

UNIVERSIDADE FEDERAL DE GOIÁS
INSTITUTO DE INFORMÁTICA

BRUNO SOARES DA SILVA

**Detecção da direcionalidade do
movimento humano utilizando
perturbações do sinal eletromagnético
de interfaces IEEE 802.11**

Goiânia
2018

**TERMO DE CIÊNCIA E DE AUTORIZAÇÃO 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 nº 9610/98, 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.

1. Identificação do material bibliográfico: ☒ **Dissertação** ☐ **Tese**

2. Identificação da Tese ou Dissertação:


Nome completo do autor: **Bruno Soares da Silva**

Título do trabalho: **Deteção da direcionalidade do movimento humano utilizando perturbações do sinal eletromagnético de interfaces IEEE 802.11**


3. Informações de acesso ao documento:

Concorda com a liberação total do documento ☒ **SIM** ☐ **NÃO**¹

Havendo concordância com a disponibilização eletrônica, torna-se imprescindível o envio do(s) arquivo(s) em formato digital PDF da tese ou dissertação.


Assinatura do(a) autor(a)²

Ciente e de acordo:


Assinatura do(a) orientador(a)²

Data: 07/11/2018

¹Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados 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

²A assinatura deve ser escaneada.

BRUNO SOARES DA SILVA

Detecção da direcionalidade do movimento humano utilizando perturbações do sinal eletromagnético de interfaces IEEE 802.11

Dissertação apresentada ao Programa de Pós-Graduação do Instituto de Informática da Universidade Federal de Goiás, como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Ciência da Computação.

Orientador: Prof. Kleber Vieira Cardoso

Co-Orientador: Prof. Gustavo Teodoro Laureano

Co-Orientador: Prof. Abdallah S. Abdallah Abousheisha

Goiânia
2018

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

da Silva, Bruno Soares

Detecção da direcionalidade do movimento humano utilizando
perturbações do sinal eletromagnético de interfaces IEEE 802.11
[manuscrito] / Bruno Soares da Silva. - 2018.

LXVI, 66 f.: il.

Orientador: Prof. Dr. Kleber Vieira Cardoso; co-orientador Dr.
Gustavo Teodoro Laureano; co-orientador Dr. Abdallah S. Abdallah
Abousheaisha.

Dissertação (Mestrado) - Universidade Federal de Goiás, Instituto
de Informática (INF), Programa de Pós-Graduação em Ciência da
Computação, Goiânia, 2018.

Bibliografia.

Inclui fotografias, gráfico, tabelas, lista de figuras, lista de tabelas.

1. Detecção de fluxos de movimento. 2. Direcionalidade de
movimentos humanos. 3. Sensores não invasivos. 4. Channel State
Information, 802.11. 5. Rede sem fio. I. Cardoso, Kleber Vieira, orient.
II. Título.

CDU 004



ATA Nº 09/2018

**ATA DA SESSÃO DE JULGAMENTO DA DISSERTAÇÃO
DE MESTRADO DE BRUNO SOARES DA SILVA**

Aos oito dias do mês de outubro de dois mil e dezoito, às nove horas e trinta minutos, na sala 150 do Instituto de Informática da Universidade Federal de Goiás, Campus Samambaia, reuniu-se a banca examinadora designada na forma regimental pela Coordenação do Curso para julgar a dissertação de mestrado intitulada **“Detecção da direcionalidade do movimento humano utilizando perturbações do sinal eletromagnético de interfaces IEEE 802.11”**, apresentada pelo aluno Bruno Soares da Silva como parte dos requisitos necessários à obtenção do grau de Mestre em Ciência da Computação, área de concentração Ciência da Computação. A banca examinadora foi presidida pelo orientador do trabalho de dissertação, Professor Doutor Kleber Vieira Cardoso (INF/UFG), tendo como membros os Professores Doutores Gustavo Teodoro Laureano (INF/UFG – coorientador), Abdallah S. Abdallah Abousheaisha (ECE/PSU - coorientador), Anderson da Silva Soares (INF/UFG) e Aline Carneiro Viana (LIX/INRIA). Os professores Abdallah S. Abdallah Abousheaisha e Aline Carneiro Viana participaram à distância por webconferência. Aberta a sessão, o candidato expôs seu trabalho. Em seguida, o aluno foi arguido pelos membros da banca e:

(☒) tendo demonstrado suficiência de conhecimento e capacidade de sistematização do tema de sua dissertação, a banca concluiu pela **aprovação** do candidato, sem restrições.

(☐) não tendo demonstrado suficiência de conhecimento e capacidade de sistematização do tema de sua dissertação, a banca concluiu pela **reprovação** do candidato.

Os trabalhos foram encerrados às 12:00 horas. Nos termos do Regulamento Geral dos Cursos de Pós-Graduação desta Universidade, lavrou-se a presente ata que, lida e julgada conforme, segue assinada pelos membros da banca examinadora.

Prof. Dr. Kleber Vieira Cardoso Kleber Vieira Cardoso
Prof. Dr. Gustavo Teodoro Laureano Gustavo Teodoro Laureano
Prof. PhD. Abdallah S. Abdallah Abousheaisha Abdallah Abdallah Abdallah
Prof. Dr. Anderson da Silva Soares Anderson S Soares
Profa. PhD. Aline Carneiro Viana Aline Carneiro Viana

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador(a).

Bruno Soares da Silva

Bacharel em Engenharia de Software pela UFG (2015). Membro do Laboratório de Redes e Sistemas Distribuídos (LABORA). Participou de projetos de pesquisa na UFG, em parceria com a Rede Nacional de Ensino e Pesquisa (RNP), na graduação e no mestrado. Seus interesses em pesquisa incluem Segurança, Sistemas Distribuídos, Redes de alto desempenho, Redes sem fio e Redes definidas por Software (SDN).

Dedico esta dissertação a Deus, a minha família, a minha namorada e aos meus amigos, por todo apoio, confiança, carinho e compreensão.

Agradecimentos

Agradeço a Deus, pela graça da vida, pela saúde e por todo apoio nos momentos difíceis.

Aos meus pais, Edemilson e Valéria, por todo amor, carinho, orientação e suporte durante toda a minha vida. Agradeço pela oportunidade de ser filho de vocês.

Aos meus familiares, que sempre me apoiaram, me auxiliaram e me ensinaram a ser a pessoa que sou hoje. Obrigado por todo carinho e suporte.

A minha namorada e companheira, Jordana, por todo companheirismo, incentivo, apoio e, principalmente, pelo seu amor. Obrigado por estar ao meu lado nos momentos difíceis da minha vida e dedicar sua vida a mim. Agradeço, especialmente, por me incentivar a finalizar minha dissertação, me ajudando a me manter focado com os meus objetivos.

A minha irmã Brendha, por todo amor, carinho, apoio e por me escutar, me compreender e me aconselhar quando necessito.

Ao Prof. Kleber Vieira Cardoso, por sua orientação, amizade, paciência e confiança. Obrigado por me mostrar o caminho e me auxiliar em minha formação.

Ao Prof. Gustavo Teodoro Laureano, por sua orientação, contribuição e confiança.

Ao Prof. Abdallah S. Abdallah, por sua orientação e contribuição.

Aos meus amigos Vinicius, Stefany, Leandro, Marcos, Geovany, Lucas, Rafael e todos os demais; por todos esses anos de amizade. Vocês me ajudam a ser forte, me incentivam a ser melhor e me trazem alegria.

Aos meus amigos do Grupo LABORA: Phelipe, Henrique, Vinicius N., Vinicius B., Marcelo, Geovana, Pablo e todos os demais; pela amizade, apoio e incentivo. Obrigado pelo auxílio e pelas contribuições neste trabalho de mestrado.

À equipe da secretaria acadêmica, em especial à Mariana, pela atenção, paciência e suporte operacional.

Ao INF/UFG, pelas instalações e equipamentos utilizados, que tornou viável o desenvolvimento do meu mestrado.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e a Rede Nacional de Ensino e Pesquisa (RNP) pelo suporte financeiro.

“A ignorância gera confiança com mais frequência do que o conhecimento: são aqueles que sabem pouco, e não aqueles que sabem muito, que tão positivamente afirmam que esse ou aquele problema jamais será resolvido pela ciência.”

Charles Robert Darwin (1809 - 1882),
<Frases e Pensamentos>.

Resumo

da Silva, Bruno. **Detecção da direcionalidade do movimento humano utilizando perturbações do sinal eletromagnético de interfaces IEEE 802.11**. Goiânia, 2018. 66p. Dissertação de Mestrado. Instituto de Informática, Universidade Federal de Goiás.

A detecção de fluxos de movimento em ambientes fechados demanda a aquisição e implantação de sensores especializados. As perturbações que podem afetar o sinal eletromagnético utilizado por interfaces de rede 802.11 tornam esse tipo de dispositivo um sensor de fluxos de movimento de baixo custo e amplamente disponível. Grande parte dos ambientes possuem interfaces 802.11 implantadas, tornando o uso desse tipo de dispositivo como sensor de fluxo de movimento bastante viável por não demandar a aquisição de nenhum novo equipamento. Neste trabalho, apresentamos o WiDMove, uma proposta que visa detectar fluxos de movimento em ambientes fechados utilizando as medidas de qualidade do canal oferecidas pelo padrão IEEE 802.11n, conhecidas como *Channel State Information* (CSI). Nossa proposta é baseada em técnicas de processamento de sinais e de reconhecimento de padrões, as quais nos permitem extrair e classificar assinaturas de fluxos de movimento usando as medidas CSI. Em testes de laboratório com interfaces 802.11 convencionais, coletamos medidas CSI influenciadas por 8 indivíduos distintos e extraímos as assinaturas de entrada e saída utilizando, dentre outras técnicas, *Principal Component Analysis* (PCA), *Short-Time Fourier Transform* (STFT) e *Continuous Wavelet Transform* (CWT). Treinamos dois tipos de modelos, um baseado em um classificador do tipo *Support Vector Machine* (SVM) e outro baseado em redes neurais do tipo *Multi Layer Perceptral* (MLP). Validamos esses modelos através de testes de acurácia média e de técnicas de validação cruzada, incluindo as técnicas *K-Fold* e *Leave-One-Out*. Os testes demonstraram que o WiDMove pode atingir uma acurácia média superior a 93% e que é possível treinar uma rede neural com acurácia de cerca de 97%.

Palavras-chave

Detecção de fluxos de movimento, Direcionalidade de movimentos, Sensores não invasivos, Movimento humano, Channel State Information, 802.11, Rede sem fio.

Abstract

da Silva, Bruno. **Sensing Human Movement Activities using IEEE 802.11 Interfaces**. Goiânia, 2018. 66p. MSc. Dissertation. Instituto de Informática, Universidade Federal de Goiás.

The movement flow detection in indoor environments requires the acquisition and implantation of specialized devices. The perturbations that can affect the electromagnetic signals used by 802.11 interfaces make this type of device a low-cost and widely available movement sensor. Most indoor environments have a 802.11 interface, which makes the use of this type of devices a good option as it doesn't require any new device. In this work, we propose the WiDMove, a proposal to detect the movement flows in an indoor environment using the channel quality measurements (known as Channel State Information - CSI) offered by the IEEE 802.11n standard. Our proposal is based on signal processing and pattern recognition techniques, which allow us to extract and classify event signatures using the CSI. In lab tests with off-the-shelf 802.11 interfaces, we collected CSI samples that were affected by 8 different people. From this collected data we extracted the signature of the entry and exit events using some techniques such as Principal Component Analysis (PCA), Short-Time Fourier Transform (STFT) and Continuous Wavelet Transform (CWT). We trained two model types, the first based on a Support Vector Machine (SVM) classifier and the second based on a Multi Layer Perceptral (MLP) neural network. We validated these models with average accuracy experiments and with the cross-validation, including the K-Fold and Leave-One-Out techniques. WiDMove presented that can reach an average accuracy above 93% and that we can train neural networks that can reach an accuracy above 97%.

Keywords

Movement flow detection, Movement direction, Non-Invasive sensors, Channel State Information, 802.11, Human movement, Wireless networks.

Sumário

Lista de Figuras	11
Lista de Tabelas	14
1 Introdução	15
1.1 Objetivos	16
1.2 Organização da dissertação	17
2 Fundamentos & Trabalhos Relacionados	18
2.1 A Tecnologia 802.11	18
2.1.1 Mecanismo de monitoramento do canal sem fio 802.11	19
2.1.2 Monitoramento de atividades ocorridas em ambientes utilizando o CSI	22
2.2 Representação e processamento de sinais CSI	25
2.2.1 Principal Component Analysis (PCA)	25
2.2.2 Fast Fourier Transform (FFT)	26
2.2.3 Short-Time Fourier Transform (STFT)	26
2.2.4 Continuous Wavelet Transform (CWT)	26
2.3 Reconhecimento de padrões	26
2.4 Trabalhos Relacionados	28
2.5 Conclusão	29
3 Metodologia & Proposta	31
3.1 Detecção de fluxos de movimento	31
3.2 WiDMove - sistema de detecção de fluxos de movimento em ambientes fechados	33
3.2.1 Preparação do ambiente e coleta das amostras CSI	33
Preparação do ambiente para coleta das amostras CSI	33
Coleta das amostras CSI	34
3.2.2 Criação dos espectrogramas	36
Espectrograma com Short-Time Fourier Transform (STFT)	36
Espectrograma com Continuous Wavelet Transform (CWT)	37
3.2.3 Preparação das amostras CSI	38
Detecção dos intervalos dos eventos nas amostras	38
Conversão e filtragem da magnitude das amostras CSI	39
3.2.4 Extração das características dos eventos	40
3.2.5 Criação do modelo de classificação	42
Classificador Support Vector Machine (SVM)	42
Rede Neural Multilayer Perceptron (MLP)	43
3.3 CSI Monitor	44
3.3.1 Interface Gráfica	45

3.3.2	CSI Device Manager Client	46
3.3.3	CSI Device Manager	46
3.4	Conclusão	47
4	Avaliação do Sistema	48
4.1	Descrição do experimento	48
4.2	Avaliação de desempenho dos modelos	49
4.2.1	Impacto da quantidade de amostras utilizadas na fase de treino	53
4.3	Conclusão	55
5	Conclusão & Trabalhos Futuros	60
5.1	Produção científica	61
5.2	Perspectivas para trabalhos futuros	62
	Referências Bibliográficas	64

