

# WiDMove - um sensor de movimento direcional baseado em perturbações do sinal eletromagnético de interfaces 802.11

Bruno Soares da Silva<sup>1</sup>, Gustavo Teodoro Laureano<sup>1</sup>, Kleber Vieira Cardoso<sup>1</sup>

<sup>1</sup>Instituto de Informática – Universidade Federal de Goiás (UFG) –  
Goiânia – GO – Brazil

{brunodasilva, gustavo, kleber}@inf.ufg.br

**Abstract.** *The accurate detection of people in indoor environments requires high-cost devices, while low-cost devices, in addition to low accuracy, offers little information about the monitored events. The perturbations that can affect the electromagnetic signals used by 802.11 interfaces make this type of device a low-cost sensor; widely available, and enoughly accurate for several applications. In this work, we propose the WiDMove, a proposal to detect the entry and exit of people indoors using channel quality measurements (known as Channel State Information - CSI) offered by the IEEE 802.11n standard. Our proposal is based on signal processing and machine learning 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) and Short-Time Fourier Transform (STFT). We trained a Support Vector Machine (SVM) classifier and validated it with cross-validation, using the K-Fold and Leave-One-Out techniques. WiDMove presented that can reach an average accuracy above 85%.*

**Resumo.** *A detecção acurada de indivíduos em ambientes fechados demanda dispositivos de alto custo, enquanto dispositivos de baixo custo, além da baixa acurácia, oferecem poucas informações sobre os eventos monitorados. As perturbações que podem afetar o sinal eletromagnético utilizado por interfaces de rede 802.11 tornam esse tipo de dispositivo um sensor de baixo custo, amplamente disponível e com acurácia satisfatória para várias aplicações. Neste trabalho, apresentamos o WiDMove, uma proposta para detecção da entrada e saída de pessoas em ambientes fechados utilizando 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 sinal e de aprendizado de máquina, as quais nos permitem extrair e classificar assinaturas de eventos usando as medidas CSI. Em testes de laboratório com interfaces 802.11 convencionais, coletamos medidas CSI influenciadas por 8 pessoas distintas e extraímos as assinaturas de entrada e saída utilizando, dentre outras técnicas, Principal Component Analysis (PCA) e Short-Time Fourier Transform (STFT). Treinamos um classificador do tipo Support Vector Machine (SVM) e o validamos com validação cruzada, utilizando as técnicas K-Fold e Leave-One-Out. Os testes demonstraram que o WiDMove pode atingir a uma acurácia média superior a 85%.*

## 1. Introdução

Ambientes inteligentes demandam dispositivos ou sensores capazes de entregar informações detalhadas sobre os eventos que ocorrem no ambiente, principalmente quando falamos de eventos que são realizados por interações humanas. Sensores de movimento capazes de detectar a direcionalidade do movimento possuem custo elevado, enquanto sensores similares e de baixo custo não são capazes de obter esse tipo de informação.

Interfaces de redes 802.11a podem operar na faixa de frequência de 5 GHz [IEEE 1999], o que significa que o seu sinal pode sofrer interferência de objetos com tamanho superior a cerca de 6 cm com maior facilidade [Proakis et al. 1994]. Somando esse fator com o fato de que o corpo humano é composto basicamente de água, o que o torna um ótimo refletor de sinais eletromagnéticos, podemos dizer que os sinais transmitidos por interfaces de rede 802.11 sofrem com facilidade perturbações de corpos humanos, tornando esse tipo de dispositivo um ótimo sensor de atividades humanas.

Com a chegada do padrão *IEEE 802.11n* foi definido um mecanismo de monitoramento do canal das interfaces 802.11, conhecido como *Channel State Information (CSI)*. Esse mecanismo é capaz de estimar as alterações sofridas pelo sinal eletromagnético, tanto na amplitude quanto na fase, durante 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 de atividades humanas utilizando esse tipo de tecnologia.

Trabalhos como os desenvolvidos por [Li and Zhu 2016] e [Wang et al. 2015] utilizam as informações do monitoramento do canal sem fio para detectar e identificar atividades humanas, entretanto, eles apenas identificam atividades de assinaturas bastante distintas. Também é possível encontrar trabalhos na literatura que utilizam Rádios Definidos por Software (SDRs), os quais conseguem monitorar o sinal eletromagnético com maior detalhamento, mas que possuem um custo de aquisição elevado.

Neste trabalho, propomos o WiDMove, uma proposta capaz de tornar interfaces de rede 802.11 convencionais e de baixo custo, em sensores de movimento capazes de identificar o andar de seres humanos e ainda saber se o indivíduo está entrando ou saindo do ambiente. O WiDMove foi implementado e testado em ambiente de laboratório utilizando amostras reais de eventos emitidos por 8 pessoas distintas. Outra contribuição do trabalho é a proposta de uma técnica de identificação do intervalo dos eventos baseada em um espectrograma, a qual consegue detectar com maior acurácia a ocorrência de uma atividade humana.

