



## AVALIAÇÃO DE MEDIDAS PARA RECUPERAÇÃO DE CURVAS SOBRE MOVIMENTOS CORPORAIS

## ASSESSMENT OF MEASURES TO RETRIEVE BODY MOTION CURVES

## EVALUACIÓN DE MEDIDAS PARA RECUPERACIÓN DE CURVAS SOBRE MOVIMIENTOS DEL CUERPO

Ana Paula Merencia<sup>1</sup>  
Huei Diana Lee<sup>2</sup>  
Weber Takaki<sup>3</sup>  
Newton Spolaôr<sup>4</sup>  
Matheus Maciel<sup>5</sup>  
Wu Feng Chung<sup>6</sup>

DOI: 10.54751/revistafoco.v16n3-112  
Recebido em: 24 de Fevereiro de 2023  
Aceito em: 22 de Março de 2023



### RESUMO

Grande parte dos métodos de análise de movimentos do corpo humano não considera as peculiaridades da resposta mecânica corporal em cada plano anatômico. Nesse contexto, sensores inerciais triaxiais, como o acelerômetro, oferecem dados que permitem a análise pormenorizada dos movimentos de articulações e partes do corpo. O objetivo deste trabalho consiste em pesquisar, implementar e analisar três medidas para a comparação de curvas de movimentos do corpo: *Dynamic Time Warping*, Coeficiente de Determinação  $R^2$  e Coeficiente de Correlação R de Pearson. Essas três medidas foram analisadas considerando como padrão uma curva de referência extraída de uma base de dados pública com atividades motoras de indivíduos coletadas por acelerômetro. Assim, todas as curvas de movimento da base foram comparadas com

<sup>1</sup> Mestranda no Programa de Pós-graduação em Engenharia Elétrica e Computação (PGEEC). Universidade Estadual do Oeste do Paraná (UNIOESTE). Av. Presidente Tancredo Neves, 6731, CEP: 85867-900. Foz do Iguaçu, Brasil.

E-mail: [ana.merencia@unioeste.br](mailto:ana.merencia@unioeste.br)

<sup>2</sup> Doutora em Ciências da Computação e Matemática Computacional pela Universidade de São Paulo (USP). Centro de Engenharias e Ciências Exatas - Universidade Estadual do Oeste do Paraná (LABI-UNIOESTE), R. Universitária, 1619, Universitário, Cascavel - PR, CEP: 85819-110. E-mail: [huei.lee@unioeste.br](mailto:huei.lee@unioeste.br)

<sup>3</sup> Doutor em Ciências da Cirurgia pela Universidade Estadual de Campinas (UNICAMP). Universidade Estadual do Oeste do Paraná (LABI-UNIOESTE), R. Universitária, 1619, Universitário, Cascavel - PR, CEP: 85819-110.

E-mail: [webertakaki@gmail.com](mailto:webertakaki@gmail.com)

<sup>4</sup> Doutor em Ciências da Computação e Matemática Computacional pela Universidade de São Paulo (USP). Universidade Estadual do Oeste do Paraná (LABI-UNIOESTE), R. Universitária, 1619, Universitário, Cascavel - PR, CEP: 85819-110. E-mail: [newtonspolaor@gmail.com](mailto:newtonspolaor@gmail.com)

<sup>5</sup> Mestrando no Programa de Pós-graduação em Engenharia Elétrica e Computação (PGEEC). Universidade Estadual do Oeste do Paraná (LABI-UNIOESTE), R. Universitária, 1619, Universitário, Cascavel - PR, CEP: 85819-110.

E-mail: [macielmaatheuss@gmail.com](mailto:macielmaatheuss@gmail.com)

<sup>6</sup> Doutor em Ciências da Cirurgia pela Universidade Estadual de Campinas (UNICAMP). Centro de Engenharias e Ciências Exatas - Universidade Estadual do Oeste do Paraná (LABI-UNIOESTE), R. Universitária, 1619, Universitário, Cascavel - PR, CEP: 85819-110. E-mail: [wu.chung@unioeste.br](mailto:wu.chung@unioeste.br)

esse padrão sob diferentes cenários: (1) dados brutos, (2) dados com normalização, (3) dados com ajuste de curva e (4) dados com normalização seguida de ajuste. Os resultados experimentais indicam que *Dynamic Time Warping* apresentou melhor desempenho na recuperação de sinais apenas nas abordagens sem ajuste de curva, mas demandou maior custo computacional. Por sua vez, os dois coeficientes levaram a desempenhos competitivos em todos os cenários para a recuperação das três curvas mais similares à referência, exibindo ainda menor custo computacional. Conclui-se que este trabalho cumpriu seu objetivo, sendo as medidas avaliadas promissoras para uso em um sistema original de telemedicina.

**Palavras-chave:** Biomecânica; aceleração; *e-health*; telessaúde; séries temporais.

### ABSTRACT

Most of the methods for analyzing human body movements do not consider the peculiarities of the body's mechanical response in each anatomical plane. In this context, triaxial inertial sensors, such as the accelerometer, provide data that allow detailed analysis of the movements of joints and body parts. The aim of this work is to research, implement and analyze three measures for comparing body movement curves: Dynamic Time Warping, Coefficient of Determination  $R^2$  and Pearson's R Correlation Coefficient. These three measures were analyzed considering as pattern a reference curve extracted from a public database with motor activities of individuals collected by accelerometer. Thus, all base motion curves were compared to this pattern under different scenarios: (1) raw data, (2) data with normalization, (3) data with curve fitting, and (4) data with normalization followed by adjustment. Experimental results indicate that Dynamic Time Warping performed better in signal recovery only in approaches without curve fitting, but demanded higher computational cost. In turn, the two coefficients led to competitive performances in all scenarios for the recovery of the three curves most similar to the reference, exhibiting even lower computational cost. It is concluded that this work fulfilled its objective, with the evaluated measures promising for use in an original telemedicine system.

