

# Classificação de Atividades Humanas com Redes Neurais Artificiais com Processamento Temporal

Janderson Lira, Marcos Wenneton, Matheus Soares,  
Nicolí Araújo, Rodrigo Moraes, Elloá B. Guedes

<sup>1</sup>Núcleo de Computação  
Escola Superior de Tecnologia  
Universidade do Estado do Amazonas  
Av. Darcy Vargas, 1200 – Manaus – Amazonas

{jnl, mwvda, massi, npda, rcm}.eng@uea.edu.br, ebgcosta@uea.edu.br

**Abstract.** *This work aims at investigating the adoption of neural networks with temporal processing to detect the type of activity developed by different subjects in an uncontrolled environment using data from accelerometer and gyroscope located in their upperarm and forearm. The results reported in the literature describe an accuracy of 75% for neural networks in this scenario. Aiming at designing neural networks more suited for this task, time delay neural networks were considered and their resulting average accuracy was equal to 86%. The models obtained can collaborate in the development of solutions to wearable devices, for example, encouraging users to become more active.*

**Resumo.** *Este trabalho visa investigar a adoção de redes neurais com processamento temporal para detecção do tipo de atividade desenvolvida por diferentes sujeitos em ambiente não-controlado a partir de dados do acelerômetro e giroscópio localizados no braço e antebraço. Os resultados reportados pela literatura revelam uma acurácia de 75% para as redes neurais neste cenário. Visando obter redes mais adequadas para endereçar esta tarefa, uma abordagem baseada em séries temporais foi considerada, resultado em uma acurácia média de 86%. Os modelos obtidos podem colaborar no desenvolvimento de soluções para dispositivos wearables, por exemplo, incentivando usuários a diminuir o sedentarismo.*

## 1. Introdução

A falta de atividade física é um risco à saúde que muitas pessoas têm enfrentado atualmente. De acordo com a Organização Mundial de Saúde (OMS), pelo menos 60% da população mundial não consegue alcançar a recomendação mínima de 30 minutos diários de atividade física moderada. A realização de atividades físicas provoca a diminuição das taxas de mortalidade relacionadas à doenças cardíacas, pressão alta e diabetes, por exemplo, colabora na diminuição do risco de fraturas e promove qualidade de vida, auxiliando na obtenção de uma composição corporal mais saudável [OMS 2010].

Na tentativa de estimular as pessoas a serem mais ativas, muitos dispositivos eletrônicos utilizados cotidianamente, a exemplo de *smartphones* e *smartwatches*, possuem diversos tipos de sensores, com capacidade de realizarem um monitoramento contínuo dos indivíduos que os utilizam, possibilitando a criação de soluções que envolvam o reconhecimento de atividades humanas.

O reconhecimento de atividades humanas a partir de dados obtidos por sensores é um problema frequentemente endereçado por métodos supervisionados da Aprendizagem de Máquina [Lara and Labrador 2013]. Inclusive, é uma prática comum a proposição e compartilhamento de conjunto de dados para estimular o desenvolvimento de novos métodos e técnicas para esta tarefa [Anguita et al. 2012, Su et al. 2014, Kurz et al. 2011, Roggen et al. 2009]. Neste sentido, mais recentemente foi proposto o *dataset* intitulado “*Real World Human Activity Recognition*” (RW-HAR) para investigar a relação entre a qualidade no reconhecimento automático de atividades e as posições corporais de diferentes dispositivos *wearable* [Szytler 2016]. Este *dataset* contempla dados de seis sensores em 15 sujeitos enquanto realizavam atividades como subir e descer escadas, ficar de pé, correr, caminhar, dentre outras. Os sensores eram distribuídos em diferentes partes do corpo, a exemplo de peito, braço, antebraço, cabeça, panturrilha e coxa.

Um primeiro trabalho que considerou a utilização do RW-HAR para reconhecimento automático de atividades levou em conta a classificação automática dos movimentos em estáticos ou dinâmicos [Szytler and Stuckenschmidt 2016]. Para tanto, os autores utilizaram diferentes técnicas de Aprendizagem de Máquina, das quais a técnica *random forest* teve *F-Score* médio de 89%, com os dados oriundos dos sensores localizados na panturrilha com melhores resultados, com *F-Score* de 94%. Por outro lado, a taxa de acerto para o reconhecimento da atividade correspondente a partir dos dados dos sensores localizados no braço e antebraço foi considerada baixa com *F-Score* de 84% e 85%, respectivamente. Os autores atribuem este problema à pouca flexibilidade destas partes do corpo durante a realização de atividades.