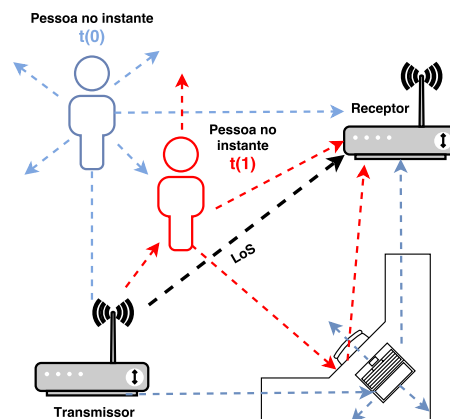
O trabalho está dividido em mais 5 seções. Na Seção 2 introduzimos os conceitos mais relevantes para o entendimento do trabalho. Na Seção 3 apresentamos os trabalhos relacionados encontrados na literatura. Na Seção 4 apresentamos a proposta do WiDMove. Na Seção 5 apresentamos detalhes dos experimentos e avaliações realizadas durante o trabalho, juntamente com a exposição dos resultados. Por fim, a Seção 6 sintetiza as contribuições e apresenta os trabalhos futuros.

## 2. Fundamentação teórica

### 2.1. Channel State Information (CSI)

Definido dentro do padrão 802.11n, o 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 até que esse chegue no receptor [IEEE 2009]. Esse mecanismo foi definido com o objetivo de auxiliar os dispositivos de rede 802.11 a se adaptarem às condições de transmissão do ambiente. Entretanto, as informações fornecidas passaram a ser utilizadas para os mais variados propósitos, uma vez que elas são capazes de descrever com uma boa precisão, as atividades que ocorrem no ambiente.

Os corpos humanos, por serem compostos basicamente de água, são ótimos refletores de sinais eletromagnéticos. Como as medidas CSI descrevem as alterações ocorridas na amplitude e na fase do sinal durante a sua transmissão, as atividades realizadas pelos corpos humanos podem facilmente ser observadas nas medidas CSI. Quando um ambiente permanece sem mudanças, ou seja, não há movimento, os valores do CSI tendem a permanecer relativamente constantes. Entretanto, quando há movimentação nesse ambiente, os valores tendem a flutuar devido ao efeito de multipercurso que ocorrerá no sinal eletromagnético, assim como observado na figura 1, onde no instante  $t(0)$  o sinal é transportado pelos percursos diferentes do instante  $t(1)$ , o que resulta em medidas CSI diferentes.



**Figura 1. Exemplo do efeito de multipercurso quando uma pessoa caminha por um ambiente.**

Redes 802.11 utilizam modulação OFDM [IEEE 1999] e, portanto, as medidas CSI incluem a descrição das alterações no sinal ocorridas em cada uma das subportadora do canal. Uma medida CSI possui dimensão  $N_{Tx} \times N_{Rx} \times N_{Sub}$ , onde  $N_{Tx}$  e  $N_{Rx}$  representam respectivamente o número de antenas dos dispositivos transmissor e receptor e  $N_{Sub}$  o número de subportadoras existentes e reportadas pelo CSI do dispositivo de 802.11 receptor. As medidas CSI são geradas para cada pacote recebido pelo receptor e que esteja de acordo com determinadas condições, dentre elas, ser transmitido utilizando uma taxa High-Throughput (HT) [IEEE 2009].

### 2.2. Reconhecimento de padrões do 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.

A área de reconhecimento de padrões oferece um conjunto de técnicas que permite a diferenciação dos padrões de interferência capturados pelo CSI. A classificação de padrões consiste em treinar um modelo matemático capaz de distinguir entre duas ou mais classes de dados com base em suas características [Duda et al. 2012]. Por outro lado, a medida do CSI no tempo oferece uma grande quantidade de informações, o que dificulta o treinamento do modelo de classificação. Neste trabalho, a extração de características é obtida pelo processamento do sinal de CSI com o objetivo de reduzir a alta dimensionalidade dos dados e selecionar as características mais representativas para a diferenciação dos eventos de entrada e saída de indivíduos. A seguir, estão listadas as principais técnicas aplicadas no trabalho.

- **Principal Component Analysis (PCA):** É uma técnica estatística amplamente usada em seleção de características que 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.
- **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.
- **Short-Time Fourier Transform (STFT):** É usada para avaliar a variação temporal do espectro de frequências de um sinal. Ela consiste na 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.
- **Validação cruzada com K-Fold:** Técnica utilizada para validar classificadores que divide o conjunto de amostras em K partes distribuídas aleatoriamente e realiza K testes, cada um excluindo uma das partes da fase de treino e utilizando-a para predição. Por fim, calcula-se a acurácia média das K execuções.
- **Validação cruzada com Leave-One-Out:** Variação da técnica K-Fold que utiliza K igual ao número total de amostras, fazendo com que cada execução exclua do treino e faça a predição de apenas uma única amostra.