Lista de Figuras

2.1	Visão de um canal sem fio que utiliza modulação OFDM.	19
2.2	Funcionamento do CSI em redes 802.11.	20
2.3	Exemplo do efeito de multipercurso quando uma pessoa se movimenta em um ambiente.	22
2.4	Diferenças do modelo de propagação e recepção de energia entre antenas direcionais e omni-direcionais.	23
2.5	Amostras CSI coletadas no tempo à uma taxa de amostragem de 800 pps.	24
(a)	Amostras do deslocamento da amplitude, observadas no tempo, coletadas pelo CSI à uma taxa de amostragem de 800 pps.	24
(b)	Amostras do deslocamento da fase, observadas no tempo, coletadas pelo CSI à uma taxa de amostragem de 800 pps.	24
3.1	Alterações no CSI de acordo com a movimentação do corpo humano baseado no efeito de multipercurso.	32
3.2	Metodologia de criação do WiDMove.	33
3.3	Dispositivos de rede e ambiente de experimentação.	34
(a)	Dispositivos utilizados e ambiente de experimentação.	34
(b)	Configuração do ambiente de experimentação e posicionamento dos dispositivos de rede.	34
3.4	Tempo de chegada das amostras CSI.	35
(a)	Tempo relativo de chegada das amostras CSI em um segundo.	35
(b)	Perfis de chegada das amostras CSI.	35
3.5	Espectrograma de amostra de teste incluindo eventos de entrada e saída criados com STFT.	37
3.6	Espectrograma de amostra de teste incluindo eventos de entrada e saída criados com CWT.	37
3.7	Deteção dos intervalos dos eventos nas amostras de teste.	39
(a)	Espectrograma de verificação dos eventos de entrada e saída nas amostras de teste.	39
(b)	Segunda componente PCA com separação dos eventos de entrada, saída e evento aleatório escolhido para representar a classe sem evento.	39
3.8	Comparativo das técnicas de filtragem da magnitude do CSI obtido por interfaces 802.11.	41
(a)	Stream CSI sem filtro em evento de entrada.	41
(b)	Stream CSI filtrada com butterworth (corte em 200 Hz) em evento de entrada.	41
(c)	Segunda componente PCA em evento de entrada.	41

(d)	Stream CSI sem filtro em evento de saída.	41
(e)	Stream CSI filtrada com butterworth (corte em 200 Hz) em evento de saída.	41
(f)	Segunda componente PCA em evento de saída.	41
3.9	Comparativo das características extraídas em cada tipo de evento e para cada tipo de espectrograma.	43
(a)	Vetor de características dos eventos de saída (STFT).	43
(b)	Vetor de características dos eventos de saída (CWT).	43
(c)	Vetor de características dos eventos de entrada (STFT).	43
(d)	Vetor de características dos eventos de entrada (CWT).	43
(e)	Vetor de características dos intervalos sem evento (STFT).	43
(f)	Vetor de características dos intervalos sem evento (CWT).	43
3.10	Arquitetura e Funcionamento do CSI Monitor.	45
3.11	Interface gráfica do CSI Monitor.	47
4.1	Peso das características atribuídos pelo algoritmo ReliefF.	50
(a)	Peso das características da assinatura baseada em STFT.	50
(b)	Peso das características da assinatura baseada em CWT.	50
4.2	Acurácia média dos classificadores SVM por tipo de assinatura e quantidade de características mais relevantes (IC de 95%).	51
(a)	Acurácia dos classificadores com STFT pela técnica K-Fold para K=10.	51
(b)	Acurácia dos classificadores com STFT pela técnica Leave-One-Out.	51
(c)	Acurácia dos classificadores com CWT pela técnica K-Fold para K=10.	51
(d)	Acurácia dos classificadores com CWT pela técnica Leave-One-Out.	51
4.3	Acurácia média das redes neurais que utilizam a configuração que obteve o melhor resultado dada a quantidade de características mais relevantes (IC de 95%).	55
(a)	Acurácia média das redes neurais pela configuração radbas (100) + logsig (10) dada a quantidade de características mais relevantes das assinaturas baseadas em STFT.	55
(b)	Acurácia média das redes neurais pela configuração tansig (250) + logsig (50) dada a quantidade de características mais relevantes das assinaturas baseadas em CWT.	55
4.4	Curvas ROC dos melhores modelos obtidos.	57
(a)	Curva ROC do classificador SVM com 25% das características mais relevantes baseadas em STFT.	57
(b)	Curva ROC do classificador SVM com todas características baseadas em CWT.	57
(c)	Curva ROC da Rede Neural radbas(100) logsig(10) com 25% das características mais relevantes baseadas em STFT.	57
(d)	Curva ROC da Rede Neural tansig(250) logsig(50) com 55% das características mais relevantes baseadas em CWT.	57
4.5	Acurácia média dos classificadores SVM dado o tipo de assinatura e quantidade de amostras usadas no treinamento (IC de 95%).	58

(a)	Acurácia dos classificadores com 25% das melhores características da assinatura baseada em STFT dada quantia de amostras usadas no treinamento.	58
(b)	Acurácia dos classificadores com todas as características da assinatura baseada em STFT dada quantia de amostras usadas no treinamento.	58
(c)	Acurácia dos classificadores com todas as características da assinatura baseada em CWT dada quantia de amostras usadas no treinamento.	58
4.6	Acurácia média das redes neurais treinadas com a configuração que obteve as melhores resultados de acordo com o tipo de assinatura e a variação da quantidade de amostras usadas no treinamento (IC de 95%).	59
(a)	Acurácia das redes neurais com 25% das melhores características da assinatura baseada em STFT dada quantia de amostras usadas no treinamento.	59
(b)	Acurácia das redes neurais com todas as características da assinatura baseada em STFT dada quantia de amostras usadas no treinamento.	59
(c)	Acurácia das redes neurais com todas as características da assinatura baseada em CWT dada quantia de amostras usadas no treinamento.	59

Lista de Tabelas

2.1	Índices das subportadoras reportadas pelo CSI dada a largura de banda e agrupamento implementado pelas interfaces de rede 802.11.	21
2.2	Comparação entre os trabalhos relacionados sobre detecção e identificação de atividades humanas através de perturbações do sinal eletromagnético encontrados na literatura.	30
3.1	Funções de ativação utilizadas no processo de treinamento e testes das redes neurais.	44
4.1	Acurácia média (%) das cinco configurações por percentual de características mais relevantes extraídas com o espectrograma baseado em STFT que produziram melhores resultados.	52
4.2	Acurácia média (%) das cinco configurações por percentual de características mais relevantes extraídas com o espectrograma baseado em CWT que produziram melhores resultados.	53
4.3	Matriz de confusão do classificador SVM com 25% das características mais relevantes baseadas em STFT.	54
4.4	Matriz de confusão do classificador SVM com todas características baseadas em CWT.	54
4.5	Matriz de confusão da Rede Neural radbas(100) logsig(10) com 25% das características mais relevantes baseadas em STFT.	54
4.6	Matriz de confusão da Rede Neural tansig(250) logsig(50) com 55% das características mais relevantes baseadas em CWT.	54

Introdução

Em ambientes inteligentes, existe uma grande demanda por dispositivos ou sensores que sejam capazes de entregar informações detalhadas do que ocorre dentro ou fora do ambiente. O monitoramento do fluxo de movimento pode ser importante para esse tipo de ambiente, dado que ele torna possível a configuração de diversos parâmetros, como por exemplo, ajuste de temperatura, luminosidade e até mesmo parâmetros de segurança do ambiente.

A detecção de fluxos de movimento pode, por exemplo, ser realizada por sensores especializados baseados em infra-vermelho. Entretanto, o uso desse tipo de sensor implica a aquisição e instalação em vários pontos do ambiente. Por outro lado, sinais eletromagnéticos de alta frequência são sensíveis o suficiente para captarem interferência de objetos e corpos pequenos, tornando possível detectar fluxos de movimento através do monitoramento das perturbações ocorridas nesse tipo de sinal. Interfaces de rede 802.11, comumente conhecidas como interfaces *WiFi*, são exemplos de dispositivos que utilizam esse tipo de sinal. Esses dispositivos estão amplamente disponíveis na maior parte dos ambientes fechados, o que torna a criação e implantação de sistemas que utilizem esses dispositivos como sensores bastante viável. Quando operando na banda de 5 GHz, os sinais eletromagnéticos podem ser perturbados por objetos com tamanho superior a cerca de 6 cm [21], transformando essas interfaces em possíveis sensores de atividades humanas e, conseqüentemente, possíveis sensores de fluxos de movimento humano.

Após a definição do padrão *IEEE 802.11n*, foi definido um mecanismo de monitoramento do canal sem fio das interfaces 802.11, conhecido como *Channel State Information (CSI)* [16]. Esse mecanismo é capaz de estimar as alterações sofridas pelo sinal eletromagnético, tanto na amplitude quanto na fase, durante a sua transmissão. Com esse mecanismo, se torna possível extrair de interfaces 802.11 convencionais e de baixo custo, as informações necessárias para se desenvolver sensores que utilizam essa tecnologia.

Trabalhos como os desenvolvidos por Li *et al.* [18] e por Wang *et al.* [26] utilizam as perturbações do canal sem fio para detectar e identificar atividades humanas. Entretanto, esses trabalhos identificam atividades de assinaturas bastante distintas, não

diferenciando, por exemplo, a direcionalidade do movimento humano. Também encontramos trabalhos na literatura que utilizam Rádios Definidos por Software (SDR's) [18]. O uso desse tipo de dispositivo resulta em um maior nível de detalhamento nas informações relativas às perturbações no canal sem fio, porém, o seu custo de aquisição é bastante elevado e o seu hardware não está amplamente disponível como ocorre com pontos de acesso 802.11.

Neste trabalho, propomos o WiDMove, um sistema capaz de transformar as interfaces de rede 802.11n convencionais, de baixo custo e já existentes nos ambientes, em sensores capazes de detectar os fluxos de movimento, detectando, por exemplo, quando um ser humano entra ou sai do ambiente. O WiDMove também é capaz de distinguir qual o tipo do fluxo de movimento, informando se o fluxo foi de entrada ou de saída do ambiente. Definimos a metodologia para a coleta das amostras de dados compostas pelas perturbações causadas pelos indivíduos enquanto entram ou saem do ambiente e, também, a metodologia para extração das assinaturas dos eventos. Posteriormente, apresentamos a metodologia para a criação dos modelos de classificação, utilizando técnicas e ferramentas de reconhecimento de padrões, que irão realizar a predição de um evento de movimento de entrada ou saída do ambiente em um determinado intervalo de tempo. Adicionalmente, também apresentamos uma ferramenta, nomeada *CSI Monitor*, que visa auxiliar o pesquisador na coleta e análise, em tempo real, das perturbações que estão ocorrendo nos sinais transmitidos por uma rede de dispositivos 802.11n.

O WiDMove foi implementado e testado em um ambiente de laboratório utilizando amostras reais de eventos emitidos por 8 indivíduos distintos. A seguir, apresentamos os principais objetivos deste trabalho e, por fim, apresentamos a forma à qual essa dissertação foi dividida.

1.1 Objetivos

O objetivo geral deste trabalho é propor um sistema capaz de transformar os dispositivos de rede sem fio 802.11n em sensores capazes de detectar fluxos de movimento, incluindo o movimento humano, e informar se o movimento realizado foi de entrada ou saída do ambiente. O sistema proposto deve contemplar o funcionamento comum de um ambiente, onde mais de um indivíduo distinto pode frequentá-lo. O sistema também deve ser capaz de identificar os eventos independente do indivíduo que o está realizando. Para atingirmos esses objetivos, algumas atividades intermediárias foram definidas:

- Definir e implantar um ambiente de experimentação que torne possível extrair as perturbações do canal sem fio quando um indivíduo está entrando ou saindo do ambiente.

- Coletar amostras das perturbações do canal sem fio enquanto indivíduos estão entrando e saindo do ambiente.
- Definir as características que são importantes para a distinção das perturbações provenientes de eventos de entrada, de eventos de saída e também de intervalos onde não ocorre nenhum evento.
- Definir um conjunto de modelos de reconhecimento de padrões que sejam capazes de classificar as assinaturas dos eventos extraídos.
- Instanciar os modelos definidos com as amostras de assinaturas de eventos coletadas.
- Validar e avaliar o desempenho dos modelos instanciados, com o objetivo de realizar a comparação dos modelos e definir qual deles produz os melhores resultados.

1.2 Organização da dissertação

O restante do trabalho está dividido em mais quatro capítulos, os quais apresentamos uma breve descrição a seguir. No Capítulo 2, introduzimos os conceitos fundamentais para a compreensão do trabalho. Adicionalmente, apresentamos os trabalhos relacionados a essa pesquisa encontrados na literatura.

No Capítulo 3 apresentamos a metodologia para o desenvolvimento da proposta. Definimos o conjunto de técnicas e processos necessários para a instanciação dos modelos propostos, desde a configuração do ambiente e coleta das amostras até a extração das assinaturas e treinamento dos modelos. Adicionalmente, apresentamos o *CSI Monitor*, uma ferramenta desenvolvida durante essa pesquisa que visa auxiliar o pesquisador coletando e mostrando, em tempo real, as medidas da magnitude das amostras CSI de cada subportadora.

No Capítulo 4 apresentamos os resultados das avaliações da proposta, realizadas através de experimentos com amostras reais de eventos de entrada e saída coletadas de 8 indivíduos distintos. Nos experimentos, comparamos a acurácia de dois tipos de assinaturas extraídas e de dois tipos de modelos de classificação treinados, com o objetivo de definirmos quais conjuntos de assinaturas e modelos resultam em uma maior acurácia. Por fim, o Capítulo 5 sintetiza as contribuições e apresenta breves discussões sobre as perspectivas de trabalhos futuros.

Fundamentos & Trabalhos Relacionados

Neste capítulo, apresentamos os fundamentos necessários para a compreensão do trabalho. Iniciamos apresentando os fundamentos relativos à tecnologia 802.11, incluindo o mecanismo de monitoramento de sinais eletromagnéticos do 802.11n. Posteriormente apresentamos as técnicas de processamento de sinais e reconhecimento de padrões que possibilitam a realização deste trabalho e, por fim, apresentamos os trabalhos relacionados a essa pesquisa encontrados na literatura.

2.1 A Tecnologia 802.11

A tecnologia IEEE 802.11 surgiu como uma opção de rede móvel para as tradicionais, e fixas, redes *ethernet* [22]. É uma tecnologia utilizada por dispositivos que fornece suporte a redes locais sem fio, conhecidas como *Wireless Local Area Network* (WLAN), que implementem o padrão IEEE 802.11 [7]. A tecnologia possui um conjunto de padrões que definem diversos mecanismos que podem ser implementados como forma de extensão de funcionalidade da interface de rede.

Exemplos mais recentes de padrões do 802.11 incluem as versões *n* e *ac*. Essas versões definem o suporte à múltiplas antenas, tecnologia conhecida como *Multiple-Input Multiple-Output* (MIMO) [13, 12]. Com essa tecnologia, os dispositivos de rede sem fio podem transmitir paralelamente mais de um símbolo ao mesmo tempo ou, utilizar as múltiplas antenas para garantir o recebimento correto do símbolo mesmo em maiores distâncias de transmissão.

A transmissão dos símbolos realizada por interfaces 802.11 que implementam os padrões mais recentes utiliza como técnica de modulação a *Orthogonal frequency-division multiplexing* (OFDM) [19]. Essa modulação divide a largura de banda de um canal sem fio em vários fragmentos menores, conhecidos como subportadoras, permitindo que vários símbolos sejam transmitidos em um mesmo instante de tempo em cada uma das subportadoras. A Figura 2.1 demonstra como é feita a divisão da largura de banda utilizando a modulação *OFDM*, onde, em cada instante de tempo são transmitidos símbolos em cada uma das subportadoras. A quantidade de subportadoras no 802.11

depende da largura de banda do canal utilizado. De acordo com o padrão 802.11n, temos 56 subportadoras nos canais de 20 MHz e 114 subportadoras nos canais de 40 MHz [16].