**Keywords:** Biomechanics; acceleration; e-health; telehealth; time series.

### RESUMEN

La mayoría de los métodos de análisis de los movimientos del cuerpo humano no consideran las peculiaridades de la respuesta mecánica del cuerpo en cada plano anatómico. En este contexto, los sensores inerciales triaxiales, como el acelerómetro, brindan datos que permiten el análisis detallado de los movimientos de las articulaciones y partes del cuerpo. El objetivo de este trabajo es investigar, implementar y analizar tres medidas para comparar las curvas de movimiento del cuerpo: Dynamic Time Warping, Coeficiente de Determinación  $R^2$  y Coeficiente de Correlación R de Pearson. Estas tres medidas fueron analizadas considerando como patrón una curva de referencia extraída de una base de datos pública con actividades motoras de individuos recolectadas por acelerómetro. Por lo tanto, todas las curvas de movimiento base se compararon con este patrón en diferentes escenarios: (1) datos sin procesar, (2) datos con normalización, (3) datos con ajuste de curva y (4) datos con normalización seguida de ajuste. Los resultados experimentales indican que Dynamic Time Warping se desempeñó mejor en la recuperación de la señal solo en enfoques sin ajuste de curva, pero exigió un mayor costo computacional. A su vez, los dos coeficientes llevaron a desempeños competitivos en todos los escenarios para la recuperación de las tres curvas más similares a la referencia, presentando un costo computacional aún menor. Se concluye que este trabajo cumplió su objetivo, siendo las medidas evaluadas promisorias para su uso en un sistema original de telemedicina.

**Palabras clave:** biomecánica; aceleración; *e-health*; telesalud; serie temporal.

## 1. Introdução

Nos últimos anos, diversos trabalhos têm apresentado abordagens para o acompanhamento e o reconhecimento de movimentos do corpo humano. Nesse cenário, sensores inerciais acoplados ao corpo são amplamente utilizados com o objetivo de obter dados de atividades corporais, possibilitando aplicações como o monitoramento do processo de reabilitação, avaliação e diagnóstico de lesões e de limitações de pacientes (CORNACCHI et al., 2017; ARANI; COSTA; SHIHAB, 2021; QIU et al., 2022).

Entre as abordagens relatadas na literatura para a realização do acompanhamento e o reconhecimento de movimentos corporais estão métodos que identificam movimentos por meio de Inteligência Computacional (IC) (LEE et al., 2013; FIGUEIRA; MATIAS; GAMBOA, 2016; CHEN et al., 2017). Em resumo, a IC se refere à capacidade de um computador aprender uma tarefa específica a partir de dados ou observação experimental (SIDDIQUE; ADELI, 2013).

No entanto, essas abordagens não consideram, de modo completo, as particularidades da resposta mecânica dos movimentos em cada plano anatômico ao longo do tempo, além de não serem capazes de analisar padrões de movimentos ou identificar parâmetros entre indivíduos saudáveis e ou lesionados nesses três planos (WU et al., 2019). Assim, Wu et al. (2019) propuseram um método original para criação e análise de curvas padrão de movimento de articulações e partes corpóreas. Esse método utiliza dados oriundos de sensores inerciais para os três eixos do sistema ortogonal de coordenadas (x, y e z), os quais referem-se aos movimentos de articulações e regiões do corpo humano. Esses dados podem ser representados na forma de séries temporais (BERNDT; CLIFFORD, 1994), sendo que cada uma consiste em uma sequência de observações realizada ao longo do tempo.

Nesse cenário, o Laboratório de Bioinformática (LABI) da Universidade Estadual do Oeste do Paraná (UNIOESTE), desenvolveu o Sistema de Monitoramento de Movimentos e Análise Remota em Telemedicina (SMMAR-T) com o propósito de automatizar o método proposto (ENSINA, 2020).

O SMMAR-T é um sistema *web* de telemedicina que permite a criação de curvas padrão de movimentos do corpo humano sem ou com lesão. Além disso, o sistema também possibilita a criação e a disponibilização de um plano de atividades para um indivíduo, o qual pode, com a supervisão presencial ou remota e em tempo real de um especialista, efetuar os exercícios planejados em qualquer lugar (ENSINA et al., 2021).

Outras funcionalidades do *software* incluem a possibilidade de o especialista comparar o movimento realizado pelo paciente com um padrão previamente estabelecido de outro paciente ou com um padrão do próprio paciente. Vale ressaltar que o movimento padrão criado pode ser representativo para um único indivíduo ou para um conjunto de indivíduos (MACIEL, 2021).

O objetivo deste trabalho consistiu em pesquisar, implementar e analisar três medidas para a comparação de curvas de movimentos do corpo: *Dynamic Time Warping* (DTW), Coeficiente de Determinação  $R^2$  e Coeficiente de Correlação R de Pearson.

## 2. Trabalhos Relacionados

Diversas medidas e métodos são encontrados na literatura para analisar e comparar séries temporais de movimentos do corpo humano (XU; HE; ZHANG, 2019; ARANI; COSTA; SHIHAB, 2021; JIANG; LAN, 2021; YOSHIHI *et al.*, 2021; LI; WANG, 2022). Nesses trabalhos, a principal abordagem adotada é o estudo de séries temporais obtidas por meio de sensores inerciais, como o acelerômetro, o giroscópio e o magnetômetro, os quais são acoplados ao corpo humano para obter dados procedentes da atividade realizada pelo usuário.