### 3. 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 and Zhu 2016] propuseram o *Hoble*, 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 multipercursos [Van Dorp and Groen 2008]. 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 desses *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. 2015] propuseram o *CARM*, 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. 2016] propuseram um sistema capaz de reconhecer indivíduos através do seu andar pela linha de visão (LoS) entre transmissor e receptor de uma rede 802.11. 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, o WiDMove detecta e identifica, dentro de uma mesma atividade (andar), a sua direcionalidade. 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 WiDMove utiliza 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 SDRs, torna a solução muito mais barata e acessível.

#### **4. Proposta: WiDMove**

Nesta Seção descrevemos a proposta do WiDMove. Inicialmente, realizamos a configuração do ambiente. Em seguida, coletamos as medidas CSI dos dispositivos de rede 802.11 de baixo custo. Posteriormente realizamos o pré-processamento dessas medidas e criamos um espectrograma do sinal pré-processado. O espectrograma é então utilizado de entrada, em conjunto com as medidas CSI no domínio do tempo, para a extração das características relativas aos eventos de entrada e saída. Por fim, realizamos o treinamento de um classificador utilizando as características obtidas e o validamos. A seguir, detalhamos cada uma das etapas da proposta.

##### **4.1. Configuração do ambiente**

Sinais eletromagnéticos são suscetíveis à interferências como absorção, reflexão e refração. Objetos com tamanho superior ao comprimento de onda do sinal eletromagnético causam interferência a esse sinal com maior facilidade. O comprimento de onda do sinal eletromagnético é dado pela equação  $\lambda = c/f$ , onde  $c$  representa a velocidade da luz e  $f$  a frequência do canal em Hz. Em redes 802.11a/g/n, temos canais em frequências de 2.4 Ghz e 5 Ghz, ou seja, canais onde o sinal possui comprimento de onda de aproximadamente 12 e 6 cm respectivamente.

Por ser tão sensível, desenvolver propostas que sejam capazes de manter a acurácia em ambientes que sofrem muitas alterações é uma tarefa bastante difícil. Portanto, com o objetivo de minimizarmos o impacto das mudanças do ambiente, além de ruídos de fontes indesejadas, é importante posicionarmos os dispositivos de rede em locais estratégicos. O WiDMove possui como objetivo identificar quando um indivíduo entrou ou saiu do ambiente, portanto, posicionamos os dispositivos nas extremidades da porta do ambiente. Quando um indivíduo passar pela porta, seja entrando ou saindo, ele vai causar a maior perturbação possível no sinal, devido a obstrução da LoS, tornando a assinatura do evento mais fácil de ser identificada [Zhang et al. 2016]. Ainda com o objetivo de minimizar as perturbações de fontes indesejadas, utilizamos um par de antenas direcionais nos dispositivos de rede.

Por se tratar de uma medida que foi inicialmente desenvolvida para auxiliar os dispositivos de rede sem fio a realizarem ajustes finos na configuração da rede, o CSI não é reportado para o *Kernel* do sistema operacional de forma nativa. Entretanto, existem modificações nos *drivers* de alguns modelos de dispositivos de rede da *Atheros* e da *Intel* que tornam possível a extração dessa informação [Halperin et al. 2011, Xie et al. 2015]. Os desenvolvedores desses *drivers* também disponibilizaram ferramentas para envio de pacotes e coleta do CSI. Para termos acesso às medidas CSI, é necessário realizar a instalação dessas ferramentas.

#### 4.2. Coleta as amostras de dados

Nesta etapa realizamos a coleta das medidas CSI que serão utilizadas para definirmos quando há um evento de entrada ou saída no ambiente. Atividades realizadas pelo corpo humano normalmente são ocorrem à uma frequência de até 300 Hz [Wang et al. 2015]. Gerando medidas CSI a uma taxa de amostragem superior a 300 Hz, conseguimos capturar as perturbações causadas pelo corpo humano enquanto este está se movimentando em um ambiente. Configuramos o transmissor para transmitir pacotes à uma taxa de 800 pps, portanto, ao final de cada segundo, obtemos uma matriz de medidas CSI correspondente às dimensões  $800 \times N_{Tx} \times N_{Rx} \times N_{Sub}$ . Cada um dos elementos da matriz alinhados no tempo corresponde a uma *stream* CSI. Desse modo, temos  $N = N_{Tx} * N_{Rx} * N_{Sub}$  *streams* CSI de tamanho  $800 * N_{Secs}$ , onde  $N_{Secs}$  representa o número de segundos da amostra de dados.

Devido ao *Carrier Frequency Offset* (CFO), a informação do deslocamento da fase, inclusa nas medidas CSI, não possui uma boa precisão, portanto, essa informação não é confiável para detecção de movimentos de atividades humanas. Neste trabalho utilizamos apenas a amplitude obtida pelas *streams* CSI [Wang et al. 2015].