Figura 2.1: Visão de um canal sem fio que utiliza modulação OFDM.

Ainda no padrão 802.11n, foi definido um mecanismo de monitoramento do canal sem fio para que as interfaces de rede possam realizar ajustes finos na rede como, por exemplo, alterar a potência e a taxa de transmissão. Esse mecanismo estima as perturbações percebidas em cada subportadora do canal para cada par de antenas habilitadas durante a transmissão e o recebimento do símbolo OFDM, oferecendo um conjunto expressivo de métricas sobre a qualidade da transmissão dos sinais.

2.1.1 Mecanismo de monitoramento do canal sem fio 802.11

Definido no padrão 802.11n, o *Channel State Information* (CSI) é um mecanismo de monitoramento do canal sem fio para interfaces 802.11 capaz de descrever as alterações ocorridas, na amplitude e na fase, durante a transmissão de um sinal [16]. Esse mecanismo foi definido com o objetivo de auxiliar os dispositivos de rede 802.11 a se adaptarem às condições de transmissão do ambiente, oferecendo métricas para a realização de ajustes em parâmetros como potência e taxa de transmissão.

Esse monitoramento é realizado pelo receptor quando recebe pacotes elegíveis à computação dessa informação que, de acordo com o padrão 802.11n, são os pacotes transmitidos a uma taxa *High Throughput* (HT). Após a computação do CSI, o receptor envia para o transmissor as informações computadas em forma de *feedback*. O CSI é uma matriz composta por um conjunto de métricas denominadas *Channel Frequency Response* (CFR). A CFR representa a estimativa das alterações que o sinal eletromagnético sofreu, na amplitude e na fase, durante a sua transmissão. A CFR é representada por um número

complexo e é mensurada para cada subportadora e em cada par de antenas entre os dispositivos transmissores e receptores da rede sem fio.

Para cada pacote de dados transmitido em uma rede 802.11n, é computada uma matriz CSI, de dimensão $N_{tx} \times N_{rx} \times N_{sub}$, onde N_{tx} representa o número de antenas no dispositivo transmissor, N_{rx} o número de antenas no dispositivo receptor e N_{sub} o número de subportadoras disponíveis no canal sem fio utilizado pela rede. N_{sub} pode variar conforme o nível de agrupamento implementado pela interface sem fio. Os níveis de agrupamento e os índices das suas respectivas subportadoras são definidos no padrão 802.11n, conforme exposto pela Tabela 2.1 [16].

O funcionamento do CSI pode ser observado na Figura 2.2, que expõe o seguinte processo: (1) O transmissor realiza a transmissão de um pacote elegível para computação da matriz CSI; (2) o receptor recebe o pacote e cria a matriz CSI, computando uma CFR para cada subportadora em cada par de antenas; (3) O receptor devolve as informações computadas para o transmissor; e (4) o transmissor realiza, caso necessário, os ajustes na rede.




Figura 2.2: Funcionamento do CSI em redes 802.11.

Tabela 2.1: Índices das subportadoras reportadas pelo CSI dada a largura de banda e agrupamento implementado pelas interfaces de rede 802.11.

Largura de Banda	Agrupamento	Nº de sub-portadoras	Índices das sub-portadoras
20MHz	1	56	Todas subportadoras: -28, -27, ..., -2, -1, 1, 2, ..., 27, 28
	2	30	-28, -26, -24, -22, -20, -18, -16, -14, -12, -10, -8, -6, -4, -2, -1, 1, 3, 5, 7, 9, 11, 13, 15, 17, 19, 21, 23, 25, 27, 28
	4	16	-28, -24, -20, -16, -12, -8, -4, -1, 1, 5, 9, 13, 17, 21, 25, 28
40MHz	1	114	Todas subportadoras: -58, -57, ..., -3, -2, 2, 3, ..., 57, 58
	2	58	-58, -56, -54, -52, -50, -48, -46, -44, -42, -40, -38, -36, -34, -32, -30, -28, -26, -24, -22, -20, -18, -16, -14, -12, -10, -8, -6, -4, -2, 2, 6, 8, 10, 12, 14, 16, 18, 20, 22, 24, 26, 28, 30, 32, 34, 36, 38, 40, 42, 44, 46, 48, 50, 52, 54, 56, 58
	4	30	-58, -54, -50, -46, -42, -38, -34, -30, -26, -22, -18, -14, -10, -6, -2, 2, 6, 10, 14, 18, 22, 26, 30, 34, 38, 42, 46, 50, 54, 58

2.1.2 Monitoramento de atividades ocorridas em ambientes utilizando o CSI

O símbolo OFDM recebido pelo receptor é uma resultante da energia enviada pelo transmissor e as perturbações sofridas na subportadora durante a sua transmissão. Como as perturbações incluem interferências produzidas pelo ambiente e a CFR descreve essas perturbações, é possível mensurar as atividades que ocorrem em um ambiente utilizando as matrizes CSI. Diversos trabalhos utilizando as métricas do CSI para os mais variados propósitos surgiram na literatura, incluindo o monitoramento dos sinais vitais de seres humanos [20] e a detecção de atividades humanas [26]. O monitoramento de atividades humanas usando o CSI é possível devido, dentre outros fatores, aos corpos humanos serem compostos basicamente por água e sais minerais, o que os torna bons interferentes de sinais eletromagnéticos. Como a CFR descreve as alterações ocorridas na amplitude e na fase do sinal durante a sua transmissão, as atividades realizadas pelos corpos humanos podem ser observadas no CSI.

Quando um ambiente permanece sem movimentação, os valores do CSI tendem a permanecer relativamente constantes. Entretanto, quando há movimentação no ambiente, os valores tendem a flutuar devido as alterações nos percursos de propagação dos sinais eletromagnéticos, causadas pelo efeito de multipercurso. A Figura 2.3 demonstra um exemplo desse efeito, onde, no instante $t(0)$ o sinal é propagado por percursos diferentes dos do instante $t(1)$, resultando em medidas CSI diferentes. Essas diferenças se tornam ainda mais perceptíveis quando há uma movimentação na *Line of Sight* (LoS), que é a menor linha de comunicação direta entre os dispositivos. Essa alta interferência ocorre devido a LoS deter a maior quantidade de energia recebida durante a comunicação entre o transmissor e o receptor. Portanto, quando há uma obstrução na LoS, o sinal eletromagnético sofre maior interferência, resultando em medidas CSI mais pronunciadas.




Figura 2.3: Exemplo do efeito de multipercurso quando uma pessoa se movimenta em um ambiente.

À medida que a frequência base do canal sem fio aumenta, menor é o tamanho

dos objetos que são capazes de causar perturbações com maior facilidade no sinal transmitido nesse canal. O comprimento necessário para que um objeto cause interferência no sinal com maior facilidade é dado pela relação $\lambda = c/f$, onde c representa a velocidade da luz e f a frequência do canal em Hz [21]. Considerando canais sem fio na faixa de 5 GHz disponíveis em dispositivos que implementam o padrão 802.11a, temos um cenário onde objetos e corpos com tamanho superior a cerca de 6 cm são capazes de perturbar significativamente os sinais transmitidos nesse canal, incluindo seres humanos que se movimentam no ambiente da rede.

Devido à grande facilidade dos sinais eletromagnéticos da faixa de 5 GHz serem perturbados, se torna necessário, em sistemas que necessitem de medidas CSI mais isoladas, o estudo de alternativas que isolem as perturbações dos sinais eletromagnéticos. Uma das alternativas possíveis é o uso de antenas direcionais, que visam focar o feixe de propagação e recepção do sinal em uma determinada direção, diminuindo a relação sinal/ruído percebida pelo dispositivo e, consequentemente, as perturbações percebidas pelo CSI. A Figura 2.4 demonstra as diferenças no modelo de propagação e recepção de energia utilizando antenas direcionais e omni-direcionais.





Figura 2.4: Diferenças do modelo de propagação e recepção de energia entre antenas direcionais e omni-direcionais.


O CSI foi desenvolvido para auxiliar os dispositivos de rede sem fio a realizarem ajustes na configuração da rede quando operando em alta taxa de transmissão (HT). Portanto, além das medidas CSI não serem geradas para todos os tipos de sinais transmitidos na rede, elas não podem ser obtidas de forma nativa pelo usuário ou aplicações que não sejam o *driver* do dispositivo de rede. Por isso, são necessárias modificações nos *drivers* desses dispositivos de rede sem fio para que se torne possível extrair as amostras CSI. Duas ferramentas de extração bastante utilizadas são as desenvolvidas por Xie *et al.* [27] e Halperin *et al.* [14]. Essa ferramentas possibilitam extrair as medidas CSI de alguns modelos de interfaces 802.11n *ath9k* da *Atheros* e da interface de rede *Intel Wi-Fi Wireless Link 5300 802.11n*. No caso da ferramenta para os dispositivos da *Atheros*, existe ainda a

possibilidade de instalação em sistemas Ubuntu e *OpenWrt*.

Os deslocamentos da amplitude e da fase observados nas amostras CSI tendem a variar bastante no tempo devido, dentre outros fatores, à característica do OFDM de alta variação de energia, da dessincronização entre os dispositivos e até mesmo de imperfeições de *hardware* nos dispositivos sem fio. Conforme podemos observar na Figura 2.5, que expõe amostras CSI de algumas subportadoras no decorrer do tempo, podemos observar que o CSI possui um grande nível de variação mesmo sem movimentação no ambiente, o que gera um alto nível de ruído branco quando tentamos extrair informações relativas às atividades que estão sendo realizadas no ambiente da rede. Portanto, torna-se necessária a aplicação de técnicas de processamento de sinais para a extração das informações relativas as atividades que ocorrem neste ambiente.



(a) Amostras do deslocamento da amplitude, observadas no tempo, coletadas pelo CSI à uma taxa de amostragem de 800 pps.



(b) Amostras do deslocamento da fase, observadas no tempo, coletadas pelo CSI à uma taxa de amostragem de 800 pps.

Figura 2.5: Amostras CSI coletadas no tempo à uma taxa de amostragem de 800 pps.

2.2 Representação e processamento de sinais CSI

A presença e a posição de objetos em um ambiente interfere na propagação do sinal eletromagnético e, conseqüentemente, na qualidade da transmissão do canal. Esse fenômeno faz do CSI uma medida capaz de associar a presença e a posição de objetos com a qualidade da transmissão do canal. Do mesmo modo, a avaliação do CSI no tempo permite estender esse conceito para a distinção do movimento de objetos no ambiente.

O CSI pode ser representado no tempo, conforme podemos observar nas Figuras 2.5(a) e 2.5(b). Entretanto, suas medidas possuem grande quantia de ruído quando tentamos extrair informações relativas aos eventos que ocorrem no ambiente. Esse problema se torna ainda mais forte quando utilizamos uma taxa de amostragem mais alta. A extração de características que descrevam eventos do ambiente deve ser obtida através do processamento do sinal CSI, onde reduzimos a alta dimensionalidade dos dados e selecionamos as características mais representativas para o evento monitorado. A seguir, apresentamos as técnicas de processamento de sinais aplicadas neste trabalho durante o processamento do CSI e a extração do vetor de características que representa as classes dos fluxos de movimento de entrada e saída do ambiente.

2.2.1 Principal Component Analysis (PCA)

É uma técnica estatística de transformação linear ortogonal que visa transformar os dados para um novo sistema de coordenadas que ordena as informações de acordo com o seu nível de variância. Essa técnica é amplamente usada em seleção de características e consiste em encontrar, a partir dos dados originais, um conjunto de variáveis não correlacionadas, denominadas *Principal Componentes* (PCs), e suas respectivas importâncias dentro do conjunto de dados. Os PCs são relacionados aos auto-vetores da matriz de dados e a importância de cada um é quantificada pelo seu respectivo auto-valor. A equação de PCA é definida por:

$$Y^T = V \Sigma^T W^T W,$$

Onde, W representa a matriz de autovalores da matriz de covariância, Σ é uma matriz diagonal retangular com números reais não negativos na diagonal e V é a matriz de autovetores da matriz de dados.

No contexto deste trabalho, a técnica é utilizada para o propósito de filtragem. Como podemos observar na Figura 2.5(a), as variações na magnitude do CSI são correlacionadas entre as subportadoras, tornando possível a utilização dessa técnica para ordenação e exclusão de componentes que representem o maior nível de variância, ou seja, componentes que representem ruído branco.

2.2.2 Fast Fourier Transform (FFT)

É um algoritmo capaz de calcular de forma eficiente a transformada discreta de Fourier. Com essa transformada é possível representar um sinal no tempo no domínio da frequência, tornando assim possível a análise espectral das frequências que compõem o sinal original. A FFT é definida por:

$$F(u) = \frac{1}{N} \sum_{x=0}^{N-1} f(x) W_n^{ux},$$

Onde, $N = 2^n$, onde n é um número inteiro positivo e $W_n^{ux} = e^{-j2\pi ux/N}$.

2.2.3 Short-Time Fourier Transform (STFT)

É usada para avaliar a variação temporal do espectro de frequências de um sinal. Ela consiste a aplicação da transformada de Fourier em segmentos do sinal agregando assim a informação de tempo ao espectro de frequências. O resultado dessa técnica é denominado espectrograma do sinal. A STFT é definida por:

$$X_{(r,w)} = \int_{-\infty}^{\infty} x(t) w_{(t-r)} e^{-j\omega t} dt,$$

Onde, $w(t)$ é a função da janela e $x(t)$ o sinal a ser transformado.

2.2.4 Continuous Wavelet Transform (CWT)

Técnica com objetivos similares à STFT que, no entanto, utiliza uma transformada baseada em uma Wavelet mãe para decompor o sinal em diversas escalas de tempo-frequência. Como resultado, obtemos um escalograma do sinal que descreve em escalas logarítmicas, o sinal no domínio tempo-frequência. A CWT de uma função $x(t)$ em uma escala $a > 0$ é dada por:

$$X_w(a, b) = \frac{1}{|a|^{1/2}} \int_{-\infty}^{\infty} x(t) \bar{\Psi} \left(\frac{t-b}{a} \right) dt,$$

Onde, $\Psi(t)$ representa a função contínua no domínio da frequência e do tempo denominada *Wavelet Mãe*.

2.3 Reconhecimento de padrões

A área de reconhecimento de padrões trata principalmente de problemas de classificação. Nesse tipo de problema, temos o conceito de características, que são informações que visam descrever uma instância de um determinado objeto. O Objetivo

desse tipo de problema é isolar as características semelhantes dos objetos de uma mesma classe e criar um modelo que consiga separar e distinguir os objetos dessa classe [10]. Sinais produzidos pelas amostras CSI no tempo podem ser representados por um conjunto de características, o que torna possível a utilização de modelos de classificação para a resolução desse tipo de problema.