Os estudos retratados a seguir seguem duas linhas de abordagens para a análise e ou monitoramento de movimentos do corpo humano: (1) métodos de Aprendizagem de Máquina e (2) comparação por limiares. Também existem referências que mesclam o uso das duas abordagens.

Li e Wang (2022) trataram sobre o reconhecimento da atividade humana no esporte e na saúde, além de propor um modelo de *Bidirectional Long Short Term Memory* (BiLSTM) (ZHAO *et al.*, 2018). A proposta primeiro extraiu automaticamente características espaciais de sinais multidimensionais de

sensores inerciais usando o bloco residual e, em seguida, obteve as dependências para frente e para trás da sequência de atributos usando BiLSTM. Após, as características obtidas foram usadas para alimentar a camada de neurônios com a função de ativação Softmax para completar o reconhecimento da atividade humana. Os parâmetros ótimos do classificador foram obtidos experimentalmente. Foi desenvolvido um dispositivo denominado *Inertial Measurement Unit* que foi fixado ao corpo humano abaixo do joelho, na parte anterior da perna. A partir dele, foram obtidas diretamente as informações de movimento dos membros inferiores do corpo humano. Seis atividades humanas foram monitoradas: sentar-se, ficar em pé, andar, correr, subir e descer. Portanto, o estudo considerou principalmente o reconhecimento de ações realizadas pelos membros inferiores. No modelo ocorreram 80 iterações. Segundo os autores, os resultados experimentais mostraram que tanto a acurácia de treinamento quanto a de validação aumentam à medida que o número de iterações de aprendizado avança. As curvas das acurácias ficaram muito próximas depois de 20 épocas e, depois de 70, a amplitude das curvas basicamente se manteve estável.

Arani, Costa e Shihab (2021) utilizaram um conjunto de dados de fotopletiografia denominado PPG-DaLiA, o qual é composto por sinais de Acelerômetro 3D (3D-ACC) e Eletrocardiógrafo (ECG) adquiridos de 15 indivíduos durante a realização de atividades diárias (WANG; CANG; YU, 2019). Também extraíram características de domínio de tempo e frequência. Em seguida, os autores aplicaram uma abordagem de seleção de atributos baseada em correlação para reduzir a dimensionalidade dos dados. Após, eles treinaram e testaram modelos de *Random Forest* (RF) conforme duas abordagens: (1) sujeito-dependente, em que treino e teste são realizados, para cada indivíduo, nos dados dessa pessoa, e (2) independente-do-sujeito, em que a inferência do classificador é realizada com dados de vários indivíduos. Adicionalmente, para analisar a contribuição do sinal em sistemas de *Human Activity Recognition*, Arani, Costa e Shihab (2021) segmentaram os sinais, usando um método de janela deslizante para extrair características do domínio do tempo e frequência. Os resultados indicaram que a combinação de características extraídas do sinal

3D-ACC e do sinal de ECG melhorou os escores de desempenho do classificador RF, de 94,07% para 96,80% (abordagem sujeito- dependente) e de 83,16% para 86,17% (abordagem independente-do-sujeito).

Jiang e Lan (2021) estudaram um modelo probabilístico de reconhecimento de escalada baseado em séries temporais de movimentos de escalada realizada por humanos. As informações foram combinadas por fusão de sensores para que os escaladores pudessem atuar de forma mais padronizada, ou seja, subir pedras de maneira correta para diminuir ao máximo o risco de acidente. Foi criado um sistema que utiliza um método para identificar padrões de movimento humano com base em informações de eventos de marcha. Além disso, este método coletou os dados de aceleração de três eixos registrados por cada acelerômetro acoplado aos indivíduos, por meio dos principais eventos de marcha, estabelecendo um conjunto de dados usado para identificar padrões de movimento humano com apoio de um classificador discriminante linear. O método atingiu 95,84% da acurácia no reconhecimento dos quatro modos de estado de escalada. O experimento final mostrou que o sistema pode reconhecer o movimento de escalada do alpinista em 3 s.

Yoshihi et al. (2021) usaram um acelerômetro de três eixos acoplados à cabeça de um indivíduo para capturar informações que pudessem levar à descoberta de três estágios específicos do sono: sono com movimento rápido dos olhos – sono *Rapid Eye Movement* (REM) –, sono leve e sono profundo. Esses estágios foram medidos por um conjunto de características de frequência cardíaca capturadas por um balistocardiograma e movimento corporal. O experimento do sono foi realizado por duas noites considerando oito homens adultos saudáveis. De acordo com o estudo, a acurácia do classificador foi de 74,6%.

Xu, He e Zhang (2019) propuseram um algoritmo de detecção de queda baseado na rede combinada *Convolutional Neural Network* (CNN)-LSTM. Foi utilizado um conjunto de dados MobiAct (conjunto de dados públicos que inclui dados de um *smartphone* de diferentes tipos de atividades e uma série de quedas) que usa o módulo de sensor inercial LSM330DLC integrado de um *smartphone* para coletar dados do acelerômetro de três eixos, giroscópio e

medidor de direção a uma frequência de 200 Hz. Além disso, o comportamento de queda e outros seis tipos de atividades da vida diária foram selecionados para treinar o modelo. O conjunto de dados experimentais foi dividido em conjunto de treinamento (80%) e conjunto de teste (20%), e um total de 5.891 amostras de treino e 1.473 amostras de teste foram obtidas.

De acordo com os autores, os resultados experimentais mostraram que a acurácia da rede CNN-LSTM é maior que a de 1D CNN e LSTM. O CNN-LSTM atingiu uma acurácia de classificação de 98,98% em sete tipos de comportamentos diários. Quanto ao comportamento de queda, a acurácia e especificidade de detecção são de 98,61% e 99,76%.