Na tentativa de obter melhores resultados no reconhecimento das atividades do RW-HAR a partir dos sensores localizados no antebraço e braço, este trabalho se propôs a utilizar a estratégia de séries temporais na reorganização dos dados para posterior apresentação à redes neurais capazes de endereçar o problema. Como resultado, foram verificadas acurácias de 92% para o antebraço e 99% para o braço nos melhores cenários, com média de 86%. A obtenção destes índices para o problema considerado pode ter aplicação direta em aplicativos para *smartwatches*, principalmente, possibilitando a utilização dos modelos elaborados para o desenvolvimento de aplicações esportivas e *fitness*, que motivem o usuário a serem mais ativos.

Para apresentar os resultados obtidos, este trabalho está organizado como segue. A Seção 2 apresenta as estratégias consideradas pelo estado da arte para o RW-HAR. A Seção 3 apresenta uma visão geral do conjunto de dados considerado no escopo deste trabalho. A Seção 4 apresenta a metodologia considerada para a proposição, treinamento e teste das redes neurais. Os resultados obtidos são apresentados e discutidos na Seção 5. Por fim, as considerações finais são apresentadas na Seção 6.

## 2. Trabalhos Relacionados

Embora haja muitos trabalhos na literatura que enderecem o reconhecimento de atividades humanas a partir de dados de sensores, dada a recente proposição do RW-HAR, ainda são poucos os trabalhos que tenham considerado este conjunto de dados e que possam ser comparados diretamente. Apesar disso, focar neste conjunto de dados permite o desenvolvimento de soluções mais realísticas, pois há a utilização de diversos sensores em diferentes partes do corpo de diferentes sujeitos em situações diferentes e em ambiente não-controlado [Szytler 2016].

O trabalho de Sztyler et al., em particular, considerou a comparação de diferentes técnicas de Aprendizagem de Máquina para o reconhecimento da atividade correspondente [Sztyler and Stuckenschmidt 2016]. Para tanto, utilizou-se janelas de tempo de 1 s de duração sobrepostas em 500 ms, com valores no domínio do tempo transformados para o domínio da frequência, utilizando a Transformada Discreta de Fourier. Os modelos a serem treinados para esta tarefa consideravam o paradigma supervisionado de aprendizado, foram eles: Redes Neurais Artificiais (RNAs), Árvores de Decisão (DTs),  $k$ -Vizinhos mais Próximos ( $k$ -NN), *Naive Bayes* (NB), *Random Forest Classifiers* (RFs) e Máquinas de Vetores de Suporte (SVMs).

Para alcançar o objetivo proposto, inicialmente os autores realizaram uma classificação da atividade em dinâmica ou estática, para somente então classificarem o tipo específico de atividade. Em relação à detecção de atividades dinâmicas ou estáticas a partir dos sensores em uma dada posição do corpo, os modelos alimentados com dados oriundos dos sensores localizados no braço e antebraço tiveram pior desempenho dentre todos os demais, com  $F$ -score igual a 85% e 84%, respectivamente, num cenário em que a média geral foi igual a 89% com valor máximo igual a 94% observados nos modelos treinados com dados oriundos dos sensores localizados na panturrilha. Em seguida, após a etapa de classificação da atividade entre estática ou dinâmica, seguiu-se para a classificação específica da atividade. Mais uma vez, os piores resultados observados ocorreram nos sensores do antebraço (79%) e braço (78%), ao passo que os melhores resultados foram observados nos dados oriundos da panturrilha, com  $F$ -score igual a 88%.

Quanto à comparação entre os modelos e métodos de Aprendizagem de Máquina adotados, os melhores resultados foram observados para RFs, ao passo que NB obteve as piores taxas de acerto. Os autores consideraram que  $k$ -NN, RNAs e SVMs tiveram resultados razoáveis. Em relação às redes neurais adotadas pelos autores, em particular, observou-se uma acurácia de 75% para a tarefa considerada. Os autores perceberam também que todos os modelos tiveram desempenho superior quando a posição dos sensores era informada durante o processo de treinamento.