Na literatura, existem diversos modelos que resolvem os problemas de classificação. Cada tipo de modelo possui suas características, o que os torna melhores para determinados tipos de dados que estão incluídos nos conjuntos de características do problema. Um desses classificadores é o *Support Vector Machine* (SVM), que busca encontrar um modelo matemático que maximiza a margem de separação das classes no espaço de parâmetros. Esse tipo de modelo divide o plano de dados em duas partes, uma positiva e outra negativa, sem grande parametrização. Portanto, problemas que incluem duas classes são bastante recomendados para esse tipo de classificador. Problemas que visem utilizar esse tipo de classificador e que possuem mais de duas classes, normalmente utilizam vários classificadores SVM, que são utilizados em conjunto para a obtenção da predição final.

Outra opção mais recente para a solução de problemas de classificação são as redes neurais. Dentre elas, as redes do tipo *Multilayer Perceptral* (MLP), que buscam o aprendizado baseado em gradiente para atualizar os pesos sinápticos dos seus neurônios. O problema desse tipo de modelo é que ele possui uma grande quantidade de parametrização e que, devido ao seu método de treinamento, talvez seja necessário o treino de várias redes para que se atinja o melhor caso. Em relação à parametrização, também não há nenhuma metodologia muito bem definida que defina os parâmetros corretos dado o conjunto de características do problema, o que torna necessário muitos testes para a obtenção do melhor modelo para a resolução do problema. Entretanto, esse tipo de modelo tem sido bastante utilizado na literatura, e possui a capacidade de obtenção de bons resultados quando configurado adequadamente.

Técnicas de avaliação desses tipos de modelos incluem a validação cruzada, que visa dividir o conjunto de amostras em K partes distribuídas aleatoriamente e realizar K experimentos, cada um deles excluindo uma das K partes das amostras de treinamento e utilizando-a para testes de predição. Por fim, calculamos a média da acurácia obtida desses K experimentos. Essa técnica é conhecida como *K-Fold* e, a sua variação, conhecida como *Leave-One-Out*, consiste no uso da mesma técnica configurando K como a quantidade de amostras existentes, de modo que cada experimento irá treinar um modelo com todas menos uma amostra de teste e irá tentar prever essa única amostra.

2.4 Trabalhos Relacionados

Nesta Seção apresentamos os principais trabalhos que monitoram as perturbações do sinal eletromagnético com o objetivo de detectar e identificar seres humanos e suas atividades.

Li *et al.* propuseram o *Hoble* [18], um sistema capaz de identificar seres humanos e detectar algumas de suas atividades como andar, sentar e cair. O sistema também é capaz de estimar a localização dos indivíduos presentes no ambiente. A assinatura dos indivíduos é criada utilizando dados de efeito *Doppler* e multipercorso [24]. Os autores utilizaram um *test-bed* de SDRs capaz de simular um dispositivo 802.11, fazendo-o transmitir *beacons* a uma taxa fixa. Posteriormente, o sistema extrai dos *beacons* as perturbações ocorridas durante a sua transmissão e as utiliza como dados de entrada. O sistema obteve uma acurácia de 87% na identificação de indivíduos e 90% na localização de indivíduos em testes realizados com 6 indivíduos distintos.

Wang *et al.* propuseram o *CARM* [26], um sistema capaz de reconhecer atividades humanas realizadas em um ambiente em tempo real. O sistema é dividido em duas etapas, a primeira consiste na criação de um modelo de velocidade que cria um perfil da atividade realizada pelos indivíduos. A segunda etapa utiliza os resultados do modelo de velocidade para definir e classificar a atividade humana que está sendo executada. Os resultados obtidos pelo *CARM* demonstraram uma acurácia superior a 96% para 8 atividades distintas realizadas no ambiente treinado. Também foram realizados testes em um ambiente diferente ao qual o modelo foi criado e a acurácia obtida foi de cerca de 80%.

Zhang *et al.* propuseram um sistema capaz de reconhecer indivíduos através do seu andar pela LoS entre transmissor e receptor de uma rede 802.11 [28]. Os autores utilizaram as medidas CSI obtidas de 3 pares de antenas entre transmissor e receptor, o que gerou uma grande quantidade de características. Mesmo com essa grande quantidade de características, os resultados demonstraram uma baixa significativa na acurácia à medida que o número de indivíduos únicos que frequentam o ambiente aumenta. O trabalho apresentou uma acurácia que varia entre 93% e 77% em ambientes que possuam entre 2 e 6 indivíduos distintos respectivamente.

Diferente dos trabalhos apresentados, a nossa proposta detecta e identifica os fluxos de movimento de objetos que estão entrando ou saindo do ambiente, incluindo os seres humanos. Por se tratar de uma mesma espécie de atividade, as características de entrada e saída do ambiente são bastante similares, tornando um desafio identificá-las. Outra diferença é que utilizamos apenas interfaces 802.11 convencionais e de baixo custo, funcionando apenas com as medidas CSI que, apesar de possuírem um nível de detalhamento inferior ao de SDR's, torna a solução muito mais barata e acessível. Apesar de não termos encontrado na literatura nenhum trabalho diretamente relacionado a este,

a Tabela 2.2 mostra um comparativo entre os trabalhos encontrados na literatura que utilizam a mesma tecnologia para detecção de atividades humanas.

2.5 Conclusão

Neste capítulo, foram apresentados alguns fundamentos necessários para a compreensão deste trabalho. Inicialmente apresentamos uma breve descrição geral sobre a tecnologia 802.11, abordando os principais conceitos da tecnologia utilizados neste trabalho. Posteriormente abordamos em maior detalhamento os aspectos do mecanismo de monitoramento do espectro sem fio oferecido pelo 802.11n e apresentamos as motivações e justificativas que nos possibilitaram realizar essa pesquisa utilizando as métricas do CSI. Também apresentamos os fundamentos sobre as técnicas usadas neste trabalho para o processamento dos sinais produzidos com as métricas CSI e para criação dos modelos que possibilitam a detecção e classificação dos eventos de entrada e saída produzidos pelo movimento dos seres humanos. Por fim, apresentamos alguns trabalhos encontrados na literatura e que estão diretamente relacionados a nossa pesquisa.

Nos próximo capítulo, apresentamos a metodologia para a instanciação da nossa proposta de detecção dos eventos de entrada e saída produzidos pelos movimentos dos seres humanos. Adicionalmente, apresentamos uma ferramenta desenvolvida durante essa pesquisa que, coleta e exibe em tempo real, as métricas da magnitude do CSI obtidas de dois dispositivos de rede 802.11.

Tabela 2.2: *Comparação entre os trabalhos relacionados sobre detecção e identificação de atividades humanas através de perturbações do sinal eletromagnético encontrados na literatura.*

Trabalho	Objetivo	Equip. especiais	Usuários	Performance
Li <i>et al.</i> (Hoble) [18]	Identificar e localizar seres humanos em um ambiente e detectar algumas atividades, como andar, correr e cair.	Rádio Definido por Software (SDR)	6	- 87% para identificação - 90% para localização
Wang <i>et al.</i> (CARM) [26]	Detectar 8 tipos de atividades humanas realizadas no ambiente utilizando um modelo de velocidade.	Nenhum	25	- 96% para o ambiente de treino - 80% para outro ambiente
Zhang <i>et al.</i> [28]	Identificar (reconhecer) indivíduos que passaram pela LoS de dispositivos de rede sem fio.	Nenhum	6	- 93% para 2 indivíduos distintos no modelo - 77% para 6 indivíduos distintos no modelo
WiDMove	Identificar fluxos de movimento de entrada e saída de ambientes (incluindo movimento humano).	Antenas direcionais	8	- 93% de acurácia média - 97% de acurácia máxima

Metodologia & Proposta

Neste capítulo, propomos um sistema capaz de detectar fluxos de movimento em um ambiente fechado e distinguir se esse movimento está sendo realizado por um indivíduo para entrar ou sair do ambiente. Nas próximas seções, descrevemos os fundamentos da solução e apresentamos a metodologia e as ferramentas necessárias para a criação do sistema. Adicionalmente, descrevemos o *CSI Monitor*, uma ferramenta desenvolvida para a coletar, em tempo real, os dados utilizados como entrada para a criação do sistema.

3.1 Detecção de fluxos de movimento

A detecção de fluxos de movimento através do monitoramento do sinal eletromagnético parte do princípio de que as perturbações causadas por objetos e por corpos humanos possuem diferenças de acordo com o sentido de seu movimento. Isso ocorre devido ao efeito de multi-percurso do sinal, onde, para uma determinada rajada de sinais transmitidos, os sinais são absorvidos e refletidos de formas diferentes, dada a direção do movimento do objeto. Essa diferença se dá, principalmente por dois fatores: (1) A direção do movimento gera padrões de multi-percurso diferentes; e (2) Apesar da simetria, os objetos e corpos humanos podem ser bombardeados por sinais eletromagnéticos em diferentes angulaturas, dependendo do sentido do movimento, o que pode produzir um padrão diferente de perturbação. A Figura 3.1 exemplifica como o sinal eletromagnético pode sofrer interferências distintas a medida que ocorre a movimentação do corpo humano, produzindo magnitudes CSI distintas. Caso o movimento humano fosse realizado no sentido inverso, os multipercursos dos sinais seriam diferentes e, portanto, seria possível diferenciar a direcionalidade do movimento.

Para realizar esse trabalho, precisamos de dispositivos que consigam determinar as perturbações sofridas no sinal eletromagnético durante a sua transmissão. As perturbações que precisamos coletar são: (1) Estimação do efeito de multipercurso; e (2) A diferença do nível de energia do sinal recebido em relação à sua transmissão.




Figura 3.1: Alterações no CSI de acordo com a movimentação do corpo humano baseado no efeito de multipercurso.

Neste trabalho, propomos uma solução baseada dispositivos de rede sem fio 802.11a/n, transformando-os em sensores capazes de identificar os fluxos de movimento de objetos e seres humanos. Nossa proposta utiliza dois dispositivos de rede sem fio, um para enviar os sinais eletromagnéticos e outro para recebê-los e computar as perturbações que ocorreram durante as transmissões utilizando o CSI. Após obtermos o CSI, extraímos dele as informações necessárias para verificarmos se há um fluxo de movimento no ambiente e, caso positivo, identificamos a assinatura desse movimento, incluindo sua direcionalidade.

Durante o processo de definição das assinaturas dos eventos, é necessário identificar as informações que melhor descrevam a classe do evento, caso contrário, podemos confundir o nosso modelo, resultando em uma baixa acurácia. Para isso, precisamos saber informações sobre os eventos que estamos monitorando e o impacto que eles causam no sinal eletromagnético.

Por fim, é necessária a criação de um modelo de classificação capaz de distinguir as classes das assinaturas extraídas. Nesse processo, é importante a escolha de um modelo que se adeque melhor ao conjunto de características que compõem as assinaturas dos eventos, uma vez que existem inúmeros tipos e configurações disponíveis na área reconhecimento de padrões. Nas próximas seções, descrevemos o processo e a metodologia aplicada para o desenvolvimento de nossa proposta.

3.2 WiDMove - sistema de detecção de fluxos de movimento em ambientes fechados

Nesta seção, descrevemos a metodologia utilizada para criar o WiDMove, um sistema capaz de detectar, utilizando apenas dispositivos de rede sem fio 802.11n, os fluxos de movimentos de entrada e saída de um ambiente fechado. A metodologia foi dividida em cinco etapas: (1) Preparação do ambiente e coleta das amostras CSI que serão usadas para treinar o modelo de classificação; (2) Criação do espectrograma das amostras coletadas; (3) Preparação dos dados coletados para uso no modelo; (4) Extração das características necessárias para identificação e diferenciação de intervalos de amostras que possuem ou não eventos de entrada ou saída; e (5) Criação do modelo capaz de classificar, dentro de intervalos de amostras, se há ou não a presença de um evento de entrada ou saída. A Figura 3.2 mostra as etapas de execução da metodologia proposta para a criação do WiDMove. A seguir, descrevemos cada uma das etapas da metodologia.




Figura 3.2: Metodologia de criação do WiDMove.

3.2.1 Preparação do ambiente e coleta das amostras CSI

Nesta subseção, apresentamos o processo de preparação e configuração do ambiente ao qual o WiDMove será desenvolvido e implantado e, por fim, explicamos o processo e as ferramentas utilizadas na etapa de coleta das amostras CSI.

Preparação do ambiente para coleta das amostras CSI

Neste trabalho, utilizamos os dispositivos de rede sem fio da *Atheros*, com suporte ao padrão 802.11n. Para o estabelecimento da rede, utilizamos as aplicações *Hostapd* [2] e *WPA Supplicant* [3]. A rede foi estabelecida no modo infraestruturado, utilizando um canal com largura de banda de 20 MHz.

Apesar de ser uma espécie de equipamento especial e adicionar algumas restrições ao nosso sistema, utilizamos um par de antenas direcionais manufaturadas nos

dispositivos de rede 802.11. O objetivo do uso dessas antenas é de reduzir a relação sinal/ruído produzida por perturbações indesejadas do ambiente. Dessa forma, conseguimos distinguir mais facilmente as perturbações de fluxos de movimento de entrada e saída do ambiente no CSI. Para isso, posicionamos os dispositivos e suas antenas nas extremidades da entrada do ambiente, conforme mostrado pela Figura 3.3.




Figura 3.3: Dispositivos de rede e ambiente de experimentação.

Nesse trabalho, utilizamos a ferramenta da *Atheros* para o sistema operacional Ubuntu, a qual foi instalada em ambos computadores.

Coleta das amostras CSI

Nesta etapa, precisamos escolher uma taxa de amostragem capaz de descrever os eventos que desejamos observar. Atividades geradas pelos corpos humanos podem ser descritas em uma frequência de até 300 Hz [26], por isso, é importante termos uma taxa de amostragem superior a 300 Hz. Escolhemos utilizar uma taxa de amostragem de 400 Hz, pois ela fornece uma margem de segurança na descrição dos eventos. Isso significa que o nosso dispositivo foi configurado para transmitir pacotes à uma taxa de 800 pps. Precisamos configurar um transmissor para enviar pacotes à essa taxa de amostragem devido, principalmente, a dois fatores: (1) O CSI não é computado para pacotes de controle da rede; e (2) A taxa de amostragem do tráfego que está fluindo na rede pode ser menor que a necessária para o funcionamento do sistema. O uso de dois equipamentos, um transmissor e outro receptor, ambos com os *drivers* de extração CSI instalados, se deu devido a uma restrição da implementação das ferramentas de extração, caso contrário, seria possível usar dispositivos convencionais para o envio dos pacotes.