### **3. Materiais e Métodos**

Nesta seção são abordados conceitos e componentes relacionados ao método deste trabalho, bem como o material e as configurações adotadas na avaliação experimental.

#### **3.1 Similaridade entre Séries Temporais**

O conceito de similaridade é importante para diversas tarefas tradicionais de Mineração de Dados (MD) e na análise de Séries Temporais (ST). Por exemplo, a tarefa de agrupamento aplica esse conceito entre os membros de um conjunto para decidir em que grupo um determinado elemento se enquadra melhor. A semelhança entre exemplos de um conjunto de dados é definida, geralmente, por meio do uso de uma medida de similaridade. O conhecimento das características das medidas disponíveis permite escolher a melhor em uma aplicação (HETLAND, 2004).

Nesse contexto, a medida estabelece o critério para quantificar quão similares são duas sequências de observações de dados ao longo do tempo e decidir se pertencem ou não a determinado padrão. A adoção dessa definição em ST é bastante subjetiva, pois depende de diversos fatores, tais como o domínio da aplicação e as características do método escolhido para o cálculo da similaridade (HETLAND, 2004).

No presente trabalho, foram avaliadas três medidas de similaridade –

DTW,  $R^2$  e  $R^-$ , as quais são descritas a seguir.

### 3.1.1 *Dynamic Time Warping*

A técnica DTW, desenvolvida com base na distância de Levenshtein (LEVENSHTEIN, 1966), foi apresentada para a comunidade de MD no trabalho de Berndt e Clifford (1994). Ela já era empregada com sucesso na área de reconhecimento de fala, e foi introduzida para a análise de séries temporais como uma solução para os principais problemas das distâncias da Norma  $L_p$  – distância Euclidiana, Manhattan e Mahalanobis, entre outras. Um dos problemas refere-se à baixa capacidade para o tratamento de *outliers* (valores fora do intervalo de determinada distribuição) e o fato de as distâncias da Norma  $LP$  serem sensíveis a pequenas distorções e deslocamentos no eixo temporal da série. Em particular, DTW adiciona qualidade à comparação de ST defasadas no eixo do tempo.

Essa distância busca alinhar, da maneira mais adequada possível, os valores das séries a serem comparadas (PETITJEAN; KETTERLIN; GANÇARSKI, 2010). Isso permite que duas ST globalmente similares, mas que estejam fora de alinhamento no eixo temporal, possam ser alinhadas para posterior comparação ponto-a-ponto. Desse modo, a DTW permite encontrar semelhança entre sequências de observações ao longo do tempo quando não seria possível identificar usando apenas a abordagem ponto-a-ponto tradicional (RATANAMAHATANA; KEOGH, 2005). O processo de alinhamento consiste em mapear pontos de uma série em outra, como apontado por Salvador e Chan (2007). Adicionalmente, a principal desvantagem do DTW está relacionada à sua complexidade  $O(m.n)$  (usando programação dinâmica), sendo  $m$  e  $n$  os tamanhos da primeira e segunda séries, respectivamente, e o fato da complexidade de memória possuir uma relação quadrática com o tamanho das séries (BROWN; RABINER, 2003).

Para alinhar duas séries  $Z$  e  $T$  de tamanhos  $m$  e  $n$ , respectivamente, o algoritmo constrói uma matriz  $m \times n$ . Nessa matriz, cada elemento  $(i, j)$  corresponde ao valor da distância entre os pontos  $(Z_i, T_j)$ . De posse dessa matriz busca-se uma rota  $R$ , que alinhe as séries  $Z$  e  $T$ , conforme definido pela Equação

1 (SALVADOR; CHAN, 2007).

$$R = (r_1, r_2, \dots, r_L) \quad (1)$$

onde cada  $r_l$  corresponde a um mapeamento  $(i, j)$  para  $l = 1, \dots, L$ , com  $L$  representando o tamanho da rota, restrito à condição  $\max(m, n) \leq L < m + n$ .

### 3.1.2 Coeficiente de Correlação R de Pearson

O Coeficiente de Correlação de Pearson, também conhecido como R de Pearson, é um coeficiente de correlação que geralmente é usado em regressão linear para encontrar a força e a direção da relação linear entre duas variáveis (BOSLAUGH; WATTERS, 2008).

O R de Pearson pode ser calculado como definido pela Equação 2 (LARSON; FARBER, 2016).

$$\rho = \frac{N \sum_{i=1}^n X_i Y_i - (\sum_{i=1}^n X_i \sum_{i=1}^n Y_i)}{\sqrt{[N \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2]} * \sqrt{[N \sum_{i=1}^n Y_i^2 - (\sum_{i=1}^n Y_i)^2]}} \quad (2)$$

onde:

$\rho$ : Coeficiente de Pearson;

$N$  = número de pares de dados;

$\sum_{i=1}^n X_i Y_i$  = soma dos produtos dos dados das séries  $X$  e  $Y$  pareados;

$\sum_{i=1}^n X_i$  = soma dos valores da série  $X$ ;

$\sum_{i=1}^n Y_i$  = soma dos valores da série  $Y$ ;

$\sum_{i=1}^n X_i^2$  = soma dos quadrados dos valores de  $X$ ;

$\sum_{i=1}^n Y_i^2$  = soma dos quadrados dos valores de  $Y$ .

O valor de R está sempre entre +1 e -1. Valores acima de 0 indicam uma relação positiva, ou seja, quando o valor de uma variável aumenta, o valor da outra que está correlacionada também aumenta. Valores abaixo de 0 indicam uma relação negativa, ou seja, quando um valor aumenta, o outro diminui. Quando R é 0, não há correlação entre as duas variáveis (BOSLAUGH; WATTERS, 2008). Para complementar, a sua complexidade é  $O(1)$ , o seu custo computacional é mais baixo que o do DTW e do  $R^2$  (BOSLAUGH; WATTERS,

2008).

