

Reconhecimento de padrões de manobras de skate

Bruno Adriano Menegotto

*Departamento Acadêmico de Engenharia Elétrica
Universidade Tecnológica Federal do Paraná
Ponta Grossa, Brasil
brunomenegotto@alunos.utfpr.edu.br*

Cristiellen Heuko da Silva

*Departamento Acadêmico de Engenharia Elétrica
Universidade Tecnológica Federal do Paraná
Ponta Grossa, Brasil
cristiellensilva@alunos.utfpr.edu.br*

Hugo Valadares Siqueira

*Departamento Acadêmico de Engenharia Elétrica
Universidade Tecnológica Federal do Paraná
Ponta Grossa, Brasil
hugosiqueira@utfpr.edu.br*

Sergio L. Stevan Jr.

*Departamento Acadêmico de Engenharia Elétrica
Universidade Tecnológica Federal do Paraná
Ponta Grossa, Brasil
sstevanjr@utfpr.edu.br*

Resumo—O skate é um esporte baseado em manobras, as quais são avaliadas por imagem ou jurados que classificam a dificuldade e perfeição do movimento. Buscando auxiliar este processo de monitoramento da manobra, uma base de dados obtida a partir de manobras realizadas com um skate instrumentado com sensores inerciais foi utilizada para avaliar o reconhecimento de padrões através de redes neurais artificiais (RNAs) e classificadores. Nesta perspectiva, foram realizadas etapas de pré-processamento para normalizar e segmentar os dados. Posteriormente 4 diferentes arquiteturas de RNAs foram utilizadas e os desempenhos avaliados e comparados: Perceptron de Múltiplas Camadas (MLP), Máquina de Aprendizado Extremo (ELM), Rede Neural com Função de Base Radial (RBF) e uma rede recorrente, *Long Short-Term Memory* (LSTM). Além disso, utilizou-se dois classificadores baseados em aprendizado de máquina, sendo estes: *Random Forest* (RF) e *Regressão Logística* (LR). O melhor resultado obtido foi para a rede MLP, a qual indicou 95% de acurácia.

Index Terms—Instrumentação, skate, classificação, redes neurais.

I. INTRODUÇÃO

A busca por melhoria no desempenho em esportes é sempre desejada, atletas de alto nível estão em constante busca por novos equipamentos e técnicas que permitam o aumento do rendimento e resultados promissores [1]. Analogamente, os sensores sofreram grandes avanços nos últimos tempos e podem ser grandes aliados de diversos segmentos, dentre eles a ciência biomédica e mais precisamente a esportiva. Por fornecerem uma análise mais precisa de atividades, o sensoriamento inercial é, indubitavelmente, essencial nos dias de hoje, compondo sistemas como os de GPS (*Global Positioning System* - Sistema de Posicionamento Global), navegação e captura de movimentos [2].

O skate, anteriormente um equipamento usado para o entretenimento, hoje em dia é uma modalidade olímpica, sendo adicionado à lista esportiva dos jogos olímpicos em 2020 [3]. Entretanto, como a maioria dos esportes de estilo livre, os atletas de skate lidam com uma grande subjetividade para avaliação de manobras, visto que dependem dos juízes. Uma forma de minimizar os erros, seria fazer a cobertura da

competição por câmeras, porém isso seria de alto custo [4]. De forma similar, o uso de sensores para monitoramento, seria uma alternativa mais viável de análise de desempenho [5]. Dessa maneira, é evidente o potencial de unir o skate aos sensores, visto que podem ser aliados de jurados em competições, trazendo maior assertividade das notas [6].

Além disso, outro fator significativo, é a falta de conhecimento de elementos básicos do skate por aqueles que o praticam, o que acaba resultando em cerca de 33% dos iniciantes lesionados. Isso demonstra ainda mais, o quanto o método científico aliado a busca pelo conhecimento é imprescindível [7].

A instrumentação do skate pode ser realizada por meio de sensores inerciais, cujo custo de aquisição é baixo, e ainda fornecem dados para mensurar as manobras do skate, o que permite uma avaliação em tempo real [5]. Para o julgamento das manobras, é realizada apenas a análise de vídeo, usando como base a pesquisa que antecede a deste trabalho, que desenvolveu um protótipo para as aquisições das manobras realizadas no skate, usando sensores inerciais.

Nesta perspectiva, Groh et al. [5] apresentou em 2015, um sistema baseado em um sensor inercial instalado junto ao eixo frontal do skate, com o objetivo de identificação de 6 manobras de skate (*Ollie*, *Nollie*, *Kickflip*, *Heelflip*, *Pop Shove-it* e *360-Flip*). Sete voluntários realizaram as 6 manobras 5 vezes cada. Foram testados 5 classificadores: *Naive Bayes* (NB), *Partial Decision Tree* (PART), *Support Vector Machine* (SVM) e *k-nearest neighbor* (k-NN). NB e SVM obtiveram as melhores taxas de acurácia com resultados superiores a 97%.

De forma análoga, M. Abdullah et al. [6] apresentou em 2019 um sistema com 1 sensor inercial para a identificação de 5 manobras de skate (*Ollie*, *Kickflip*, *Shove-it*, *Nollie* e *Frontside 180*), as quais foram executadas 5 vezes por um único voluntário. Foram utilizados 5 classificadores (*Support Vector Machine*, k-NN, *Artificial Neural Networks* (ANN), *Logistic Regression*, *Random Forest* and *Naive Bayes* para os quais, LR e NB obtiveram resultados superiores a 95% de acurácia, seguidos de ANN e SVM com 90% e RF com 85%

e k-NN com 75%.