Em nosso ambiente de experimentação, observamos que os dispositivos nos entregam amostras CSI de cerca de 90% dos pacotes que são transmitidos. Os fatores que levam a esse fator são perdas na rede e, principalmente, ao atraso de processamento e entrega das amostras enquanto elas são enviadas ao arquivos de dispositivos de hardware (*/dev/csi-dev*) criado pela ferramenta extratora. Podemos observar esse efeito quando

analisamos o tempo de chegada de cada amostra no arquivo de dispositivo. Observamos que a média do atraso das amostras CSI, para uma taxa de transmissão de 800 pps, é de cerca de $1378 \mu s$, o que corresponde a 725 amostras por segundo. Entretanto, para recebermos 800 pacotes por segundo, deveríamos ter um atraso médio de $1250 \mu s$. Ao observarmos a Figura 3.4(a), podemos notar que diversas amostras chegam com atraso superior ao desejado, porém, como apenas cerca de 10% das amostras correspondem à aquelas com atraso elevado e que, elas estão distribuídas aleatoriamente na amostra, continuamos considerando uma taxa de amostragem de 400 Hz.




Figura 3.4: Tempo de chegada das amostras CSI.

Para a coleta das amostras, utilizamos uma ferramenta desenvolvida neste trabalho e que será apresentada na Seção 3.3. Configuramos a ferramenta extratora com: (1) envio de 800 pps; (2) tempo de teste de 60 segundos; e (3) janela de dados de 60 segundos. Em cada execução do teste de coleta dos dados, os indivíduos iniciaram dentro do ambiente e, posteriormente saíram, aguardaram cerca de 10 segundos do lado de fora e voltaram para dentro do ambiente. Todos os indivíduos foram orientados a andarem da forma mais natural possível, com o objetivo de replicar o cenário mais comum do ambiente.

Ao final de cada execução, extraímos as amostras utilizando a própria opção fornecida pela ferramenta. Como utilizamos apenas um par de antenas, coletamos os dados apenas para o par de antenas utilizado. Portanto, cada amostra de teste consiste em uma matriz bi-dimensional de tamanho $N_{CSI} \times N_{Sub}$, onde N_{CSI} corresponde ao número de amostras CSI recebidas e ordenadas no tempo e N_{Sub} ao número de subportadoras do canal sem fio reportadas pelo CSI. Como utilizamos um canal de 20 MHz e dispositivos que não realizam nenhum agrupamento de subportadoras no CSI, N_{Sub} equivale a 56 subportadoras. O tamanho, em segundos, de cada amostra de teste variou de acordo com o tempo que cada indivíduo levou para andar até o lado de fora do ambiente, aguardar alguns segundos e retornar, o que na média nos gerou amostras com duração entre 30 e 50 segundos.

3.2.2 Criação dos espectrogramas

Nesta subseção, descrevemos o processo de criação dos espectrogramas que serão capazes de descrever os eventos de entrada e saída presentes nas amostras CSI no domínio tempo-frequência. Os espectrogramas são utilizados tanto na fase de preparação dos dados, para a definição dos intervalos dos eventos, quanto na fase de extração de características dos eventos, com os sinais já filtrados. A seguir, descrevemos o processo de criação dos espectrogramas utilizando duas técnicas, uma baseada em STFT e outra baseada em CWT. Neste trabalho, essas técnicas não foram utilizadas de forma conjunta, ou seja, cada técnica nos fornece um conjunto distinto de características na etapa de extração das assinaturas. No Capítulo 4, expomos um comparativo dos resultados de ambas as técnicas.

Espectrograma com Short-Time Fourier Transform (STFT)

O processo de criação desse espectrograma é baseado em uma técnica definida em [25] que, além de criar um espectrograma utilizando a técnica de STFT, também realiza algumas otimizações para remover intervalos de tempo que não possuem nenhuma atividade humana e para atenuar intervalos nos quais exista alguma atividade.

Como entrada para a criação do espectrograma, utilizamos as 20 componentes PCA de maior relevância da amostra de teste, onde, em cada uma delas, computamos a STFT utilizando como parâmetros uma janela de 256 amostras e 155 amostras sobrepostas. Essa configuração, para uma taxa de amostragem de 400 Hz, nos proporciona um nível de detalhamento de 3,12 Hz e 0,12 segundos por janela.

Processamos cada uma das STFTs computadas em um processo de cinco etapas: (1) Zerar as energias das frequências acima de 100 Hz; (2) Buscar os quadros de tempo cuja somatória da energia de todas as frequências não atinja um valor mínimo obtido através de testes; (3) Normalizar a energia de cada uma das frequências dos quadros de tempo através da divisão pela somatória das energias da frequência; (4) Remoção do ruído de fundo através da subtração da média da energia de cada frequência nos quadros buscados na etapa (2); e (5) Zerar as energias dos quadros buscados na etapa (2).

Após a computação e otimização de cada uma das 20 STFTs, somamos as energias de todas e normalizamos a energia resultante entre 0 e 1. Por fim, obtemos o espectrograma final aplicando um filtro gaussiano nos dados normalizados, utilizando como parâmetros o desvio padrão $\sigma = 0,8$ e tamanho do filtro $tf = 5$ quadros. A Figura 3.5 mostra um exemplo de um espectrograma obtidos com essa técnica quando uma pessoa entra e sai de um ambiente.




Figura 3.5: *Espectrograma de amostra de teste incluindo eventos de entrada e saída criados com STFT.*

Espectrograma com Continuous Wavelet Transform (CWT)

O espectrograma baseado em CWT difere um pouco do criado com a STFT, iniciando pelo seu processamento, que não necessita de tantos passos quanto no anterior. Como entrada, utilizamos apenas da segunda à sexta componente PCA mais relevante, uma vez que a primeira possui grande nível de representatividade de ruído. Computamos a CWT de cada uma dessas cinco componentes PCA utilizando como função a *Morlet Wavelet* e uma frequência de 400 Hz.

Cada CWT computada passa por um processo de otimização de três passos: (1) Remoção do ruído de fundo através da subtração da média da energia em cada intervalo de tempo das suas respectivas frequências; (2) Zerar as energias de frequências superiores a 100 Hz; e (3) Zerar energias negativas.

Após a computação e otimização de cada uma das 5 CWTs, somamos as energias de todas e normalizamos a energia resultante entre 0 e 1. Por fim, obtemos o espectrograma final aplicando um filtro gaussiano nos dados normalizados, utilizando como parâmetros o desvio padrão $\sigma = 0,8$ e tamanho do filtro $tf = 5$ quadros. A figura 3.6 mostra um espectrograma de uma amostra de teste utilizando a técnica acima descrita.




Figura 3.6: *Espectrograma de amostra de teste incluindo eventos de entrada e saída criados com CWT.*

3.2.3 Preparação das amostras CSI

Nesta subseção, descrevemos o processo de preparação das amostras CSI ao qual expomos as amostras de testes coletadas antes de utiliza-las para extração das características. Essa preparação é realizada em duas etapas: (1) Detecção e extração prévia dos intervalos, em cada amostra de teste, onde cada evento de entrada e saída estão localizados; e (2) Conversão e filtragem da magnitude das amostras CSI.

Detecção dos intervalos dos eventos nas amostras

A detecção prévia dos intervalos dos eventos possui como objetivo realizar a normalização/sincronia do intervalo dos eventos de entrada e saída dentro das amostras CSI. Essa etapa é necessária devido as pessoas se movimentarem em padrões e velocidades diferentes.

De acordo com Wang *et al.* [25], os movimentos do torso humano estão localizados na faixa de frequência de 20 até 50 Hz. Por esse motivo, o método proposto busca por intervalos de tamanho mínimo $\Delta t = 1,2$ segundos que possuam energia em todas as janelas de tempo na faixa de frequência do torso humano. A escolha do intervalo de 1,2 segundos foi obtido pelo valor de 80% da duração mínima das perturbações por movimento humano encontrados em nossas amostras de teste. Para cada um dos intervalos encontrados, verificamos se a média da energia total, calculada para todas frequências e janelas de tempo, dividida pela média de todas energias presentes em todo espectrograma, $\Delta E \geq 0,5$. Caso o intervalo encontrado satisfaça essas condições, ele é considerado um intervalo de evento de entrada ou saída. Nessa etapa, utilizamos o espectrograma baseado em SFTF descrito na Subseção 3.2.2.

Cada evento pode ter duração variada, uma vez que as pessoas não andam na mesma velocidade e nem mesmo mantêm a mesma velocidade em todas amostras. Em nossas amostras, a duração dos eventos variam entre 1,5 e 3,5 segundos. Assim, escolhemos extrair as amostras dos eventos com um tamanho fixo de 4 segundos. Para cada intervalo de evento encontrado, selecionamos a segunda componente do sinal da amplitude no domínio do tempo filtrado com PCA, verificamos o momento onde ocorreu a maior energia e o consideramos como o centro do evento. A escolha da segunda componente se deu devido a ela ter a capacidade de representar melhor as atividades que ocorrem no ambiente, uma vez que a primeira componente representa, em maior parte, um ruído característico do sinal da magnitude do CSI no tempo [26]. Posteriormente, definimos o intervalo do evento na amostra tendo como o início 2 segundos antes desse centro do evento e o final como 2 segundos após.

Após a definição automatizada dos intervalos, cerca de 2% das amostras encontraram falsos positivos de eventos e, portanto, após a definição inicial dos intervalos,

tornou-se necessário a verificação manual, a olho nú, de cada um dos intervalos encontrados. Para esse processo, utilizamos imagens do espectrograma e do sinal da segunda componente da amplitude filtrada com PCA, o que nos possibilitou excluir os falsos positivos. Por fim, selecionamos, em cada uma das amostras, um intervalo aleatório de 4 segundos que não contém nenhuma posição dos eventos de entrada e saída. Salvamos esse intervalo para criarmos a assinatura da classe que descreve a não ocorrência de nenhum evento de entrada ou saída. Assim, cada amostra de teste conterá ao final desse processo, três intervalos, o primeiro descrevendo o evento de saída, o segundo o evento de entrada e o terceiro descrevendo a não ocorrência de nenhum evento, conforme podemos observar nas Figura 3.7(a) e 3.7(b).




Figura 3.7: Detecção dos intervalos dos eventos nas amostras de teste.

Conversão e filtragem da magnitude das amostras CSI

O CSI contém informações sobre o deslocamento da fase do sinal, entretanto, essa informação, quando obtida de dispositivos convencionais, é bastante imprecisa. Essa imprecisão ocorre devido, dentre outros fatores, a imperfeições nos componentes eletrônicos e dessincronização dos dispositivos. Esse problema, conhecido como *Carrier Frequency Offset* (CFO) [26], torna a métrica da fase não confiável para o reconhecimento de atividades humanas. Portanto, neste trabalho, utilizamos apenas a magnitude das amostras CSI, que pode ser obtida pela seguinte equação:

$$CSI_M = \sqrt{CSI_R^2 + CSI_I^2},$$

onde CSI_R representa a parte real do CSI e CSI_I a parte imaginária. As amostras CSI obtidas de dispositivos 802.11 convencionais incluem diversos tipos de ruídos devido

a, dentre outros fatores, interferência de dispositivos próximos, adaptação de potência de transmissão e sincronização imperfeita [11]. Portanto, é importante realizarmos uma filtragem no sinal obtido pela magnitude das medidas CSI de cada amostra de teste.

O processo de filtragem é realizado em três etapas: (1) Organização de cada um dos sinais das subportadoras (*streams* CSI) em uma matriz bidimensional, onde a primeira dimensão representa as medidas CSI recebidas no tempo e a segunda cada uma das *streams*; (2) Remoção da energia estática, correspondente a energia proveniente do caminho LoS em cada uma das *streams*, dada pela subtração da média da magnitude em cada uma das *streams*; e (3) Filtragem dos sinais com um algoritmo baseado em PCA [26].

Apesar de outros autores utilizarem técnicas de filtragem com filtros passa-baixo ou passa-alto, esses filtros tendem a não funcionar adequadamente na filtragem das *streams* CSI porque elas contêm informações e ruídos tanto em baixa frequência quanto em alta frequência [25]. A técnica que se mostrou mais estável para filtragem de atividades humanas em *streams* CSI foi a proposta por [26], a qual considera que as perturbações relativas ao corpo humano são correlacionadas em todas as *streams*, ou seja, quando há uma mudança na magnitude na *stream* X no tempo $t(n)$, também podemos observar uma mudança correlacionada nas demais *streams* no mesmo tempo $t(n)$. O PCA é capaz de calcular essas correlações e recombina-las, tornando possível filtrar as características relativas às perturbações causadas pelos seres humanos. A Figura 3.8 mostra uma comparação entre técnicas de filtragem, onde podemos observar que a técnica baseada em PCA resulta em um sinal bem mais limpo.

3.2.4 Extração das características dos eventos

As características utilizadas neste trabalho possuem informações extraídas diretamente de espectrogramas e também informações da segunda à sexta componente PCA, as quais nos retorna métricas diretas do domínio do tempo. A quantidade de características obtidas ao final desse processo depende do tipo de espectrograma utilizado, uma vez que um subconjunto das características depende da quantidade de janelas de frequência que o espectrograma possui na faixa de 0 até 100 Hz.

Em uma única amostra de teste de 4 segundos de duração, obtemos cerca de 179.200 medidas da magnitude do CSI por par de antenas. Dada essa quantidade de dados, é necessário extrairmos um subconjunto que torne capaz descrever os eventos desejados. A escolha das características se baseou em dois objetivos: (1) Descrever, no domínio da frequência, informações que sejam capazes de nos fornecer detalhes sobre os eventos executados nas faixas de frequência em que os eventos ocorrem; e (2) Descrever, no domínio do tempo, o padrão de energia dos movimentos humanos utilizando as




Figura 3.8: Comparativo das técnicas de filtragem da magnitude do CSI obtido por interfaces 802.11.

componentes PCA.

Para a extração das primeiras características, criamos 3 sinais que descrevem o percentual de energia do espectrograma no intervalo de tempo do evento, para os percentuais de 25, 50 e 95%. A criação desses sinais é feita extraíndo, em cada fatia de tempo (t), a frequência (f) onde a energia acumulada atinge o percentual buscado, conforme descrito pela Equação 3-1, onde $f_p(p, t)$ representa a frequência da fatia t em que o percentual p foi atingido, f_{max} representa a frequência máxima do espectrograma e $E_{(t,x)}$ representa a energia da frequência x na fatia de tempo t . Após definirmos os sinais, os redimensionamos para o tamanho de 30 pontos, usando como método de interpolação os vizinhos mais próximos. Obtendo, por fim, as primeiras 90 características.

$$f_p(p, t) = \min_{\forall f \in [1, \dots, f_{max}]} \left\{ f \left| \frac{\sum_{a=1}^f E_{(t,a)}}{\sum_{x=1}^{f_{max}} E_{(t,x)}} \geq p \right. \right\}. \quad (3-1)$$

O movimento do torso e das pernas dos indivíduos podem ser descritos, respectivamente, pelos sinais de percentual de energia de 50 e 95% [24]. Para cada valor presente nesses sinais, calculamos a velocidade de movimento utilizando a fórmula $v = f * \lambda / 2$ [25], onde f representa a frequência em Hz e λ o comprimento de onda do canal sem fio.

Como resultado, temos sinais que descrevem no tempo a velocidade de movimento do torso e das pernas do indivíduo. Para cada um desses sinais de movimento, calculamos a média, variância, valores mínimo e máximo, assimetria, curtose e entropia, resultando em mais 14 características.