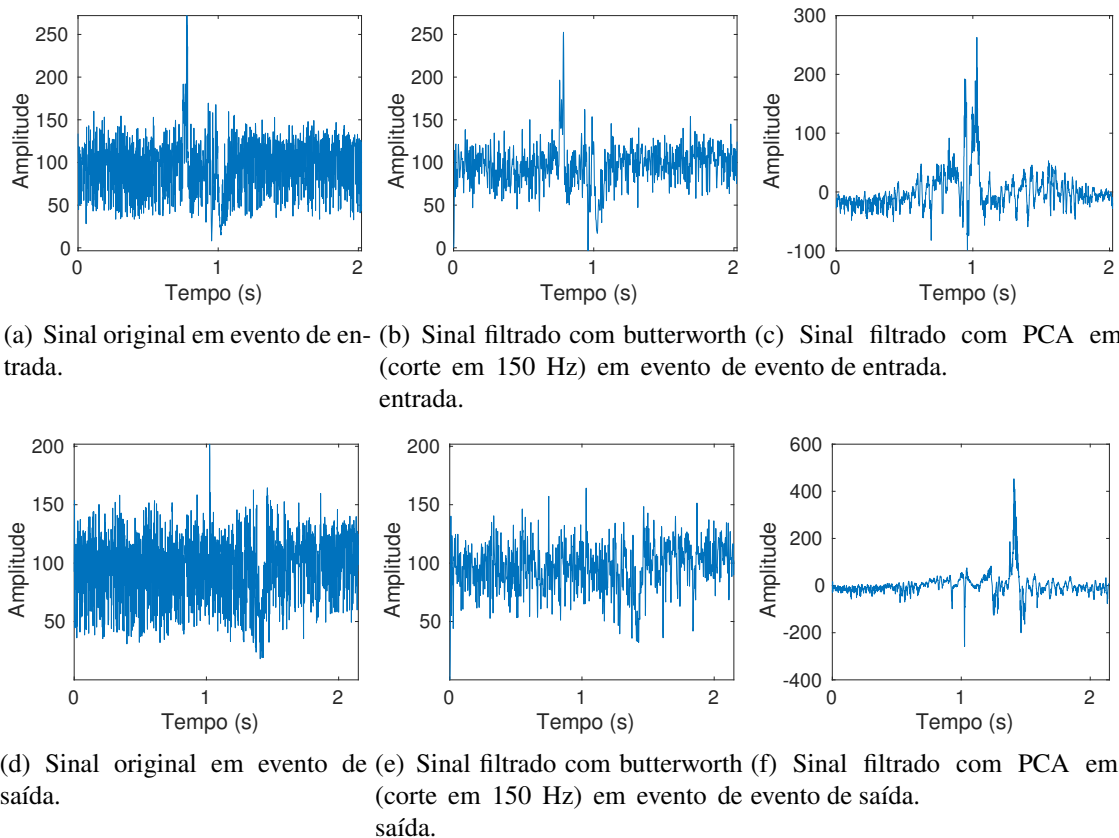
#### 4.3. Pré-processamento dos dados

As medidas CSI obtidas através de dispositivos 802.11 convencionais que são vendidos comercialmente incluem em suas amostras diversos tipos de ruídos devido a, dentre outros fatores, interferência de dispositivos próximos, adaptação de potência de transmissão e sincronização imperfeita [Gjengset et al. 2014]. Por esse fator, torna-se necessário filtrar os sinais obtidos pelas *streams* CSI antes de utiliza-los na extração de características.

Para realizar a filtragem, iniciamos organizando cada uma das *streams* CSI em uma matriz bidimensional de tamanho  $(800 * N_{Secs}) \times (N_{Tx} * N_{Rx} * N_{Sub})$ , onde a primeira dimensão representa o número de medidas CSI recebidas no tempo e a segunda

cada uma das *streams*. Posteriormente removemos a energia estática correspondente a energia proveniente do caminho LoS em cada uma das *streams*. Essa remoção é realizada subtraindo das *streams* a média calculada de um conjunto de medidas CSI equivalente a 4 segundos.

Técnicas existentes que utilizam filtros passa-baixo tendem a não funcionar bem na filtragem das *streams* CSI devido a elas conterem impulsos de alta frequência, além de também conterem ruídos em baixa frequência [Wang et al. 2016]. Uma técnica de filtragem das *streams* CSI baseada em PCA foi proposta por [Wang et al. 2015] com o objetivo de resolver esse problema. A técnica é baseada no princípio de que as perturbações relativas ao corpo humano são correlacionadas nas *streams* CSI, ou seja, quando há um aumento na amplitude proveniente desse tipo de perturbação na *stream*  $X$  no tempo  $t(n)$ , também podemos observar um aumento 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 2 mostra uma comparação entre as técnicas de filtragem.