### 3.1.3 Coeficiente de Determinação ( $R^2$ )

O Coeficiente de Determinação é uma medida estatística que examina como as diferenças em uma variável podem ser explicadas pela diferença em uma segunda variável, ao prever o resultado de um determinado evento. Em outras palavras, esse coeficiente avalia quão forte é a relação linear entre duas variáveis, sendo uma escolha frequente de pesquisadores que realizam análises de tendências (LARSON; FARBER, 2016).

O  $R^2$  é usado para explicar quanta variabilidade de um fator pode ser causada por sua relação com outro fator. Essa correlação, conhecida como “qualidade de ajuste”, varia no intervalo  $[0, 1]$ . Se  $R^2$  for igual a 1, há um ajuste perfeito e, portanto, o modelo é altamente confiável para previsões futuras. Caso o coeficiente seja 0, o modelo não corresponde com precisão aos dados. Porém, valores de 0,20 e 0,50, por exemplo, sugerem respectivamente que 20% e 50% da variável dependente é prevista pela variável independente. A complexidade de  $R^2$  é  $O(n)$ , ou seja, a medida é menos custosa que DTW, mas um pouco mais complexa que o R (WANG; JIANG; LIU, 2017).

O cálculo do  $R^2$  pode ser representado pela Equação 3 (LARSON; FARBER, 2016).

$$R^2 = 1 - \frac{RSS}{TSS} \quad (3)$$

onde:

RSS: soma residual dos quadrados (Equação 4);  
TSS: soma total dos quadrados (Equação 5);

$$RSS = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

$$TSS = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (5)$$

Onde:

$n$ : número de observações;

$y_i$ : valor observado;

$\hat{y}$ : valor estimado (previsão) de  $y_i$ ;

$\bar{y}$ : média das observações;

### 3.2 Ferramentas e Base de Dados Utilizadas

Neste trabalho foram utilizadas as seguintes ferramentas e base de dados:

- Computador com sistema operacional Windows 10, processador Intel i5, 8 GB de memória principal e disco rígido com capacidade de 1 Terabyte;
- Linguagem de programação Python (BORGES, 2014; LAMBERT, 2022);
- Ambiente de desenvolvimento integrado Spyder (SPYDER, 2021);
- Base de dados pública de séries temporais *Activity Recognition from Single Chest-Mounted Accelerometer* (CASALE, 2013) contendo dados de 15 indivíduos para sete movimentos ((1) caminhada; (2) trabalhando no computador; (3) em pé; (4) subindo/descendo escadas; (5) andar e falar com alguém; (6) falar enquanto está em pé e (7) em pé, andando e subindo/descendo escadas). Esses dados foram coletados a partir de um sensor acelerômetro posicionado no tórax dos indivíduos com frequência de amostragem de 52Hz. Neste trabalho foi considerado apenas o movimento de caminhada.

### 3.3 Configuração dos Experimentos

Uma Curva de Referência (CR) foi extraída contendo 60 amostras (pontos) da curva total de caminhada do indivíduo 12, localizadas do índice 263.059 ao 263.119. Esse indivíduo foi o escolhido para a extração da CR pois, dentre as 15 pessoas, ele apresentou a curva com a sazonalidade mais regular, ou seja, melhor visualização do movimento regular correspondente a aproximadamente dois passos da caminhada que se repete ao longo da série.

Essa CR foi comparada, utilizando as três medidas de similaridade – DTW,  $R^2$  e R, com as curvas obtidas de uma sequência completa de caminhada

considerando todos os indivíduos da base de dados, a fim de encontrar as dez curvas mais similares. Essa sequência completa contém 357.064 amostras e concatena os dados gerados a partir da marcha de todos os 15 indivíduos da base de dados. A comparação da CR foi realizada usando uma janela deslizante de tamanho 60 e avanço de um em um ponto sobre as 357.064 amostras para as três medidas de similaridade.

Esse processo foi analisado sob quatro cenários distintos:

1. E1: sem Normalização de Dados (ND) e sem Ajuste de Curva (AC);
2. E2: com ND pela técnica min-max (BORGES, 2014; LAMBERT, 2022) e sem AC;
3. E3: sem ND e com AC conforme modelo polinomial de grau cinco (CHATTERJEE; HADI, 2013);
4. E4: com ND e com AC.

Além disso, para padronização dos valores de similaridade, os resultados de DTW foram convertidos para o intervalo [0, 1] como definido pela Equação 6.

$$DTW' = 1 - \frac{DTW}{DTW_{max}} \quad (6)$$

onde:

*DTW*: valor da distância encontrada;

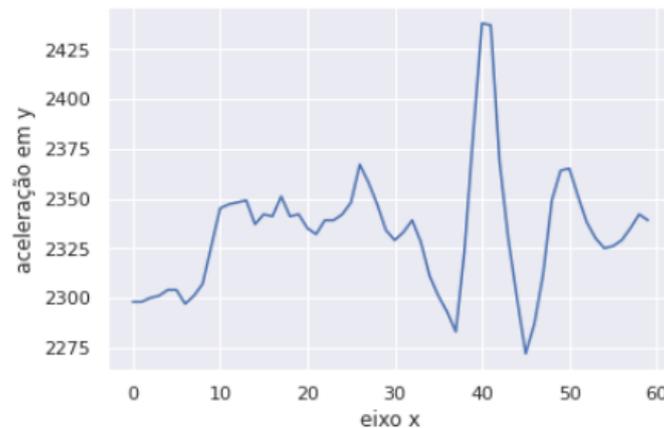
*DTW<sub>max</sub>*: valor máximo da distância retornada pelo DTW.