As próximas características descrevem a assinatura de energia do evento no espectrograma. Para calcular essas características, dividimos o intervalo do evento em 4 partes e calculamos em cada uma delas a média da energia de cada uma das frequências de 0 até 100 Hz contidas no espectrograma. Ao utilizar o espectrograma criado com STFT, temos como resultado 132 características, em comparação ao espectrograma criado com CWT, o qual nos gera 268 características por conter um número maior de janelas de frequência. Esse conjunto de características possui uma escala muito inferior as demais e, portanto, os modelos de classificação poderiam não atribuir um peso considerável a essas características. Por esse motivo, alteramos a escala dessas características através da multiplicação dos seus valores por 200, deste modo, os valores das demais características se manterão na mesma ordem de grandeza.

Por fim, extraímos características da segunda até a sexta componente PCA. Filtramos cada componente utilizando uma CWT aplicada com *Morlet Wavelet* e depois a sua inversa (ICWT) para obtermos um sinal relativo às perturbações de 20 até 100 Hz. Dividimos cada um dos sinais em 10 partes e calculamos para cada um deles a média, variância, valores mínimo e máximo, taxa de cruzamento em zero (ZCR), assimetria, curtose, entropia, média da energia e a frequência com maior energia obtida pela FFT, resultando nas últimas 500 características do evento, sendo 100 para cada componente PCA. A Figura 3.9 mostra os vetores de características extraídos pelo processo acima descrito em cada tipo de evento, utilizando tanto um espectrograma baseado em STFT quanto um baseado em CWT.

3.2.5 Criação do modelo de classificação

Nesta subseção, descrevemos o processo de criação dos modelos de classificação capazes de diferenciarem as classes das amostras. Criamos dois tipos de modelos, um baseado em um classificador tradicional, do tipo SVM, e outro baseado em uma rede neural do tipo MLP. A seguir descrevemos o processo de criação de cada modelo.

Classificador Support Vector Machine (SVM)

Embora existam inúmeros tipos de classificadores, escolhemos utilizar um classificador SVM, configurando-o para utilizar como função *kernel* a *Radial Basis Function* (RBF). Esse tipo de classificador foi escolhido porque ele não necessita de uma grande quantidade de parâmetros e que, utilizando um *kernel* radial, podemos ter hiperplanos de




Figura 3.9: Comparativo das características extraídas em cada tipo de evento e para cada tipo de espectrograma.

separação mais flexíveis. A sua escolha também se deu por ele ser bastante utilizado na literatura.

Rede Neural Multilayer Perceptron (MLP)

A criação de uma rede neural MLP exige o ajuste de um grande conjunto de parâmetros, o que inclui função de treinamento, número de camadas, funções de ativação em cada camada e número de neurônios por camada. Apesar de existirem técnicas que fornecem alguma orientação sobre quais tipos de configurações devem ser utilizadas, não

existe uma metodologia bem definida para a escolha dessas configurações, demandando muitos testes para que obtenhamos a configuração adequada. O conjunto de combinações possíveis de configurações de uma rede neural é muito amplo, portanto, é necessário diminuirmos o escopo de configuração com base no tipo de dados de entrada.

Para melhorar o desempenho, dado o grande conjunto de configurações possíveis, utilizamos como função de treinamento a *Scaled conjugate gradient backpropagation*. Combinamos as possíveis configurações com até 2 camadas internas que variam a quantidade de neurônios por camada de 0 até 500, incrementando 50 neurônios por vez, com mínimo de 10. Também variamos as funções de ativação listadas na Tabela 3.1 em cada uma das camadas. A camada de saída foi configurada com a função de ativação *Soft Max* e, por fim, obtivemos um conjunto de 4422 configurações possíveis.

Os resultados dos testes dessas configurações são mostrados no Capítulo 4 e, conforme mostrado pelas Tabelas 4.1 e 4.2, a melhor configuração encontrada para a rede neural das características baseadas em STFT foi com primeira camada configurada com a função de ativação Radial com 100 neurônios e a segunda camada com a função de ativação Sigmoide Logatítica com 10 neurônios, utilizando apenas 25% das melhores características computadas pelo algoritmo ReliefF. Já a melhor configuração para a rede neural das características baseadas em CWT foi com a primeira camada configurada com a função de ativação Sigmoide Tangente Hiperbólica com 250 neurônios e a segunda camada com a função de ativação Sigmoide Logatítica com 50 neurônios, utilizando todas as características extraídas.

Tabela 3.1: Funções de ativação utilizadas no processo de treinamento e testes das redes neurais.

Nome da Função
Competitiva
Soft Max
Radial
Radial Normalizada
Sigmoide Logatítica
Sigmoide Tangente Hiperbólica

3.3 CSI Monitor

Nesta seção, descrevemos a ferramenta *CSI Monitor*, desenvolvida no decorrer deste trabalho com o objetivo de facilitar o processo de monitoramento das perturbações do sinal eletromagnético percebidas pelas medidas CSI com a visualização dos dados em tempo real. A ferramenta possui três componentes: (1) A interface gráfica programada diretamente no MATLAB; (2) O *CSI Device Manager Client (DMC)*, um componente

desenvolvido em Python e que é executado em conjunto à interface gráfica, realizando a sua integração com o componente que se comunica diretamente com os dispositivos de rede sem fio; e (3) O *CSI Device Manager (DM)*, um componente desenvolvido em C e que é executado dentro dos dispositivos de rede sem fio, coletando e armazenando as amostras CSI recebidas e oferecendo uma interface de comunicação para controlar o dispositivo e fazer o *download* das amostras CSI. A Figura 3.10 mostra os componentes do *CSI Monitor* e o seu ciclo de funcionamento. A ferramenta está disponível para *download* e uso da comunidade acadêmica [1]. A seguir, descrevemos cada um dos componentes do *CSI Monitor* em maior nível de detalhamento.

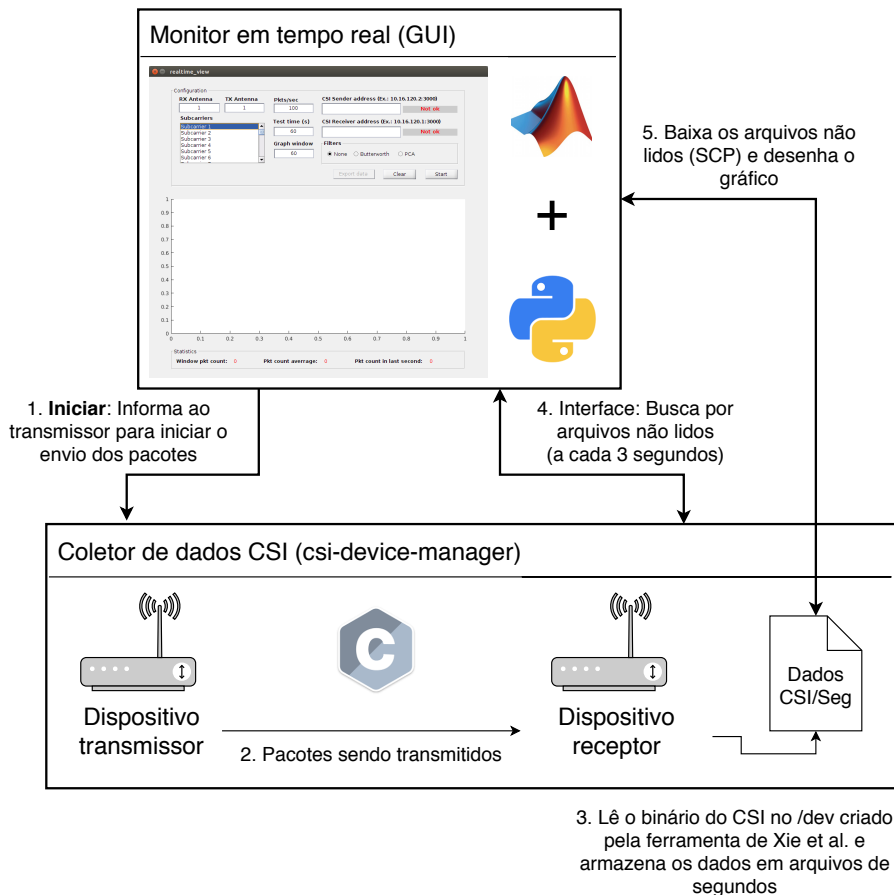


Figura 3.10: Arquitetura e Funcionamento do *CSI Monitor*.

3.3.1 Interface Gráfica

A interface gráfica do *CSI Monitor* possui como objetivo mostrar as alterações na magnitude do CSI em tempo real, possibilitando monitorar as perturbações ocorridas no ambiente. Para a realização do teste, o usuário pode configurar o par de antenas que deseja monitorar, a taxa de transmissão de pacotes, o tempo que o teste será executado e a janela de tempo do gráfico. A taxa de transmissão escolhida pelo usuário está diretamente relacionada a quantidade de amostras CSI que serão recebidas a cada segundo, uma

vez que o CSI é calculado para cada pacote recebido pela interface de rede. Após configurar os parâmetros desejados, o usuário precisa apenas informar o endereço, no padrão *<IP:Porta>*, onde o DM dos dispositivos transmissor e receptor estão sendo executados.

Com tudo configurado, o usuário deve clicar no botão *start* e, nesse momento, a interface iniciará o DMC, que irá se comunicar com o DM dos dispositivos e iniciará a execução do teste e a coleta dos arquivos de dados das amostras CSI de cada segundo. Com o teste iniciado, a interface irá requisitar a cada três segundos os arquivos de amostras CSI disponíveis e não lidos para o DMC e, posteriormente, irá lê-los, extrair a magnitude de cada amostra, realizar a filtragem escolhida, atualizar o gráfico e armazenar os dados brutos das amostras para que o usuário possa salva-los. A escolha dos três segundos para a atualização se dá devido à aplicação MATLAB não possuir suporte a múltiplas *threads* e, portanto, é necessária a configuração de um tempo que possibilite que todo o processamento seja realizado antes de buscar mais arquivos.

Caso o usuário deseje parar o teste no meio da sua execução, basta clicar no botão *stop* que é liberado quando um teste está sendo executado. Para extrair os dados do experimento o usuário precisa clicar no botão *export data* após a execução do teste.

A interface também oferece um conjunto de funcionalidades como: (1) Filtrar o sinal produzido no tempo com as magnitudes CSI utilizando a técnica baseada em PCA e ou em filtro passa-baixo de *Butterworth*; e (2) Monitorar uma subportadora específica. A Figura 3.11 mostra a interface gráfica e as suas opções.

3.3.2 CSI Device Manager Client

A necessidade do DMC se deu devido ao MATLAB não possuir suporte a múltiplas *threads*. Como é necessário se conectar com o servidor *socket* do DM de cada um dos dispositivos, foi necessário desenvolver um componente intermediário, para fazer esse interfaceamento entre a interface e os DM's. Esse componente foi desenvolvido em Python e é executado na mesma máquina e em conjunto à interface gráfica, sendo iniciado por ela. Apesar da interface apenas consultar os arquivos disponíveis a cada 3 segundos, o DMC coleta a cada segundo o arquivo do DM receptor, deixando-os sempre disponível para a interface gráfica. A coleta dos arquivos é realizada via SCP para o dispositivo de rede onde o DM receptor está instalado.

3.3.3 CSI Device Manager

O DM é o componente localizado em cada dispositivo de rede sem fio e que, lê o arquivo de dispositivo de hardware do CSI e salva as amostras recebidas a cada segundo em arquivos separados. Ele também oferece uma interface de comunicação via




Figura 3.11: Interface gráfica do CSI Monitor.

servidor *socket* que possibilita fazer com que o dispositivo inicie ou pare uma transmissão de pacotes na rede à uma taxa específica. Ele também possibilita a busca dos arquivos de amostras CSI disponíveis para que sejam coletados pelo DMC e, posteriormente, mostrados a interface gráfica.

3.4 Conclusão

Neste capítulo, propusemos a criação de um sistema, conhecido como WiD-Move, que é capaz de identificar os fluxos de movimentos em um ambiente fechado, distinguindo se o movimento foi realizado para entrar ou sair do ambiente. Apresentamos toda a metodologia executada, desde o processo de configuração do ambiente e coleta das amostras de dados até a criação e calibração do modelo de classificação. Por fim, apresentamos o CSI Monitor, uma ferramenta desenvolvida para monitorar, em tempo real, as perturbações do sinal eletromagnético reportadas pelo CSI entre dois dispositivos de rede 802.11n. No próximo capítulo, apresentamos a avaliação de desempenho e os resultados do sistema proposto.

Avaliação do Sistema

Este capítulo apresenta uma avaliação do WiDMove, um sistema de detecção de fluxos de movimento que usa a informação das perturbações causadas no espectro sem fio do 802.11. A avaliação é realizada através de testes de acurácia e comparação das técnicas propostas utilizando amostras de eventos reais coletadas em laboratório. Adicionalmente, avaliamos o impacto das características escolhidas na acurácia dos modelos e, por fim, avaliamos o impacto da quantidade de amostras por classe de evento necessárias na etapa de treinamento dos modelos.

4.1 Descrição do experimento

No ambiente de experimentação, utilizamos dois computadores com processadores Intel Core i7, 8GB de RAM, Sistema Operacional Ubuntu 14.04 LTS e interfaces de rede sem fio 802.11abgn *Atheros AR9830*. O *driver* e as ferramentas de extração do CSI foram instalados em ambos os computadores, conforme especificado pelos desenvolvedores [27]. Os computadores foram posicionados nas extremidades da entrada do laboratório, conforme mostrado na figura 3.3(b). Por fim, estabelecemos uma rede entre os dispositivos no modo infraestruturado, utilizando um canal da faixa de frequência de 5 GHz e com largura de banda de 20 MHz.

Coletamos as amostras CSI de 8 indivíduos, dentre eles, 7 do sexo masculino e 1 do sexo feminino, com idades que variam entre 19 e 27 anos. Cada amostra de teste contém duas assinaturas, uma do indivíduo saindo e outra do indivíduo entrando no ambiente. Após o processo de coleta, obtemos um total de 264 amostras que, após a extração dos intervalos, resultou num total de 792 intervalos de eventos que representam as classes de eventos de entrada, saída e nenhum evento. Para cada um dos intervalos, computamos dois tipos de assinaturas, o primeiro utilizando o espectrograma baseado em STFT e o segundo baseado em CWT. Essas assinaturas estão disponíveis para toda a comunidade acadêmica [4].

Treinamos modelos de classificação baseados em um classificador SVM e em redes neurais do tipo MLP para cada tipo de assinatura. A escolha do conjunto de



configurações para a criação das redes neurais, no que diz respeito às funções de ativação, foi baseado nas implementações disponíveis na versão 2017a do MATLAB que melhor se encaixaram no tipo de dados do nosso vetor de características. Nas próximas seções, apresentamos os resultados dos experimentos realizados com os modelos treinados.