### 3. Visão Geral do Conjunto de Dados

O conjunto de dados “*Real World Human Activity Recognition*” (RW-HAR) proposto por pesquisadores alemães disponibiliza dados de atividades diferentes, realizadas por quinze pessoas, com idade de  $31.9 \pm 12.4$  anos, altura de  $173.1 \pm 6.9$  cm, peso de  $74.1 \pm 13.8$  kg, compreendendo oito homens e sete mulheres. Os sensores foram distribuídos nos sujeitos nas seguintes partes do corpo: peito, braço, antebraço, cabeça, pulso, panturrilha e coxa. Cada parte do corpo era, então, monitorada por diferentes sensores, são eles: acelerômetro, GPS, giroscópio, sensores de luminosidade, campo magnético e nível sonoro. Estes sensores coletavam dados numa frequência de 50 Hz enquanto cada sujeito realizava uma das seguintes atividades: subir ou descer escadas, pular, deitar, ficar em pé, sentar, correr rápido ou lento, e andar. Exceto pelo alto esforço físico para a atividade de pular, que durou aproximadamente 1.7 min, as demais atividades foram conduzidas pelos sujeitos por aproximadamente 10 minutos. Informações de sexo, altura e peso dos sujeitos também estão presentes no conjunto de dados [Sztyler 2016].

No escopo deste artigo, considerou-se apenas a utilização dos dados oriundos do acelerômetro e giroscópio, pois estes sensores são de baixo custo e integram muitos dispositivos *wearables* já disponíveis atualmente. Uma etapa de pré-processamento eliminou

os atributos que não foram considerados. Cada amostra de dados é, portanto, composta de coordenadas  $(x,y,z)$  oriundas do acelerômetro e de valores de (rolo, passo, guinada) oriundos do giroscópio.

Para abordar o problema segundo a utilização de séries temporais, é necessário organizar os dados disponíveis no RW-HAR de acordo esta abordagem. Para tanto, foram definidas três janelas de tempo  $w_1 = 250$  ms,  $w_2 = 500$  ms e  $w_3 = 1000$  ms e, num determinado instante  $t$ , era necessário determinar a quantidade de amostras  $n$  compreendidas nesta janela, sabendo que a duração  $d$  de cada amostra  $a$  poderia variar. Para resolver esta questão, as seguintes equações foram utilizadas:

$$d_t = a_t - a_{t-1}, \quad (1)$$

$$n = \frac{|w|}{d}. \quad (2)$$

O valor de  $d_t$  variou entre 15 e 25 ms para 92% das amostras existentes no *dataset*. Para tornar viável a obtenção dos dados apesar destas diferenças, considerou-se o tempo médio  $d = 20$  ms para posterior definição da quantidade de amostras defasadas necessárias para a criação de uma janela. Como resultado, o número de amostras para cada janela encontra-se sintetizado na Tabela 1.

**Tabela 1. Quantidade de amostras que compõem cada uma das janelas com diferentes durações de tempo.**

Tamanho da Janela	Quantidade de Amostras
250 ms	13
500 ms	25
1000 ms	50

Assim, após a determinação da quantidade de amostras por janela, foram produzidos 6 diferentes *datasets* a partir do conjunto de dados original, os quais contemplam a organização dos dados do antebraço e do braço com as medições defasadas correspondentes à cada janela. O total de exemplos de cada um dos *datasets* pode ser visto na Tabela 2, a qual também contempla algumas características de cada conjunto.

**Tabela 2. Visão geral dos exemplos de acordo com a parte do braço e janela de tempo.**

Posição	Tamanho da Janela	Qtd. de Exemplos	Ex. Estáticos	Ex. Dinâmicos
Antebraço	250 ms	148630	67524	81106
Antebraço	500 ms	69745	31979	37766
Antebraço	1000 ms	28616	12947	15669
Braço	250 ms	105164	44265	60899
Braço	500 ms	37181	15574	21607
Braço	1000 ms	1219	457	762

Como mostrado na Tabela 2, é possível perceber que há mais exemplos nos *datasets* com menores janelas, uma consequência do fato de que cada exemplo é composto de uma quantidade menor de amostras defasadas, conforme Tabela 1. É possível perceber também que há cerca de 40% de exemplos estáticos e 60% de exemplos dinâmicos, o que favorece o treinamento de redes neurais visto que os exemplos são aproximadamente balanceados.