**Figura 2. Comparativo das técnicas de filtragem do ruído do sinal obtido por interfaces 802.11.**

Ao final dessa etapa temos uma matriz de tamanho  $(N_{Tx} * N_{Rx} * N_{Sub}) \times (800 * N_{Secs})$ , onde a primeira dimensão corresponde as componentes PCA ordenadas da maior para a menor representatividade dos dados e a segunda corresponde aos valores das componentes descritas no tempo.

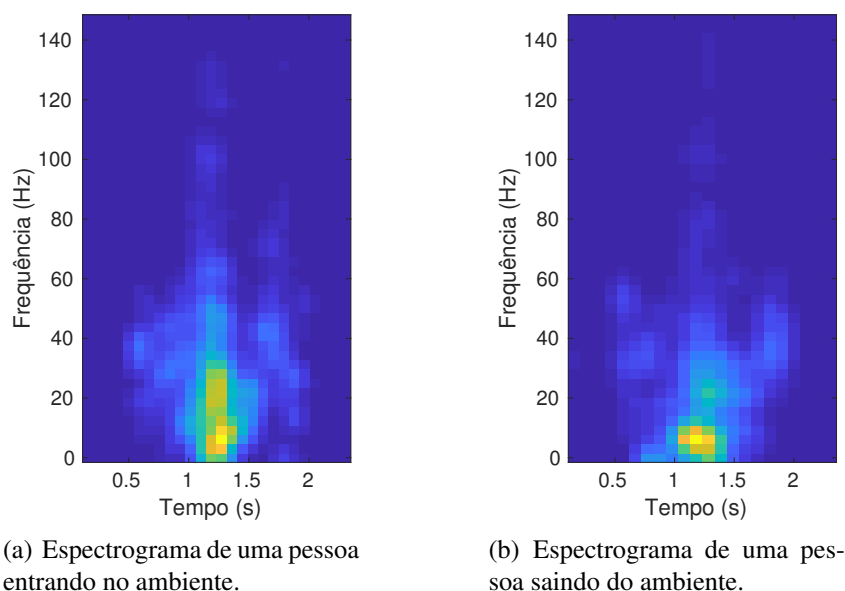
#### 4.4. Criação do espectrograma

Apesar de conseguir representar a variação do espectro de frequências e, consequentemente, os eventos de entrada e saída de um ambiente, a criação de um espectrograma utilizando as componentes PCA é uma tarefa desafiadora, uma vez que várias das componentes PCA possuem tanto informações do evento quanto de ruído. [Wang et al. 2016] propôs uma técnica para a criação desse tipo de espectrograma, a qual utilizamos como base para o desenvolvimento da nossa, que descrevemos a seguir.

Como entrada utilizamos as 20 componentes PCA de maior relevância. Para cada uma das componentes calculamos a STFT utilizando como parâmetro a janela de 256 amostras e 155 amostras sobrepostas, onde, para uma taxa e amostragem de 800 pps, nos proporciona um nível de detalhamento de 3,12 Hz e 0,12 segundos por janela.

Após o cálculo das STFTs, cada uma delas passa por um processo de otimização, o qual é realizado em cinco etapas: (1) Zerar as energias das frequências acima de 146 Hz. (2) Buscar os quadros de tempo cujo a 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).

O espectrograma final é obtido através da soma das energias das 20 STFTs tratadas. A figura 3 mostra os espectrogramas obtidos quando uma pessoa entra e sai de um ambiente.



**Figura 3. Espectrograma dos eventos de entrada e saída de um ambiente.**

#### 4.5. Detecção dos eventos de entrada e saída

A identificação dos intervalos contidos nas amostras das medidas CSI onde os indivíduos estão causando uma perturbação relativa a um evento de entrada ou saída é uma tarefa extremamente importante, pois é nesse intervalo que podemos extrair as características



que irão compor a assinatura do evento. Caso esse intervalo não seja identificado com precisão, é possível que a assinatura do evento seja influenciada de tal modo que a acurácia do sistema seja afetada.

Técnicas que estimam esses intervalos utilizando a variância da amplitude em intervalos curtos possuem uma baixa eficácia, uma vez que, mesmo após filtrado, os sinais obtidos tanto pelas *streams* CSI quanto pelas componentes PCA, possuem perfis de variância diferentes para cada tipo de ambiente [Zhang et al. 2016, Gjengset et al. 2014], tornando extremamente difícil a definição de um perfil de variância capaz de descrever as atividades humanas em quaisquer cenários.

Nesse trabalho propomos uma técnica de identificação do início e do fim de um evento baseado no espectrograma produzido pela Seção 4.4. Além de ser eficaz contra alterações do ambiente, essa técnica também possibilita filtrar os eventos pelos níveis de energia em determinadas frequências onde os eventos causam maior impacto.


