural complexity. **Science**, American Association for the Advancement of Science, v. 320, n. 5874, p. 323–324, 2008. 57

WEAVER, W. Science and complexity. **American Scientist**, v. 36, n. 1, p. 536–544, 1948. 33, 54

WILSON, M. P. General system theory: Towards the unification of science. In: **Proceedings of the 58th Annual Meeting of the ISSS-2014 United States**. [S.l.: s.n.], 2015. v. 1, n. 1. 42, 43

WOLFRAM, S. Universality and complexity in cellular automata. **Physica D: Nonlinear Phenomena**, Elsevier, v. 10, n. 1-2, p. 1–35, 1984. 63

XUE, Y.; BOGDAN, P. Reliable multi-fractal characterization of weighted complex networks: algorithms and implications. **Scientific reports**, Nature Publishing Group, v. 7, n. 1, p. 7487, 2017. 34

YOUNG, G.; DEY, S.; ROGERS, A.; EXTON, D. Cost and time-effective method for multi-scale measures of rugosity, fractal dimension, and vector dispersion from coral reef 3d models. **PloS one**, Public Library of Science, v. 12, n. 4, p. e0175341, 2017. 34

ZADEH, L. A. On the definition of adaptivity. **Proceedings of the IEEE**, IEEE, v. 51, n. 3, p. 469–470, 1963. 46

ZHANG, H.; HENDERSON-SELLERS, A.; PITMAN, A.; DESBOROUGH, C.; MCGREGOR, J.; KATZFEY, J. Limited-area model sensitivity to the complexity of representation of the land surface energy balance. **Journal of climate**, v. 14, n. 19, p. 3965–3986, 2001. 36, 82

ZHANG, Y.; DUBE, M. A.; MCLEAN, D. D.; KATES, M. Biodiesel production from waste cooking oil: 2. economic assessment and sensitivity analysis. **Bioresource Technology**, v. 90, n. 3, p. 229–240, 2003. 81

ZUREK, W. H. Thermodynamic cost of computation, algorithmic complexity and the information metric. **Nature**, Nature Publishing Group, v. 341, n. 6238, p. 119, 1989. 61