Ao fim dos experimentos, foram aplicados testes estatísticos descritivos e analíticos adequados para comparar o tempo de execução de DTW, R<sup>2</sup> e R.

#### 4. Resultados

Na Figura 1 é apresentada a CR usada nos experimentos.

Figura 1 – Curva de referência do movimento de caminhada



Na Tabela 1 estão apresentados os índices de curva (ID) que exibem o ponto onde inicia cada curva de comprimento igual a 60 pontos, recuperada por cada medida, e os valores de cada medida de similaridade em E1 para a recuperação das dez curvas mais similares à CR. As séries recuperadas foram ordenadas da mais à menos semelhante, conforme indicado na primeira coluna da tabela. Vale lembrar que  $R^2$  e  $R$  variam, respectivamente, nos intervalos  $[0, 1]$  e  $[-1, 1]$ , sendo que quanto mais próximo o coeficiente for de 1, maior é a similaridade entre as séries comparadas. Para fins de legibilidade e melhor comparação dos resultados, os valores de DTW foram convertidos para  $[0, 1]$  por meio da Equação 6.

Tabela 1 - Curvas recuperadas para E1

Ordem	ID	DTW	ID	$R^2$	ID	R
1	263.059	1,000	263.059	1,000	263.059	1,000
2	263.060	0,999	263.060	0,644	263.060	0,802
3	263.061	0,999	263.058	0,636	263.058	0,797
4	263.062	0,999	262.609	0,620	263.609	0,787
5	263.063	0,998	323	0,617	323	0,785
6	263.058	0,998	6.420	0,610	262.643	0,731
7	263.064	0,997	4.960	0,583	262.969	0,719
8	263.065	0,997	1.294	0,578	2.210	0,719
9	263.066	0,997	334.314	0,578	98.280	0,702
10	263.067	0,996	340.203	0,563	262.610	0,696

Na Tabela 2 são exibidos os tempos de execução médios de DTW,  $R^2$  e  $R$  em milissegundos (ms), com o seu respectivo desvio padrão (DP) (entre parênteses), calculado a partir das 10 curvas nos quatro cenários estudados.

Tabela 2 – Tempo de Execução

	DTW	R <sup>2</sup>	R
E1	0,805 (0,027)	0,176 (0,026)	0,122 (0,039)
E2	0,732 (0,016)	0,124 (0,028)	0,091 (0,016)
E3	1,071 (0,173)	0,159 (0,013)	0,106 (0,003)
E4	1,148 (0,303)	0,197 (0,051)	0,112 (0,016)
Média	0,939	0,164	0,108
DP	0,202	0,031	0,013

Como uma quantidade grande de figuras foi gerada, todas as curvas recuperadas e as tabelas com os resultados completos e testes estatísticos para E1, E2, E3 e E4 foram disponibilizadas no [link tinyurl.com/34dta5e2](http://link.tinyurl.com/34dta5e2).

Os resultados referentes aos tempos de execução foram analisados por meio do teste de Kruskal-Wallis, com intervalo de confiança de 95% e pós-teste de Tukey. Encontrou-se Diferença Estatisticamente Significativa (DES) entre os grupos, sendo visto que:

- Em E1 e E2, com exceção somente do caso R<sup>2</sup> vs R, ocorreram DES nas comparações do pós-teste, com DTW sendo sempre o algoritmo mais custoso computacionalmente nessas comparações;
- Em E3 e E4 ocorreram DES em todos os casos, sendo que em todas as comparações o DTW foi a medida mais lenta e R a mais rápida.

Os resultados de todas as comparações do pós-teste podem ser observadas no [link](#) citado anteriormente.

Nas Figuras 2 e 3 estão ilustradas, respectivamente, a segunda, a quarta e a décima ST mais similares à CR, recuperadas pelas três medidas para E1. Como exemplo, são representadas na Figura 2 a CR, a segunda (Figura 2 (a)) e a quarta curva (Figura 2 (b)) com maior semelhança a esse padrão conforme o algoritmo DTW e os coeficientes R<sup>2</sup> e o R de Pearson.

Já na Figura 3 está apresentada a CR e a décima curva recuperada como a mais similar pelas três medidas no E1. Como é possível observar, a décima curva mais similar resgata por R e R<sup>2</sup> é bastante dissimilar em comparação com a CR. Já o DTW manteve a décima curva recuperada bem próxima ao formato da CR.

Figura 2 – (a) segunda curva e (b) quarta curva mais similares para E1

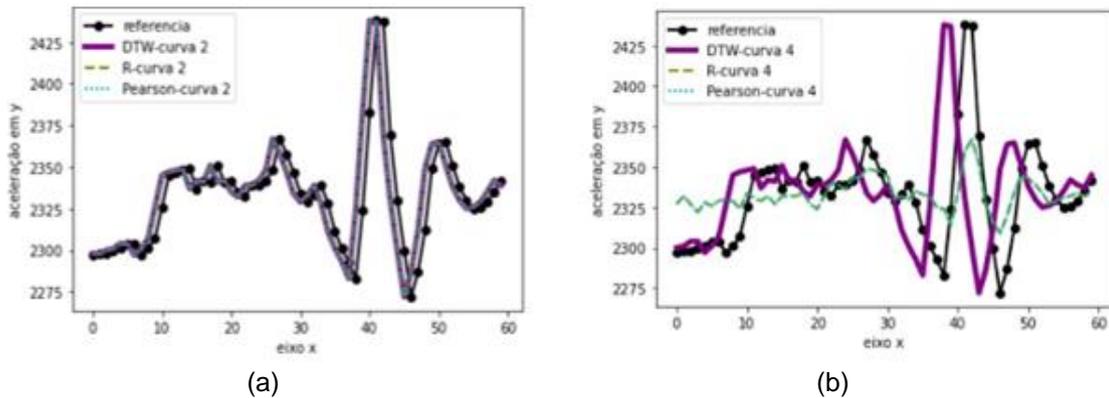
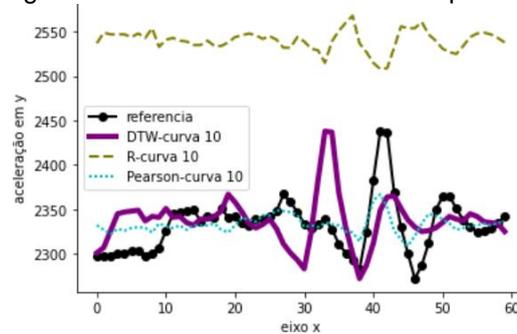