Eventos de entrada e saída são compostos principalmente pelo deslocamento do torso humano, o que ocorre normalmente a uma velocidade média de 1 ms. A equação que descreve a frequência onde um movimento de determinada velocidade pode ser encontrado no espectrograma é dada por  $f = 2 * v / \lambda$  [Wang et al. 2016]. Considerando um canal na frequência de 5 Ghz, com comprimento de onda de 5.95 cm, podemos observar que a perturbação relativa ao deslocamento do torso de um indivíduo que se desloca a uma velocidade de 1 ms está descrita por volta da frequência de 33 Hz. Por esse motivo, utilizamos a faixa de frequência do espectrograma de 20 até 50 Hz na identificação do início e do fim dos eventos de entrada e saída.

Para definirmos os intervalos dos eventos em uma amostra de dados, buscamos inicialmente todos os intervalos com duração mínima de 1,2 segundos e que possuam energia em todas suas fatias. Posteriormente, verificamos para cada intervalo obtido se a soma das suas energias normalizada pela divisão da média da energia de todos os intervalos é maior que um valor heurístico obtido através de testes. Caso o intervalo esteja de acordo com essa definição, ele é considerado um intervalo de evento de entrada ou saída. A figura 4 mostra um sinal de longa duração filtrado com PCA e o espectrograma desse sinal na faixa de 20 até 50 Hz contendo os intervalos dos eventos extraídos.

#### 4.6. Extração de características

Nesta Seção descrevemos como extrair as 737 características que irão compor a assinatura dos eventos de entrada e saída.

A primeira característica extraída é a duração do evento em segundos. Posteriormente, criamos 3 sinais que descrevem o percentual de energia do espectrograma no intervalo de tempo do evento, utilizando os percentuais de 25, 50 e 95%. A criação desses sinais é feita extraindo, em cada fatia de tempo, a frequência onde a energia acumulada atinge o percentual buscado, conforme descrito pela equação 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  $t$ . Realizamos o redimensionamento de cada um dos sinais obtido para o tamanho de 30 pontos, usando como método de interpolação os vizinhos mais próximos. Como resultado, temos 90 características.



(a) Sinal de longa duração filtrado com PCA incluindo eventos de entrada e saída.

(b) Espectrograma de longa duração incluindo eventos de entrada e saída reconhecidos no sinal.

**Figura 4. Exemplo da técnica de detecção dos eventos de entrada e saída.**

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

O movimento do torso e das pernas dos indivíduos podem ser descritos pelos sinais de percentual de energia de 50 e 95% respectivamente [Van Dorp and Groen 2008]. Para cada valor presente nesses sinais, calculamos a velocidade de movimento utilizando a fórmula  $v = f * \lambda/2$  [Wang et al. 2016]. 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. 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 contidas no espectrograma de 0 até 100 Hz, resultando em 132 características.

Por fim, extraímos características da segunda até a sexta componente PCA, a qual descrevem melhor as perturbações relativas as atividades humanas [Wang et al. 2015]. Filtramos cada uma componente utilizando *Continuous Wavelet Transform* (CWT) aplicada com *Morlet Wavelet* e depois a sua inversa (ICWT) para obtermos um sinal relativo às perturbações de 20 até 80 Hz. Em cada um dos cinco sinais obtidos, realizamos a sua divisão em 10 partes e calculamos 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.

#### 4.7. Criação do classificador

Por não necessitar uma grande quantidade de parametrização, além de ser um classificador robusto e bastante utilizado na literatura, utilizamos um classificador do tipo *Support Vector Machine* (SVM) configurado com *Radial Basis Function* (RBF) como função *kernel* para criar o modelo capaz de classificar os eventos de entrada e saída.


## 5. Avaliação de desempenho

Nesta Seção descrevemos os experimentos, a validação e a avaliação de desempenho do WiDMove. Nas próximas seções, detalhamos como o experimento foi conduzido e os seus resultados. Posteriormente apresentamos a avaliação sobre o impacto da quantidade de características do classificador e, por fim, apresentamos uma avaliação sobre a quantidade de amostras necessárias na etapa de treino para que o classificador possua uma boa acurácia.

### 5.1. Descrição do experimento

Configuramos o ambiente de experimentação em um laboratório utilizando dois computadores com processador Intel Core I7, 8GB de RAM e sistema operacional Ubuntu 14.04 LTS. Equipamos ambos computadores com interfaces de rede 802.11 *Atheros ath9k AR9380*, a qual possui suporte ao padrão 802.11n e, portanto, ao CSI. O *driver* e as ferramentas de extração do CSI foram instalados em ambos os computadores, conforme especificado pelos desenvolvedores [Xie et al. 2015].

Os computadores foram posicionados nas extremidades da porta do laboratório, conforme mostrado pela figura 5. Por fim, estabelecemos a rede no modo infraestruturado, utilizando um canal da faixa de frequência de 5 GHz e com largura de banda de 20 MHz.