#### 4. Materiais e Métodos

O problema a ser endereçado no escopo deste trabalho é uma tarefa de classificação binária, em que medições coletadas em uma janela de tempo, a partir de dados do acelerômetro e giroscópio, são utilizadas para identificar se o sujeito está realizando uma tarefa de natureza estática ou dinâmica.

Para resolver este problema, considerou-se a adoção de redes neurais com processamento temporal, as chamadas *time delay neural networks*. Este tipo de rede neural artificial é uma rede *feedforward multilayer perceptron* que tem como propósito o aprendizado de padrões em dados sequenciais, onde a resposta da rede no tempo  $t$  é baseada nas entradas no tempo  $(t - 1), (t - 2), \dots, (t - n)$ . Devido às capacidades de aprendizado e generalização a partir de dados observacionais, este modelo da Aprendizagem de Máquina é amplamente adotado para processamento de dados experimentais.

Como mencionado na seção anterior, serão utilizadas três janelas de tempo diferentes, com  $w_1 = 250$  ms,  $w_2 = 500$  ms e  $w_3 = 1000$  ms. Em decorrência disto, o número de neurônios na camada de entrada das redes neurais a serem propostas será diferente. Para as redes que irão ser treinadas com a janela  $w_1$ , as quais recebem 13 amostras defasadas (vide Tabela 1) dos seis parâmetros oriundos dos 2 sensores, tem-se uma camada de entrada  $N_{i,1}$  com 78 neurônios. De maneira análoga, as redes que receberão dados da janela  $w_2$  terão  $N_{i,2} = 150$ , e as redes que receberão dados da janela  $w_3$  terão  $N_{i,3} = 300$  neurônios.

Seguiu-se então para a determinação da quantidade de camadas ocultas e do número de neurônios nestas camadas. Considerou-se apenas a utilização de redes neurais com uma ou duas camadas ocultas, em virtude de serem aproximadoras universais de qualquer função [Haykin 2009]. Quanto ao número de neurônios nessas camadas, embora não haja uma maneira analítica de precisar este valor, considerou-se a regra da pirâmide geométrica [Palit and Popovic 2005]. De acordo com esta regra, o número de neurônios  $N_{h,w}$  nas camadas ocultas em função da janela  $w$  é dado por:

$$N_{h,w} = \alpha \cdot \sqrt{N_{i,w} \times N_o}, \quad (3)$$

em que  $N_{i,w}$  é o número de neurônios na camada de entrada, e que precisa levar em conta o tamanho da janela  $w$  que está sendo considerado;  $N_o = 1$  é o número de neurônios na camada de saída, que tem este valor em virtude do problema abordado ser de classificação binária; e  $\alpha$  é uma constante que assume valores no intervalo  $0.5 \leq \alpha \leq 2$ .

Além de uma quantidade diferentes de camadas ocultas e de um número variado de neurônios nestas camadas, optou-se pela utilização de duas diferentes funções de ativação, a tangente hiperbólica (*tanh*) ou a sigmóide (*logistic*), e pela variação na taxa de aprendizado inicial a qual é adaptativa, ou seja, tem seu valor ajustado conforme o erro

diminui. Como resultado, foram propostas 464 redes neurais artificiais diferentes para este cenário, sendo 112 delas para a janela de  $w_1$ , 148 para  $w_2$  e 204 para  $w_3$ . O detalhamento das redes propostas é mostrado na Tabela 3.

**Tabela 3. Arquiteturas e configurações das redes neurais artificiais propostas.**

Janela	Neurônios na Camada Oculta	Taxa de Aprendizado
$w_1 = 250$ ms	$4 \leq N_{h,1} \leq 19$	0.001 ou 0.003
$w_2 = 500$ ms	$7 \leq N_{h,2} \leq 28$	0.001 ou 0.003
$w_3 = 1000$ ms	$9 \leq N_{h,3} \leq 38$	0.001 ou 0.003

Os exemplos disponíveis nos *datasets* foram separados em uma partição de 70% para o conjunto de treinamento e 30% para o conjunto de testes, selecionados e apresentados às redes de maneira aleatória. O treinamento e teste de cada rede foi repetido 10 vezes a fim de evitar algum viés introduzido pela escolha aleatória dos pesos iniciais ou pela ordem de apresentação dos elementos às redes. Todas as redes foram treinadas com o algoritmo *backpropagation* considerando a otimização de Levenberg-Marquadt. A acurácia foi a métrica de desempenho adotada para comparar as diferentes redes neurais obtidas e elencar as que possuíam melhor performance perante o conjunto de testes.