Figura 3 – Décima curva mais similar para E1



## 5. Discussão

A escolha das medidas DTW,  $R^2$  e R foi baseada na busca na literatura, a qual indicou que essas medidas figuram entre as mais utilizadas para comparação de ST e identificação de relação entre curvas e variáveis.

Como se pode notar na Tabela 1, todas as medidas recuperaram a ST com 100% de similaridade com início no ponto 263.059 da curva total, ou seja, a própria curva de referência. O mesmo ocorreu para os outros três cenários experimentais. Este é um aspecto importante, uma vez que as medidas devem ser capazes de recuperar corretamente, ao menos, a própria CR.

Em E1 e E2, os resultados foram semelhantes: até a terceira curva, as medidas recuperaram curvas mais similares à de referência. A partir da quarta sequência, os coeficientes  $R^2$  e R não resgataram séries tão similares à CR – vide Figura 2. Por outro lado, o algoritmo DTW seguiu obtendo séries similares nesses casos.

Os comportamentos verificados em E3 e E4 foram diferentes dos observados nos cenários anteriores: na recuperação da segunda curva, DTW

obteve uma curva com alta dissimilaridade em relação à de referência, enquanto  $R^2$  e  $R$  recuperaram curvas mais similares. Essa característica se manteve até a décima curva obtida.

De modo geral, a partir dos gráficos foi possível notar que as curvas retornadas por DTW foram melhores do que as obtidas pelos coeficientes somente nos experimentos em que não houve ajuste de curva.

Outra constatação é de que os valores de similaridade do DTW foram mais próximos de 1 do que  $R^2$  e  $R$ . Entretanto, isso não indica necessariamente que esse algoritmo foi superior aos outros dois. De fato, em alguns casos, os coeficientes conseguiram recuperar as mesmas curvas que o algoritmo DTW, a exemplo da segunda curva na Tabela 1. Assim, apesar da padronização dos índices, a comparação utilizando simplesmente este valor deve ser complementada com a análise das curvas em si. Esse aspecto deve ser melhor analisado em trabalhos futuros.

Em relação ao tempo médio de execução, DTW apresentou maior valor nos experimentos. Isso é esperado devido ao maior custo computacional teórico desse algoritmo em relação às outras medidas (BROWN; RABINER, 2003).

Essas constatações podem ser observadas no conjunto de imagens e tabelas disponibilizadas no *link* na seção de Resultados.

## 6. Conclusão

Neste trabalho foram pesquisadas, implementadas e analisadas três medidas para a comparação de curvas de movimentos do corpo: DTW,  $R^2$  e  $R$ .

Os experimentos demonstraram que, em relação à recuperação de curvas por similaridade, DTW foi superior apenas nos casos em que não houve ajuste de curva. Além disso, essa medida também apresentou o maior custo computacional em comparação com os dois coeficientes, como demonstrado pelo maior tempo de execução médio. Já  $R$  e  $R^2$  apresentaram desempenhos competitivos em todos os cenários para a recuperação das três curvas mais similares e com menor custo computacional. Desse modo, tanto DTW quanto  $R$  poderão ser incorporados ao sistema original em telemedicina SMMAR-T, o qual já contém  $R^2$ , para ser aplicadas conforme a necessidade do usuário.

Trabalhos futuros incluem realizar a comparação de séries utilizando o algoritmo *Symbolic Aggregate ApproXimation* (ZHANG et al., 2019) para a extração de características dessas sequências de observações e a aplicação de novos métodos de ajuste de curva.

### Financiamento

Beneficiária de auxílio financeiro da CAPES.

### Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

### REFERÊNCIAS

ARANI, M. S. A. et al. Human activity recognition: A comparative study to assess the contribution level of accelerometer, ECG, and PPG signals. **Sensors**, Brasília, v. 21, p. 21, 2021.

BERNDT, D.; CLIFFORD, J. Using dynamic time warping to find patterns in time series. In: WORKSHOP ON KNOWLEDGE DISCOVERY IN DATABASES, 1994, Seattle. **Anais**. Seattle: AAAI, 1994. p. 359–370.

BORGES, L. E. **Python para Desenvolvedores**. Rio de Janeiro: Novatec, 2014.

BOSLAUGH, S.; WATTERS, P. A. **Statistics in a Nutshell**. 2. ed. Sebastopol: O'Reilly Media, 2008.

BROWN, M.; RABINER, L. Dynamic time warping for isolated word recognition based on ordered graph searching techniques. In: IEEE INTERNATIONAL CONFERENCE ON ACOUSTIC, SPEECH, AND SIGNALS PROCESSING, 1982., 2003, Paris. **Anais**. Paris: IEEE, 2003. p. 1255–1258.

CASALE, P. UCI Machine Learning Repository: Activity Recognition from Single Chest-Mounted Accelerometer, 2013. Disponível em: <https://archive.ics.uci.edu/ml>. Acesso em: 28 mar. 2022.