**Figura 5. Configuração do ambiente de testes e posicionamento dos dispositivos de rede.**

Realizamos os testes com 8 indivíduos, sendo 7 do sexo masculino e 1 do sexo feminino, com idades entre 19 e 27 anos. Coletamos um total de 304 amostras para cada evento de entrada e saída, onde os indivíduos foram orientados a andarem normalmente durante a coleta das amostras. As amostras serão disponibilizadas para a comunidade acadêmica através de requisições.

Criamos um classificador do tipo SVM e o validamos as técnicas de validação cruzada *Leave-One-Out* e *K-Fold*, configurado com  $K = 10$ . Os resultados demonstram que o WiDMove é capaz de atingir uma acurácia superior a 85%, conforme mostrado pela figura 7, que utiliza nível de significância (NS) de 95%.

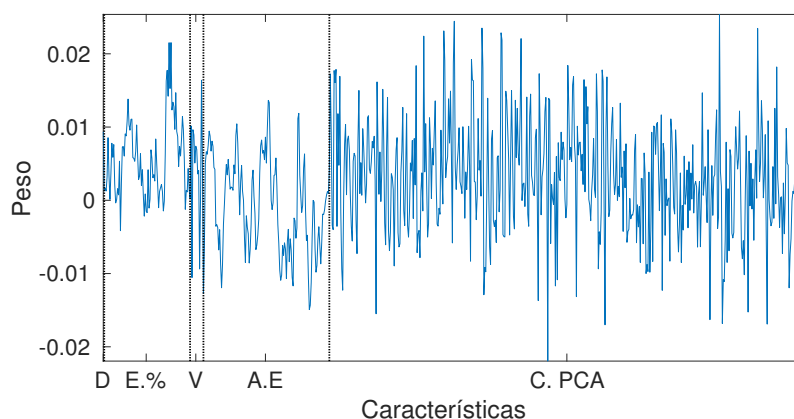
A tabela 1 mostra as contagens de TP, TN, FP e FN da média de 50 testes executados com um classificador treinado com 279 amostras escolhidas aleatoriamente e contendo todas as 737 características. Conforme esperado, de acordo com a figura 8, a acurácia média do apresentada pelo WiDMove para esse classificador foi de aproximadamente 86%.

**Tabela 1. Contagens de Verdadeiro/Falso Positivo e Verdadeiro/Falso Negativo da média de 50 experimentos aleatórios utilizando um classificador que inclui 100% das características e treinado com 279 das amostras por classe.**

	+	-	
+	<b>86,3%</b>	14.8%	101,1%
-	13.7%	<b>85,2%</b>	98.9%
	100%	100%	

## 5.2. Impacto da quantidade de características

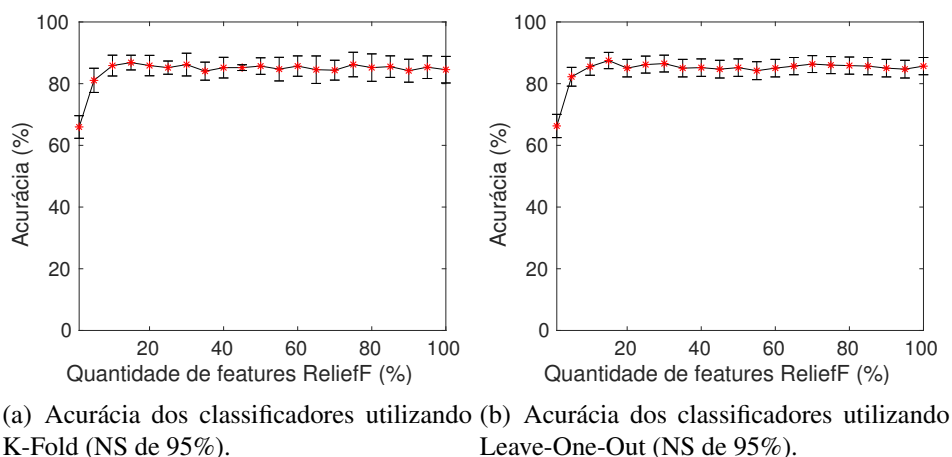
A quantidade de características de um classificador causa impacto tanto no desempenho, quanto em sua acurácia, uma vez que uma característica pode, além de definir a classe correta, confundir o classificador. Calculamos o *ranking* das características que melhor definem as classes de entrada e saída utilizando o algoritmo de seleção de características ReliefF. A figura 6 mostra o peso de cada uma das características utilizadas pelo WiDMove. Posteriormente, criamos classificadores que utilizam apenas parte dessas características, ordenadas pela maior relevância, e os validamos com as técnicas *Leave-One-Out* e *K-Fold* utilizando  $K = 10$ . Os resultados mostram que o uso de todas as características não degrada significativamente a acurácia da proposta, e que, utilizando cerca de 15% das características mais relevantes, conseguimos atingir uma acurácia próxima a 87%, conforme mostrado pela figura 7.