A implementação, treinamento e teste das redes neurais considerou o ambiente de programação provido pela linguagem Python, em que o *framework* `sci-kit learn`<sup>1</sup> e a biblioteca `pandas`<sup>2</sup> possuíam papel central.

## 5. Resultados e Discussão

Para apresentar os resultados obtidos, serão selecionadas as 10 melhores redes neurais em cada cenário. Primeiramente, no caso do antebraço, os resultados estão sintetizados nas Tabelas 4,5 e 6.

**Tabela 4. Resultados das redes neurais com maior acurácia treinadas e testadas com dados do antebraço e janela de tempo  $w_1 = 250$  ms**

Acurácia	Arquitetura	Função de Ativação	Taxa de Aprendizado
0.927695	(78, 13, 1)	tanh	0.003
0.920249	(78, 8, 1)	logistic	0.003
0.912288	(78, 13, 1)	logistic	0.001
0.906367	(78, 13, 6, 1)	logistic	0.001
0.901500	(78, 18, 1)	logistic	0.003
0.894324	(78, 18, 1)	logistic	0.001
0.892574	(78, 13, 1)	logistic	0.003
0.891789	(78, 7, 1)	logistic	0.003
0.889435	(78, 16, 1)	logistic	0.003
0.884882	(78, 9, 1)	logistic	0.001

<sup>1</sup><http://scikit-learn.org/>

<sup>2</sup><http://pandas.pydata.org/>

**Tabela 5. Resultados das redes neurais com maior acurácia treinadas e testadas com dados do antebraço e janela de tempo  $w_2 = 500$  ms**

<b>Acurácia</b>	<b>Arquitetura</b>	<b>Função de Ativação</b>	<b>Taxa de Aprendizado</b>
0.834687	(150, 17, 11, 1)	logistic	0.003
0.834401	(150, 11, 1)	logistic	0.001
0.834305	(150, 14, 14, 1)	logistic	0.003
0.834018	(150, 21, 7, 1)	logistic	0.003
0.833588	(150, 20, 8, 1)	logistic	0.003
0.832585	(150, 19, 9, 1)	logistic	0.003
0.831677	(150, 20, 8, 1)	logistic	0.001
0.830195	(150, 12, 16, 1)	logistic	0.001
0.830147	(150, 14, 14, 1)	tanh	0.001
0.829621	(150, 15, 13, 1)	logistic	0.001

**Tabela 6. Resultados das redes neurais com maior acurácia treinadas e testadas com dados do antebraço e janela de tempo  $w_3 = 1000$  ms**

<b>Acurácia</b>	<b>Arquitetura</b>	<b>Função de Ativação</b>	<b>Taxa de Aprendizado</b>
0.759581	(300, 20, 18, 1)	tanh	0.003
0.756436	(300, 24, 14, 1)	tanh	0.003
0.756203	(300, 18, 20, 1)	tanh	0.003
0.751310	(300, 15, 23, 1)	tanh	0.003
0.750495	(300, 29, 9, 1)	tanh	0.003
0.749563	(300, 19, 19, 1)	tanh	0.003
0.747932	(300, 13, 25, 1)	tanh	0.003
0.745719	(300, 10, 28, 1)	tanh	0.001
0.744089	(300, 27, 11, 1)	tanh	0.003
0.743856	(300, 16, 22, 1)	tanh	0.003

No caso dos resultados obtidos para a classificação da atividade (estática ou dinâmica) a partir dos sensores disponíveis no antebraço, é interessante observar que o aumento na janela não correspondeu exatamente a um aumento no desempenho da tarefa. Isto é um aspecto interessante do ponto de vista prático, pois quanto menor o tamanho da janela, menor é a quantidade de neurônios na camada de entrada da rede, o que a torna estruturalmente simples. É possível observar também que as três redes com maior métrica de performance são aquelas que possuem apenas uma camada oculta. Este é um outro aspecto positivo dos modelos com maior taxa de acerto identificados neste trabalho, pois são mais simples de treinar devido ao menor número de pesos a serem ajustados quando comparadas às redes com duas camadas ocultas.