CHATTERJEE, S; HADI, A. S. **Regression Analysis**. 5. ed. Hoboken: John Wiley & Sons, 2013.

CHEN, Z. et al. Robust human activity recognition using smartphone sensors via CT-PCA and online SVM. **IEEE Transactions on Industrial Informatics**, Nova Iorque, v. 13, n. 6, p. 317–318, 2017.

CORNACCHI, M et al. A survey on activity detection and classification using wearable sensors. **IEEE Sensors Journal**, Nova Iorque, v. 17, n. 17, p. 386–403, 2017.

ENSINA, L. A. **Sistema Computacional Web para o Monitoramento de Movimentos em Tempo Real**. 2020. Dissertação (Mestrado em Engenharia Elétrica e Computação) — Universidade Estadual do Oeste do Paraná, Foz do Iguaçu.

Ensina, L. A et al. Sistema computacional web para o monitoramento de movimentos em tempo real. **Journal of Health Informatics**, São Paulo, v. 12, 189-195, 2021.

FIGUEIRA, C.; MATIAS, R.; GAMBOA, H. Body location independent activity monitoring. In: INTERNATIONAL CONFERENCE ON BIO-INSPIRED SYSTEMS AND SIGNAL PROCESSING, 9., 2016, Roma. **Anais**. Roma: SCITEPRESS-Science and Technology Publications, 2016. p. 190–197.

HETLAND, M. L. A survey of recent methods for efficient retrieval of similar time sequences. In: LAST, M.; KANDEL, A.; BUNKE, H. (ed.). **Data Mining in Time Series Databases**. Londres: World Scientific, 2004. p. 23–42.

JIANG, Y.; LAN, D. Probability model of rock climbing recognition based on information fusion sensor time series. **EURASIP Journal on Advances in Signal Processing**, Nova Iorque, v. 2021, n. 109, 2021.

LAMBERT, K. A. **Fundamentos de python: Estruturas de dados**. São Paulo: Cengage Learning, 2022.

LARSON, R.; FARBER, B. **Estatística aplicada**. 6. ed. São Paulo: Pearson Education do Brasil, 2016.

LEE, J et al. A pilot study of activity recognition on rehabilitation exercise of frozen shoulder using wireless inertial sensor node. In: INTERNATIONAL SYMPOSIUM ON MEDICAL INFORMATION AND COMMUNICATION TECHNOLOGY, 7., 2013, Lincoln. **Simpósio**. Lincoln: IEEE, 2013. p. 117–120.

LEVENSHTAIN, V. I. Binary codes capable of correcting deletions, insertions, and reversals. In: DOKLADY AKADEMII NAUK, 1966, São Petersburgo. **Anais**. São Petersburgo: Soviet Physics Doklady, 1966. p. 845–848.

LI, Y.; WANG, L. Human activity recognition based on residual network and BiLSTM. **Sensors**, Basileia, v. 22, p. 2, 2022.

MACIEL, M. **Manutenção Evolutiva e Inclusão de Novas Funcionalidades em um Sistema de Monitoramento e Análise Remota de Movimentos do Corpo Humano**. 2021. Monografia de Conclusão de Curso (Graduação em Ciência da Computação) — Universidade Estadual do Oeste do Paraná, Foz do Iguaçu.

PETITJEAN, F.; KETTERLIN, A.; GANÇARSKI, P. A global averaging method for dynamic time warping, with applications to clustering. **Pattern Recognition**, Amsterdã, v. 44, p. 678–693, 2010.

QIU, S et al. Sensor combination selection strategy for kayak cycle phase segmentation based on body sensor networks. **IEEE Internet of Things Journal**, Nova lorque, v. 9, n. 6, p. 4190–4201, 2022.

RATANAMAHATANA, C.; KEOGH, E. Exact indexing of dynamic time warping. In: PROCEEDINGS OF SIAM INTERNATIONAL CONFERENCE ON DATA MINING, 2005, Londres. **Anais**. Londres: KAIS, 2005. p. 358–386.

SALVADOR, S.; CHAN, P. Toward accurate dynamic time warping in linear time and space. **Intelligent Data Analysis**, Amsterdã, v. 11, p. 561–580, 2007.

SIDDIQUE, N; ADELI, H. **Computational Intelligence**. Hoboken: John Wiley & Sons, 2013.

SPYDER. 2021. Disponível em: <https://www.spyder-ide.org/>. Acesso em: 05 maio. 2022.

WANG, X.; JIANG, B.; LIU, J. S. **Generalized R-squared for detecting dependence**. 3. ed. Londres: Biometrika, 2017.

WANG, Y.; CANG, S.; YU, H. A survey on wearable sensor modality centred human activity recognition in health care. **Expert Systems with Applications**, Nova lorque, v. 137, p. 167–190, 2019.

WU, F. C et al. **Método para monitorar e analisar movimentos de articulações e de partes do corpo**. Patente BR 10 2019 015290 7. Instituto Nacional da Propriedade Industrial, 2019.

XU, J.; HE, Z.; ZHANG, Y. CNN-LSTM combined network for IoT enabled fall detection applications. **Journal of Physics: Conference Series**, Brisol, v. 1267, p. 25–27, 2019.

YOSHIHI, M et al. Stimating sleep stages using a head acceleration sensor. **Sensors**, Basileia, v. 21, p. 3, 2021.

ZHANG, C. K et al. Anomaly detection in ECG based on trend symbolic aggregate approximation. **Mathematical Biosciences and Engineering**, Springfield, v. 16, p. 2154-2167, 2019.

ZHAO, Y et al. Deep residual Bidir-LSTM for human activity recognition using wearable sensors. **Mathematical Problems in Engineering**, Nova lorque, p. 1–3, 2018.