**Figura 6. Peso das características atribuídos pelo algoritmo ReliefF.**

## 5.3. Impacto da quantidade de amostras utilizadas na fase de treino

Um dos desafios da área de reconhecimento de padrões, mais especificamente sobre problemas de classificação, é definir a quantidade de amostras mínima por classe que um classificador necessita em sua etapa de treinamento para que este consiga prever as classes de novos elementos com uma boa acurácia. Avaliamos esse impacto através de um experimento onde separamos 25 amostras por classe de forma aleatória para utilização na fase de testes e, posteriormente, treinamos diversos classificadores variando a quantidade das amostras remanescentes na fase de treinamento. Por fim, calculamos a acurácia de cada um dos classificadores na predição das 50 amostras inicialmente separadas. O teste foi realizado 50 vezes e a média dos resultados é apresentada pela figura 8, que indica que os classificadores que foram treinados com pelo menos 150 amostras já são capazes de oferecerem uma acurácia superior a 80%.



**Figura 7. Avaliação da acurácia dos classificadores dado o número de características utilizadas.**



**Figura 8. Impacto da quantidade de amostras na fase de treino de um classificador que utiliza 100% das características (NS de 95%).**

## 6. Conclusão

Aplicações para ambientes inteligentes possuem uma demanda de informações detalhadas sobre os eventos que ocorrem nos ambientes monitorados. Sensores capazes de obter um maior nível de detalhamento sobre os eventos monitorados possuem, normalmente, um custo elevado. Interfaces de rede 802.11n por outro lado, são capazes de monitorar as atividades realizadas por seres humanos através das perturbações ocorridas nos sinais eletromagnéticos, o que torna esse tipo de dispositivo um sensor de baixo custo capaz de obter informações detalhadas sobre os eventos que ocorrem no ambiente. Neste trabalho, propomos o WiDMove, uma proposta que combina técnicas de processamento de sinais e aprendizado de máquina e torna interfaces de rede 802.11 sensores de movimento capazes de informar quando uma pessoa está entrando ou saindo de um ambiente. Diferente de outras propostas que utilizam as medidas CSI para monitorar atividades humanas, o WiDMove consegue diferenciar, dentro da atividade do andar, a sua direcionalidade com uma acurácia superior a 85%. Também propomos uma técnica de detecção de atividades baseada em um espectrograma, o que permite que as atividades humanas sejam identificadas observando não mais apenas o nível de variância no tempo, mas sim o nível de energia de uma determinada faixa de frequência em um intervalo de tempo.

Trabalhos futuros incluem realizar testes em ambientes diferentes do laboratório para validar se o modelo é resistente a mudança de ambiente, aumentar o número de amostras com pessoas distintas com o objetivo de avaliar se a acurácia se mantém mesmo em um grupo grande de indivíduos distintos e realizar testes com mais de um indivíduo passando ao mesmo tempo e/ou com objetos estranhos.

## Agradecimentos

Este trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG) e pela Rede Nacional de Ensino e Pesquisa (RNP).

## Referências

- Duda, R. O., Hart, P. E., and Stork, D. G. (2012). *Pattern classification*. John Wiley & Sons.
- Gjengset, J., Xiong, J., McPhillips, G., and Jamieson, K. (2014). Phaser: Enabling phased array signal processing on commodity wifi access points. In *Proceedings of the 20th annual international conference on Mobile computing and networking*, pages 153–164. ACM.
- Halperin, D., Hu, W., Sheth, A., and Wetherall, D. (2011). Tool release: Gathering 802.11n traces with channel state information. *ACM SIGCOMM CCR*, 41(1):53.
- IEEE (1999). 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*, pages 1–102.
- IEEE (2009). 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*, pages 1–565.
- Li, Y. and Zhu, T. (2016). 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*, pages 238–247. IEEE.
- Proakis, J. G., Salehi, M., Zhou, N., and Li, X. (1994). *Communication systems engineering*, volume 2. Prentice Hall New Jersey.
- Van Dorp, P. and Groen, F. (2008). Feature-based human motion parameter estimation with radar. *IET Radar, Sonar & Navigation*, 2(2):135–145.
- Wang, W., Liu, A. X., and Shahzad, M. (2016). Gait recognition using wifi signals. In *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pages 363–373. ACM.
- Wang, W., Liu, A. X., Shahzad, M., Ling, K., and Lu, S. (2015). Understanding and modeling of wifi signal based human activity recognition. In *Proceedings of the 21st annual international conference on mobile computing and networking*, pages 65–76. ACM.
- Xie, Y., Li, Z., and Li, M. (2015). Precise power delay profiling with commodity wifi. In *Proceedings of the 21st Annual International Conference on Mobile Computing and Networking, MobiCom '15*, pages 53–64, New York, NY, USA. ACM.
- Zhang, J., Wei, B., Hu, W., and Kanhere, S. S. (2016). Wifi-id: Human identification using wifi signal. In *Distributed Computing in Sensor Systems (DCOSS), 2016 International Conference on*, pages 75–82. IEEE.