Os resultados obtidos pelas redes neurais com processamento temporal para identificação do tipo de atividade, a partir dos sensores localizados no antebraço, indicam acurácia média de 82%, com maior acurácia igual a 92,7% para a rede com arquitetura (78,13,1) e janela de tempo  $w_1 = 250$  ms.

Partindo para os resultados do braço, as Tabelas 7, 8 e 9 sintetizam os resultados obtidos. Observa-se que a classificação com os dados dos sensores localizados nesta parte do corpo obtiveram resultados satisfatórios, com acurácia média de 89%, e maior valor igual a 99.14% para rede com arquitetura (150,20,1) considerando a janela de tempo  $w_2$  igual a 500 ms.

**Tabela 7. Resultados das redes neurais com maior acurácia testadas com dados do braço e janela de tempo  $w_1 = 250$  ms**

<b>Acurácia</b>	<b>Arquitetura</b>	<b>Função de Ativação</b>	<b>Taxa de Aprendizado</b>
0.934802	(78, 14, 1)	logistic	0.003
0.905990	(78, 15, 1)	logistic	0.003
0.902631	(78, 12, 7, 1)	tanh	0.003
0.897147	(78, 5, 1)	logistic	0.003
0.884120	(78, 8, 1)	tanh	0.003
0.870650	(78, 9, 10, 1)	logistic	0.001
0.870079	(78, 8, 1)	logistic	0.003
0.869731	(78, 7, 12, 1)	tanh	0.003
0.868843	(78, 12, 7, 1)	logistic	0.001
0.868082	(78, 18, 1)	logistic	0.001

**Tabela 8. Resultados das redes neurais com maior acurácia testadas com dados do braço e janela de tempo  $w_2 = 500$  ms**

<b>Acurácia</b>	<b>Arquitetura</b>	<b>Função de Ativação</b>	<b>Taxa de Aprendizado</b>
0.991484	(150, 20, 1)	logistic	0.003
0.990946	(150, 15, 1)	logistic	0.003
0.990766	(150, 11, 1)	tanh	0.003
0.990498	(150, 9, 19, 1)	logistic	0.001
0.990498	(150, 15, 1)	logistic	0.001
0.990408	(150, 25, 1)	logistic	0.003
0.990408	(150, 17, 1)	tanh	0.003
0.990408	(150, 17, 1)	logistic	0.003
0.990408	(150, 21, 7, 1)	logistic	0.003
0.990318	(150, 21, 1)	logistic	0.003



**Tabela 9. Resultados das redes neurais com maior acurácia testadas com dados do braço e janela de tempo  $w_3 = 1000$  ms**

Acurácia	Arquitetura	Função de Ativação	Taxa de Aprendizado
0.844262	(300, 38, 1)	tanh	0.003
0.841530	(300, 27, 1)	tanh	0.003
0.838798	(300, 25, 1)	tanh	0.003
0.816940	(300, 28, 10, 1)	tanh	0.003
0.811475	(300, 26, 12, 1)	tanh	0.003
0.803279	(300, 29, 9, 1)	tanh	0.003
0.803279	(300, 26, 1)	logistic	0.003
0.800546	(300, 31, 1)	logistic	0.003
0.800546	(300, 13, 25, 1)	tanh	0.003
0.797814	(300, 19, 19, 1)	tanh	0.003

Os resultados obtidos por meio das redes neurais com processamento temporal mostram-se equiparáveis aos resultados reportados na literatura, vide [Szytler and Stuckenschmidt 2016], especialmente considerando a métrica de acurácia e a utilização de redes neurais. A abordagem considerada no escopo deste trabalho evidencia a extração de padrões relevantes para auxiliar na determinação do tipo de atividade que o sujeito está realizando.

## 6. Considerações Finais

Este trabalho se propôs a utilizar *time delay neural networks* para detecção do tipo de atividade que sujeitos estavam realizando em um ambiente não controlado. A atividade era classificada em dinâmica ou estática e os dados das mesmas foram adquiridos de sensores localizados no braço e antebraço dos sujeitos, disponibilizados por meio de um *dataset* proposto recentemente. Diferentes redes neurais foram propostas, treinadas e testadas para o problema em questão, considerando diferentes janelas de tempo.