4.2 Avaliação de desempenho dos modelos

Nesta seção, apresentamos os resultados obtidos através da computação da acurácia dos modelos treinados, conforme especificado anteriormente. Como a quantidade de características utilizadas em classificadores e redes neurais podem impactar na acurácia dos modelos, iniciamos a avaliação de desempenho do sistema computando o peso das características incluídas em cada tipo de assinatura utilizando o algoritmo ReliefF. Posteriormente, ordenamos cada uma das características incluídas em todas as assinaturas de modo que as mais relevantes ficassem no início e as menos relevantes no final. A Figura 4.1 mostra o peso das características de ambos tipos de assinaturas computados pelo ReliefF.

Após termos as assinaturas dos eventos com suas características ordenadas pelo seu peso, iniciamos o processo de treinamento e computação das acurácias dos modelos. Para cada tipo de modelo proposto no Capítulo 3, treinamos um subconjunto de modelos que utiliza quantias variadas das características, ordenadas do maior para o menor nível de relevância em para cada tipo de assinatura. No caso dos modelos baseados em classificadores SVM, realizamos os testes através de técnicas de validação cruzada, utilizando as técnicas *Leave-One-Out* e *K-Fold*, onde o último utiliza $K = 10$. Os resultados obtidos são apresentados pela Figura 4.2 e demonstram que: (1) A acurácia máxima obtida pelos classificadores de assinaturas STFT foi de cerca de 91,5% quando utilizado 25% das características mais relevantes; (2) Quando utilizado mais de 25% das características das assinaturas STFT, os classificadores não conseguem distinguir as amostras da classe onde não há movimento humano, o que degrada a acurácia média desses classificadores para cerca de 65%; (3) A acurácia máxima obtida pelos classificadores de assinaturas CWT foi de cerca de 94% quando utilizado entre 85% e 100% das características mais relevantes; e (4) Os classificadores baseados em assinaturas CWT conseguiram distinguir 100% das amostras sem movimento quando utilizado mais de 65% das características. Os resultados apresentados utilizam um intervalo de confiança (IC) de 95%.

Em relação a avaliação dos modelos baseados em redes neurais, não foram utilizadas as técnicas *K-Fold* e *Leave-One-Out*, uma vez que, principalmente no caso da *Leave-One-Out*, produziria um conjunto excessivo casos de testes, superando a marca de 70 milhões. Assim, validamos esses modelos seguindo o seguinte processo: (1) Para

(a) *Peso das características da assinatura baseada em STFT.*(b) *Peso das características da assinatura baseada em CWT.***Figura 4.1:** *Peso das características atribuídos pelo algoritmo ReliefF.*

cada configuração de rede neural, criamos 21 subconjuntos variando o percentual de características mais relevantes de 1 até 100%, incrementando de 5 em 5%; (2) Para cada subconjunto separamos aleatoriamente todas as assinaturas que serão utilizadas, dado o tipo de assinatura que será testado, em amostras de treinamento e amostras de testes, onde 40 (15%) das amostras de cada classe de evento foram separadas para testes, aleatoriamente definidas em cada execução; (3) Treinamos o modelo com as respectivas amostras e computamos a acurácia por cada tipo de classe; (4) Repetimos os passos (2) e (3) por 30 vezes; e (5) computamos a média da acurácia das 30 execuções, resultando na média final para cada subconjunto de modelos de cada uma das configurações possíveis das redes neurais. Esse processo é realizado para cada um dos tipos de assinaturas.

Por se tratarem de um grande conjunto de resultados, composto por $N_{conf} * N_{rp}$, onde N_{conf} representa o número de configurações possíveis propostas no Capítulo 3 e N_{rp} representa o tamanho do conjunto de percentuais de características mais relevantes,




Figura 4.2: Acurácia média dos classificadores SVM por tipo de assinatura e quantidade de características mais relevantes (IC de 95%).

se torna inviável apresentarmos em detalhes todos os resultados obtidos neste trabalho. Portanto, focamos em apresentar os resultados das cinco configurações que resultaram nas melhores acurácias de cada tipo de assinatura. As Tabelas 4.1 e 4.2 apresentam essas cinco configurações que apresentaram os melhores resultados em cada tipo de assinatura, onde podemos observar que a acurácia média mais alta obtida para os modelos de assinaturas STFT foi de 88.35%. Já em relação aos modelos baseados em CWT, podemos observar que a média mais alta foi de cerca de 93%. A Figura 4.3 apresenta os resultados da configuração de rede que apresentou as melhores acurácias, conforme destacado nas Tabelas 4.1 e 4.2.

Como observado, os resultados das médias das redes neurais são menos estáveis do que os obtidos pelos modelos baseados no classificador SVM. Entretanto, apesar da

Tabela 4.1: Acurácia média (%) das cinco configurações por percentual de características mais relevantes extraídas com o espectrograma baseado em STFT que produziram melhores resultados.

	radbas (100) logsig (10)	radbas (300) radbas (10)	tansig (100) radbas (10)	tansig (300) radbas (50)	tansig (300) tansig (10)
1%	69.83	67.58	70.58	69.58	69.50
5%	78.92	79.58	79.58	78.67	78.25
10%	83.42	81.75	80.83	80.83	81.17
15%	84.83	84.58	84.42	83.83	84
20%	8º 87.08	6º 87.58	7º 87.25	4º 87.75	5º 87.75
25%	1º 88.33	9º 87.08	2º 87.83	10º 85.67	3º 87.83
30%	64.17	63.33	56.17	63.50	61.08
35%	62.83	62.33	62.17	63.50	60
40%	61.25	64	64.67	61.67	62.25
45%	65.42	61.67	63.75	61.08	58.17
50%	56.75	63.67	56.33	58	60.25
55%	65	64.42	58.75	63.08	57.83
60%	61.92	63.67	63.17	62.50	54.42
65%	61.33	62.75	62.75	61.42	55.67
70%	62.67	62.08	62.92	62.75	60.17
75%	62.92	60.17	60.50	62.25	57.42
80%	60.83	62.08	55.50	63.67	59.92
85%	58	64.83	61	62.75	62.67
90%	65.08	64.17	61.58	61.75	56.75
95%	60.75	59.33	62.33	62.42	52.75
100%	63.33	60.83	59.08	61.58	61.42
Média	67.84	67.97	66.72	67.53	65.2

acurácia média ser pouco inferior às do SVM, obtivemos redes neurais que apresentaram resultados significativamente superiores, tornando esse tipo de modelo bastante viável para a instanciação de sistema de produção. As Tabelas 4.3, 4.4, 4.5 e 4.6 representam as matrizes de confusão dos modelos baseados em classificadores SVM e dos melhores modelos obtidos utilizando as redes neurais. É possível observar pelas tabelas que, apesar da acurácia média das redes neurais serem inferiores, os melhores modelos chegaram a 96,6% pras assinaturas baseadas em STFT e 97,1% pras assinaturas baseadas em CWT. A Figura 4.4 mostra as curvas de Característica de Operação do Receptor (ROC) dos modelos com melhores resultados apresentados anteriormente, exibindo o desempenho de cada um dos modelos e seus respectivos limiares de discriminação.

Tabela 4.2: Acurácia média (%) das cinco configurações por percentual de características mais relevantes extraídas com o espectrograma baseado em CWT que produziram melhores resultados.

	radbas (400) logsig (10)	tansig (100) radbas (50)	tansig (250) logsig (50)	tansig (250) radbas (10)	tansig (400) logsig (50)
1%	69.08	67.08	65.58	67.58	65.58
5%	77	78.08	74.58	78	78.50
10%	83.25	83.67	86.58	84.50	81.42
15%	84.83	83.42	83.83	84.83	86.50
20%	85.58	85.58	88.67	85.83	82.67
25%	86.33	88.75	86.92	86.83	85
30%	86.25	88.92	88.83	86.50	85.08
35%	88.17	88.83	90.25	87.92	84
40%	87.92	88.50	86.83	88.33	88.83
45%	89.83	89.42	90.67	85.17	90.67
50%	89.75	90	9 ^o 91.58	90.75	10 ^o 91.42
55%	89.58	90.83	90.08	86.75	87.67
60%	90.50	91.25	4 ^o 92.75	89.83	89.50
65%	90.83	89.25	87.08	89.67	89.83
70%	91.08	90.50	91.83	90.67	88.92
75%	90.92	86.75	1 ^o 92.92	90.08	88.08
80%	7 ^o 91.83	90.42	2 ^o 92.92	90.08	8 ^o 91.67
85%	88.17	88.67	86.25	89.17	6 ^o 92
90%	89.17	89.50	3 ^o 92.92	90	90.75
95%	90	90.58	88.67	90.33	90.42
100%	90.92	90.58	5 ^o 92.08	89.17	11 ^o 91.42
Média	87.19	87.17	87.70	86.76	86.66

4.2.1 Impacto da quantidade de amostras utilizadas na fase de treino

Um dos desafios da área de reconhecimento de padrões é definir a quantidade mínima de amostras por classe que uma rede neural ou classificador necessita em sua fase de treinamento para atingir uma acurácia estável. Neste trabalho, realizamos essa avaliação através de um experimento realizado nas seguintes etapas: (1) Separamos, aleatoriamente, 40 amostras por classe de evento que serão utilizadas na etapa de testes; (2) Separamos subconjuntos das amostras remanescentes, de forma aleatória, que forneçam um total de 1% até 100% das amostras por classe, variando de 5% em 5%; (3) Treinamos os modelos que apresentaram as melhores acurácias, conforme apontado na seção anterior, com cada subconjunto de amostras separados na etapa anterior; (4) Realizamos os testes com as amostras separadas na etapa (1); e (5) Repetimos esse processo por 30 vezes e computamos a média dos resultados obtidos.

Após a realização dos experimentos, obtivemos os resultados mostrados nas

Tabela 4.3: Matriz de confusão do classificador SVM com 25% das características mais relevantes baseadas em STFT.

	Entrada	Saída	Nenhum	
Entrada	90,16%	15,53%	0,37%	106,06%
Saída	9,84%	84,47%	0%	94,31%
Nenhum	0%	0%	99,63%	99,63%
	100%	100%	100%	

Tabela 4.4: Matriz de confusão do classificador SVM com todas as características baseadas em CWT.


	Entrada	Saída	Nenhum	
Entrada	89,02%	10,61%	0%	99,63%
Saída	9,47%	89,02%	0%	98,49%
Nenhum	1,51%	0,37%	100%	101,88%
	100%	100%	100%	

Tabela 4.5: Matriz de confusão da Rede Neural radbas(100) logsig(10) com 25% das características mais relevantes baseadas em STFT.

	Entrada	Saída	Nenhum	
Entrada	93,18%	3,4%	0%	96,58%
Saída	6,82%	96,6%	0%	103,42%
Nenhum	0%	0%	100%	100%
	100%	100%	100%	

Tabela 4.6: Matriz de confusão da Rede Neural tansig(250) logsig(50) com 55% das características mais relevantes baseadas em CWT.

	Entrada	Saída	Nenhum	
Entrada	93,94%	1,89%	0%	95,83%
Saída	5,69%	98,11%	0,75%	104,55%
Nenhum	0,37%	0%	99,25%	99,62%
	100%	100%	100%	



(a) Acurácia média das redes neurais pela configuração *radbas* (100) + *logsig* (10) dada a quantidade de características mais relevantes das assinaturas baseadas em STFT.

(b) Acurácia média das redes neurais pela configuração *tansig* (250) + *logsig* (50) dada a quantidade de características mais relevantes das assinaturas baseadas em CWT.

Figura 4.3: Acurácia média das redes neurais que utilizam a configuração que obteve o melhor resultado dada a quantidade de características mais relevantes (IC de 95%).

Figuras 4.5 e 4.6. Para os modelos de assinaturas baseadas em STFT, apresentamos dois resultados, dado que eles não apresentam uma boa acurácia na classe sem movimento quando utilizado mais que 25% das características mais relevantes. Conforme podemos observar, os modelos baseados em SVM apresentam uma acurácia superior a 85% quando treinados com pelo menos cerca de 100 amostras por evento em quaisquer tipos de assinaturas. Já com cerca de 200 amostras por classe, os modelos de assinaturas STFT chegam até cerca de 90% de acurácia, enquanto os de assinatura CWT chegam até cerca de 93%, que são valores bem próximos das melhores acurácias apresentadas na seção anterior.

Por fim, observamos que os modelos baseados em redes neurais necessitaram de uma quantia maior de amostras por classe para convergirem para os melhores resultados, de modo que, com cerca de 100 amostras por classe eles atingiram apenas cerca de 80% de acurácia em ambos tipos de assinatura. Entretanto, quando utilizamos cerca de 200 amostras por classe, os modelos também produziram resultados similares aos máximos apresentados anteriormente.


4.3 Conclusão

Neste capítulo, fornecemos uma avaliação do WiDMove realizada através de testes com amostras reais de eventos de movimento de entrada e saída gerados por seres humanos. Avaliamos a acurácia produzida pelos tipos de assinaturas extraídos com as duas técnicas de espectrogramas descritas no capítulo anterior para dois tipos de


modelos, um baseado em um classificador SVM e outro baseado em redes neurais MLP. Apresentamos um comparativo desses modelos com o objetivo de identificar qual deles é o mais adequado para a implementação da proposta e, por fim, avaliamos a qualidade das características extraídas em cada tipo de assinatura e o a quantidade de amostras necessárias na etapa de treinamento dos modelos.

Ao final dos experimentos, percebemos que, apesar das assinaturas criadas com o espectrograma STFT resultarem em uma acurácia próxima, na predição de intervalos onde ocorrem os eventos de entrada e saída, elas não apresentam uma acurácia aceitável na predição de intervalos onde não ocorre nenhum evento, tornando extremamente baixa a acurácia média dos modelos produzidos com essas assinaturas. Por outro lado, os modelos criados utilizando as assinaturas baseadas em CWT resultaram em uma acurácia superior tanto na predição dos intervalos onde há eventos quanto na predição dos intervalos sem eventos, podendo chegar em até cerca de 93% de acurácia média.

Em relação aos experimentos comparativos entre os tipos de modelos, percebemos que os resultados médios dos melhores modelos criados com as redes neurais foram pouco inferiores aos dos modelos baseados em classificador SVM, entretanto, houveram modelos de redes neurais que chegaram a uma acurácia superior a 97%, o que torna o uso desse tipo de modelo bastante viável. Do ponto de vista dos experimentos sobre a quantidade de amostras necessárias na etapa de treino, percebemos que para o classificador SVM, cerca de 100 amostras por classe já produzem uma acurácia superior a 85%, entretanto, para as redes neurais, são necessárias mais de 150 amostras por classe para produzirem resultados similares. Por fim, percebemos que cerca de 25% das características mais relevantes, computadas pelo algoritmo ReliefF, já são capazes de produzirem um dos melhores resultados dos modelos, ou seja, essas características poderiam apresentar o melhor *trade-off* para a criação de sistemas desse tipo. No próximo capítulo, apresentamos as considerações finais do trabalho e discutimos perspectivas para a sua continuidade. Além disso, listamos os produtos gerados no decorrer do desenvolvimento deste trabalho.