Os resultados obtidos evidenciam que a abordagem proposta é adequada, com resultados equiparáveis aos da literatura se considerado o mesmo modelo de Aprendizagem de Máquina. A utilização de redes neurais artificiais e a captura de aspectos temporais podem justificar o desempenho dos resultados obtidos, capturando mais adequadamente características inerentes ao domínio do problema. Vale ressaltar que os resultados obtidos com estes modelos não são dependentes do sujeito que realiza as atividades, um aspecto que pode contribuir na adoção da solução proposta para o desenvolvimento de aplicativos para *smartphones* e *smartwatches* que motivem os usuários a terem um estilo de vida mais saudável.

Embora os resultados obtidos mostrem uma boa performance para o reconhecimento das tarefas a partir dos sensores localizados no braço e antebraço, é preciso a realização de mais pesquisas para verificar se os resultados aqui reportados são superiores aos que foram obtidos com a utilização de *random forest classifier* [Szytler and Stuckenschmidt 2016], especialmente considerando a obtenção de métricas de desempenho diretamente comparáveis. Esta perspectiva já está sendo considerada.

Em outros trabalhos futuros almeja-se investigar mais a fundo a utilização de redes

neurais para reconhecimento de atividades humanas em ambientes não controlados. Além da classificação quanto ao tipo de atividade, pretende-se partir para um refinamento de determinação do tipo específico de atividade em questão.

## Agradecimentos

Os autores Janderson do Nascimento Lira, Nicoli Pinheiro de Araújo e Rodrigo Moraes agradecem o apoio financeiro provido pela Universidade do Estado do Amazonas e pela Fundação de Amparo à Pesquisa do Amazonas por meio do Programa de Apoio à Iniciação Científica.

## Referências

- [Anguita et al. 2012] Anguita, D., Ghio, A., Oneto, L., Parra, X., and Reyes-Ortiz, J. L. (2012). Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine. In *International workshop on ambient assisted living*, pages 216–223, Berlim. Springer.
- [Haykin 2009] Haykin, S. (2009). *Neural Networks and Learning Machines*. Pearson, Nova Jersey, 3 edition.
- [Kurz et al. 2011] Kurz, M., Holzl, G., Ferscha, A., Sagha, H., del R Millán, J., and Chavarriaga, R. (2011). Dynamic quantification of activity recognition capabilities in opportunistic systems. In *IEEE 73rd Vehicular Technology Conference (VTC Spring)*, pages 1–5.
- [Lara and Labrador 2013] Lara, O. and Labrador, M. A. (2013). A survey on human activity recognition using wearable sensors. *IEEE Communications Surveys & Tutorials*, 15(3):1192–1209.
- [OMS 2010] OMS (2010). *Global Recommendations on Physical Activity for Health*. Editora da OMS, Suíça.
- [Palit and Popovic 2005] Palit, A. K. and Popovic, D. (2005). *Computational Intelligence in Time Series Forecasting - Theory and Engineering Applications*. Springer, Londres, 1 edition.
- [Roggen et al. 2009] Roggen, D., Forster, K., Calatroni, A., Holleczeck, T., Fang, Y., Troster, G., Ferscha, A., Holzmann, C., Riener, A., and Lukowicz, P. (2009). Opportunity: Towards opportunistic activity and context recognition systems. In *IEEE International Symposium on a World of Wireless, Mobile and Multimedia Networks & Workshops (WoWMoM 2009)*, pages 1–6. IEEE.
- [Su et al. 2014] Su, X., Tong, H., and Ji, P. (2014). Activity recognition with smartphone sensors. *Tsinghua Science and Technology*, 19(3):235–249.
- [Szytler 2016] Szytler, T. (2016). Real world human activity recognition. University of Mannheim – Research Group Data and Web Science. Disponível em [http://sensor.informatik.uni-mannheim.de/#dataset\\_realworld](http://sensor.informatik.uni-mannheim.de/#dataset_realworld). Acessado em 11 de setembro de 2017.
- [Szytler and Stuckenschmidt 2016] Szytler, T. and Stuckenschmidt, H. (2016). On-body localization of wearable devices: an investigation of position-aware activity recognition. In *IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pages 1–9. IEEE.