(a) Curva ROC do classificador SVM com 25% das características mais relevantes baseadas em STFT. (b) Curva ROC do classificador SVM com todas as características baseadas em CWT.




(c) Curva ROC da Rede Neural radbas(100) log-sig(10) com 25% das características mais relevantes baseadas em STFT. (d) Curva ROC da Rede Neural tansig(250) log-sig(50) com 55% das características mais relevantes baseadas em CWT.

Figura 4.4: Curvas ROC dos melhores modelos obtidos.




(a) Acurácia dos classificadores com 25% das melhores características da assinatura baseada em STFT dada quantia de amostras usadas no treinamento.

(b) Acurácia dos classificadores com todas as características da assinatura baseada em STFT dada quantia de amostras usadas no treinamento.




(c) Acurácia dos classificadores com todas as características da assinatura baseada em CWT dada quantia de amostras usadas no treinamento.

Figura 4.5: Acurácia média dos classificadores SVM dado o tipo de assinatura e quantidade de amostras usadas no treinamento (IC de 95%).



(a) Acurácia das redes neurais com 25% das melhores características da assinatura baseada em STFT dada quantia de amostras usadas no treinamento.

(b) Acurácia das redes neurais com todas as características da assinatura baseada em STFT dada quantia de amostras usadas no treinamento.



(c) Acurácia das redes neurais com todas as características da assinatura baseada em CWT dada quantia de amostras usadas no treinamento.

Figura 4.6: Acurácia média das redes neurais treinadas com a configuração que obteve as melhores resultados de acordo com o tipo de assinatura e a variação da quantidade de amostras usadas no treinamento (IC de 95%).

Conclusão & Trabalhos Futuros

O monitoramento de fluxos de movimento exige, normalmente, a aquisição e implantação de diversos sensores dedicados que sejam capazes de computar e entregar essa informação. Por outro lado, dispositivos de rede 802.11 já estão amplamente disponíveis nos mais variados ambientes e são capazes de entregar essa informação sem nenhum custo ou equipamento adicional, o que os torna potenciais sensores de atividades para a nova era de ambientes inteligentes.

Nesta dissertação, propusemos o WiDMove, um sistema que transforma os dispositivos 802.11n em sensores capazes de monitorar os fluxos de movimento de um ambiente, detectando, por exemplo, quando um indivíduo entra ou sai desse ambiente. O WiDMove utiliza como entrada as medidas coletadas pelo mecanismo de monitoramento do espectro do canal sem fio, conhecido como *Channel State Information* (CSI), que nos fornece métricas sobre as perturbações que ocorreram no sinal eletromagnético dos dispositivos 802.11n durante a sua transmissão. Apresentamos também uma ferramenta, denominada CSI Monitor, que coleta e exibe, em tempo real, as amostras CSI coletadas de um par de dispositivos 802.11, auxiliando os pesquisadores dessa área no processo de coleta e análise dos dados.

Seguindo a metodologia descrita, coletamos amostras de 8 indivíduos distintos, sendo 7 do sexo masculino e 1 do sexo feminino, enquanto entravam e saíam de um ambiente de experimentação. De posse das amostras de dados, instanciamos os modelos propostos com os dados reais coletados.

Avaliamos os resultados dos modelos e comparamos quais as técnicas produziram melhores resultados para a implementação de um serviço real do WiDMove. Essa avaliação foi realizada através de técnicas de validação cruzada e média de acurácia de 30 experimentos aleatórios. Após a coleta dos resultados, pudemos observar que as assinaturas criadas com espectrogramas baseados em CWT resultam em melhores resultados se comparados às criadas com espectrogramas baseados em STFT. Observamos também que os modelos baseados em classificadores SVM resultaram em uma acurácia média de cerca de 93%. Essa acurácia foi superior se comparada a acurácia média de 92% dos modelos baseados em redes neurais do tipo MLP. Entretanto, dada a forma de funcionamento

das redes neurais, conseguimos criar redes que atingiram uma acurácia de cerca de 97%, tornando extremamente viável a utilização desse tipo de modelo na implantação desse sistema.

Por fim, realizamos testes que demonstraram que cerca de 100 amostras por classe de evento já são suficientes para treinar modelos que sejam capazes de atingir uma acurácia superior a 85%.

5.1 Produção científica

Além do texto desta dissertação, as pesquisas desenvolvidas neste trabalho produziram os seguintes produtos:

- **Artigo:** WiDMove-um sensor de movimento direcional baseado em perturbações do sinal eletromagnético de interfaces 802.11 [9].
Evento: Simpósio Brasileiro de Redes de Computadores (SBRC 2018) - Campos do Jordão, São Paulo, Brasil. Maio de 2018.
Modalidade: Evento nacional. Apresentação de artigo completo.
Situação: Publicado e apresentado.
- **Artigo:** WiDMove: Sensing Movement Direction using IEEE 802.11n Interfaces [8].
Evento: Canadian Conference on Electrical and Computer Engineering (CCECE) - Quebec, Canadá. Maio de 2018.
Modalidade: Evento internacional. Apresentação de artigo completo.
Situação: Publicado e apresentado.
- **Software:** CSI Monitor [1].
Descrição: Software de coleta e monitoramento das medidas produzidas pelo CSI em tempo real.
Linguagem: MATLAB, Python e C.
Situação: Publicado e disponível para a comunidade acadêmica.
- **Dataset:** Assinaturas dos eventos de entrada e saída de ambiente produzidos pelas perturbações do movimento humano no espectro sem fio, detectados pelo CSI [4].
Extensão: .mat (MATLAB).
Situação: Publicado e disponível para a comunidade acadêmica.

5.2 Perspectivas para trabalhos futuros

No decorrer desta pesquisa, identificamos alguns tópicos que não foram abordados neste trabalho e que possuem potencial para serem investigados. A seguir, apresentamos uma breve discussão sobre esses potenciais tópicos de trabalhos futuros.

- **Avaliação do sistema com um número maior de indivíduos distintos e, consequentemente, um número maior de amostras.** Como pudemos observar nos resultados, quanto mais amostras utilizamos na etapa de treinamento do modelo, maior foi a acurácia que obtivemos. Portanto, um aspecto importante de se estudar seria qual o limite de amostras em que a acurácia se estabiliza, ou seja, não possui aumento, ou se ela pode decair caso tenhamos amostras de outros perfis de indivíduos.
- **Avaliação do funcionamento do sistema em outros ambientes.** É importante validar se o sistema proposto mantém a sua acurácia caso utilizado em outros ambientes, pois, caso negativo, devemos buscar soluções para tornar as assinaturas robustas às alterações de ambiente.
- **Avaliação do funcionamento do sistema com mais de um indivíduo passando ao mesmo tempo ou com intervalos bem próximos entre os dispositivos.** Como as amostras são compostas de intervalos de 4 segundos e, a perturbação normalmente não dura esse intervalo inteiro, é importante avaliar se o modelo de classificação é impactado quando temos perturbações seguidas nas janelas de 4 segundos ou até mesmo evoluir o sistema para que ele consiga distinguir quando há mais de um indivíduo presente em uma amostra de evento.
- **Avaliação do desempenho do sistema com objetos estranhos passando entre os dispositivos ou com pessoas portando objetos estranhos.** Algo bastante comum é pessoas entrarem em ambientes portando objetos, tais como mochilas e notebooks. Uma avaliação importante é ser feita se o sistema é robusto o suficiente para não ser impactado quando um indivíduo está realizando o evento portando algum objeto estranho ou até mesmo se outro objeto, e não um corpo humano, gera falsos positivos no sistema.
- **Avaliação do funcionamento do sistema com antenas omni-direcionais.** Um dos aspectos que influenciam negativamente a implantação do sistema é o uso de antenas direcionais, devido a atuarem como hardwares especiais que não são inclusos normalmente nos ambientes de uso do sistema. Uma avaliação importante a ser feita é se o sistema funciona sem o uso dessas antenas especiais e, se negativo, qual o impacto e as alterações que devem ser realizadas para que o sistema funcione com antenas omni-direcionais.

- **Avaliação do uso de taxas de amostragem menores que 800 pps.** O uso de uma taxa de amostragem tão alta pode vir a degradar o funcionamento da rede sem fio e, por isso, um potencial trabalho futuro é o estudo da viabilidade do funcionamento do sistema com taxas de amostragem menores, uma vez que os pacotes de controle da rede não nos informa o CSI.
- **Identificação de qual indivíduo está realizando o evento de entrar ou sair do ambiente.** Existem trabalhos na literatura que identificam pessoas baseado nas perturbações obtidas nas amostras CSI [28, 18]. Entretanto, esses trabalhos analisam cenários mais simples ou não possuem uma acurácia muito alta a medida que o número de indivíduos distintos presentes no modelo treinado aumenta. Uma evolução natural deste trabalho é evoluir o sistema para tentar identificar qual indivíduo realizou o evento de entrada ou saída do ambiente.

Referências Bibliográficas

- [1] **Csi monitor.** <https://github.com/brunosoaresds/csi-monitor>. Último acesso: 01-Agosto-2018.
- [2] **hostapd: ieee 802.11 ap, ieee 802.1x/wpa/wpa2/eap/radius authenticator.** <https://w1.fi/hostapd/>. Último acesso: 14-Junho-2018.
- [3] **Linux wpa/wpa2/ieee 802.1x supplicant.** https://w1.fi/wpa_supplicant/. Último acesso: 14-Junho-2018.
- [4] **Widmove - dataset of csi samples including entry/exit human walking movement.** <https://brunosoaresds.github.io/widmove/>. Último acesso: 01-Agosto-2018.
- [5] BOULIC, R.; RENAULT, O. **3d hierarchies for animation.** In: Magnenat-Thalmann, N.; Thalmann, D., editors, *New Trends in Animation and Visualization*. John Wiley & Sons Ltd., 1991.
- [6] BROWN, T. G. **The intrinsic factors in the act of progression in the mammal.** *Proceedings of the Royal Society of London. Series B, containing papers of a biological character*, 84(572):308–319, 1911.
- [7] CROW, B. P.; WIDJAJA, I.; KIM, J. G.; SAKAI, P. T. **ieee 802.11 wireless local area networks.** *IEEE Communications Magazine*, 35(9):116–126, Sept 1997.
- [8] DA SILVA, B. S.; LAUREANO, G. T.; ABDALLAH, A. S.; CARDOSO, K. V. **Widmove: Sensing movement direction using ieee 802.11n interfaces.** In: *2018 IEEE Canadian Conference on Electrical Computer Engineering (CCECE)*, p. 1–4, May 2018.
- [9] DA SILVA, B. S.; LAUREANO, G. T.; CARDOSO, K. V. **Widmove-um sensor de movimento direcional baseado em perturbações do sinal eletromagnético de interfaces 802.11.** In: *Simpósio Brasileiro de Redes de Computadores (SBRC)*, volume 36, 2018.

- [10] DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. John Wiley & Sons, 2012.
- [11] GJENGSET, J.; XIONG, J.; MCPHILLIPS, G.; JAMIESON, K. **Phaser: Enabling phased array signal processing on commodity wifi access points**. In: *Proceedings of the 20th annual international conference on Mobile computing and networking*, p. 153–164. ACM, 2014.
- [12] HALPERIN, D.; HU, W.; SHETH, A.; WETHERALL, D. **Two antennas are better than one: A measurement study of 802.11n**. *Unpublished technical report, University of Washington*, 2009.
- [13] HALPERIN, D.; HU, W.; SHETH, A.; WETHERALL, D. **802.11 with multiple antennas for dummies**. *SIGCOMM Comput. Commun. Rev.*, 40(1):19–25, Jan. 2010.
- [14] HALPERIN, D.; HU, W.; SHETH, A.; WETHERALL, D. **Tool release: Gathering 802.11n traces with channel state information**. *ACM SIGCOMM CCR*, 41(1):53, Jan. 2011.
- [15] IEEE. **IEEE standard for telecommunications and information exchange between systems - lan/man specific requirements - part 11: Wireless medium access control (mac) and physical layer (phy) specifications: High speed physical layer in the 5 ghz band**. *IEEE Std 802.11a-1999*, p. 1–102, Dec 1999.
- [16] IEEE. **IEEE standard for information technology– local and metropolitan area networks– specific requirements– part 11: Wireless lan medium access control (mac) and physical layer (phy) specifications amendment 5: Enhancements for higher throughput**. *IEEE Std 802.11n-2009*, p. 1–565, Oct 2009.
- [17] KNUTH, D. E. **The T_EX Book**. Addison-Wesley, 15th edition, 1984.
- [18] LI, Y.; ZHU, T. **Using wi-fi signals to characterize human gait for identification and activity monitoring**. In: *Connected Health: Applications, Systems and Engineering Technologies (CHASE), 2016 IEEE First International Conference on*, p. 238–247. IEEE, 2016.
- [19] LITWIN, L.; PUGEL, M. **The principles of ofdm**, Jan. 2001.
- [20] LIU, J.; WANG, Y.; CHEN, Y.; YANG, J.; CHEN, X.; CHENG, J. **Tracking vital signs during sleep leveraging off-the-shelf wifi**. In: *Proceedings of the 16th ACM International Symposium on Mobile Ad Hoc Networking and Computing, MobiHoc '15*, p. 267–276, New York, NY, USA, 2015. ACM.

- [21] PROAKIS, J. G.; SALEHI, M.; ZHOU, N.; LI, X. **Communication systems engineering**, volume 2. Prentice Hall New Jersey, 1994.
- [22] RANIWALA, A.; CKER CHIUUEH, T. **Architecture and algorithms for an ieee 802.11-based multi-channel wireless mesh network**. In: *Proceedings IEEE 24th Annual Joint Conference of the IEEE Computer and Communications Societies.*, volume 3, p. 2223–2234 vol. 3, March 2005.
- [23] SMITH, A.; JONES, B. **On the complexity of computing**. In: Smith-Jones, A. B., editor, *Advances in Computer Science*, p. 555–566. Publishing Press, 1999.
- [24] VAN DORP, P.; GROEN, F. **Feature-based human motion parameter estimation with radar**. *IET Radar, Sonar & Navigation*, 2(2):135–145, 2008.
- [25] WANG, W.; LIU, A. X.; SHAHZAD, M. **Gait recognition using wifi signals**. In: *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, p. 363–373. ACM, 2016.
- [26] WANG, W.; LIU, A. X.; SHAHZAD, M.; LING, K.; LU, S. **Understanding and modeling of wifi signal based human activity recognition**. In: *Proceedings of the 21st annual international conference on mobile computing and networking*, p. 65–76. ACM, 2015.
- [27] XIE, Y.; LI, Z.; LI, M. **Precise power delay profiling with commodity wifi**. In: *Proceedings of the 21st Annual International Conference on Mobile Computing and Networking, MobiCom '15*, p. 53–64, New York, NY, USA, 2015. ACM.
- [28] ZHANG, J.; WEI, B.; HU, W.; KANHERE, S. S. **Wifi-id: Human identification using wifi signal**. In: *Distributed Computing in Sensor Systems (DCOSS), 2016 International Conference on*, p. 75–82. IEEE, 2016.