Foram realizadas análises dos dados adquiridos por dois sensores, instalados simetricamente, diferentemente dos trabalhos pesquisados, que utilizaram somente um sensor para obtenção do sinal. A análise foi realizada levando em consideração a atuação dos dois sensores concomitantemente e o seu desempenho individual, analisando se haveria ganho com a utilização de mais de um sensor. A partir disso, efetuou-se uma classificação das manobras executadas com base nos dados dos sensores, organizando uma segmentação do sinal adquirido, a extração de características destes sinais e posteriormente, a utilização de redes neurais para classificá-los.

Este trabalho está organizado como segue: a presente seção I trata da introdução; a seção II apresenta a aquisição dos dados; a III faz referência à segmentação dos dados; a IV mostra o processo de extração de característica; a V trata das Redes Neurais utilizadas e dos classificadores utilizados para comparação com as redes neurais; a VI demonstra os procedimentos e técnicas; a VII apresenta os resultados e VIII mostra a conclusão.

II. AQUISIÇÃO DOS DADOS

A obtenção dos dados cinéticos do skate durante a execução das manobras, contou com dois sensores inerciais MPU9250 que apresentam um acelerômetro e giroscópio MPU-6500. A escolha deste inercial foi pelo motivo de possuir uma dimensão física pequena e fácil manipulação.

O microcontrolador utilizado para a aquisição dos sinais inerciais, foi o ESP-01 [8]. A escolha deste microcontrolador foi pelo fato de já possuir um módulo *WiFi* integrado e ter uma dimensão física pequena, o que facilita na instalação do equipamento no skate. Os dados foram transmitidos via *WiFi* do dispositivo microcontrolador, sendo armazenados utilizando o software MATLAB™ no computador. A Figura 1 apresenta a instalação dos dois sensores inerciais, nos dois eixos do skate, e a central da aquisição dos dados no centro do skate.



Figura 1. Esquema da instrumentação do skate, considerando a fixação dos sensores em posições simétricas próximas aos eixos em uma linha longitudinal central.

Os sensores inerciais foram posicionados de forma simétrica, em um linha longitudinal média, junto à base dos eixos (Figura 1) e uma central com o microcontrolador e bateria para realizar a aquisição e transmissão dos dados é alocada no centro da plataforma apenas para este protótipo e avaliação dos dois sensores.

Foi monitorada a execução de três manobras: *ollie*, *nollie* e *backside 180*; para as quais foram realizadas 10 repetições de cada, com taxa de aquisição dados de 100 Hz. As manobras estão ilustradas na Figura 2.

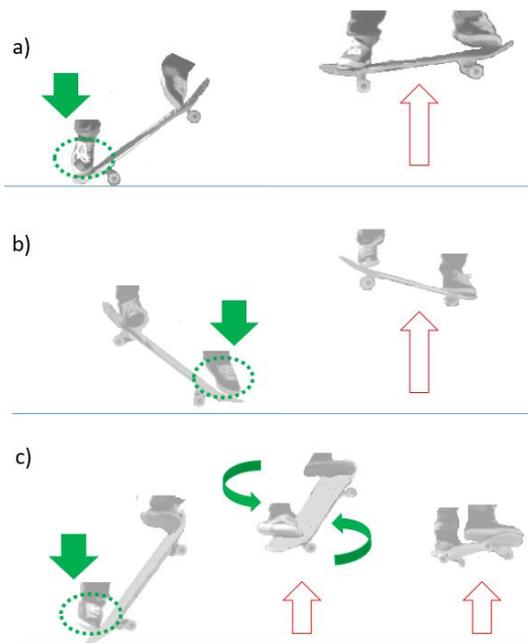


Figura 2. Manobras do skate. a) *ollie*; b) *nollie*; c) *backside 180*

A manobra *backside 180* consiste basicamente em girar o skate e o corpo 180° na direção das costas. Já a manobra *nollie* o skatista bate no *nose* (parte da frente do skate) para o *tail* (parte de trás do skate) para que o mesmo seja levantado do chão, no ar o pé deve ser deslizado para o *tail* até que o *shape* fique na horizontal e volte a tocar no solo. Agora para a manobra *ollie*, o processo é o mesmo da manobra *nollie*, porém ao invés de iniciada no *nose*, o skatista bate a parte do *tail* no chão e o processo é o mesmo.

O uso de dois sensores para obtenção dos dados tem por objetivo permitir análises mais abrangentes sobre a influência da posição de fixação individual do sensor (frente ou atrás) e também conjunta deles na classificação das manobras.

III. SEGMENTAÇÃO

O processo de segmentação basicamente consiste em separar os intervalos de aquisição para que o sinal possa ter suas características extraídas. Esse processo é normalmente utilizado em sequência a um pós processamento. A etapa consiste em extrair o segmento adequado para que seja retirada as características, e implementadas nas entradas de um classificador [9].

A segmentação consiste em calcular a diferença absoluta entre valores de amostras consecutivas de um determinado sinal, em busca de um limiar (*threshold*), que permita indicar a diferença entre ruído e a efetiva execução da manobra. Assim é possível determinar o início de um movimento *onset* e o término de um movimento *offset*. Porém o processo de

segmentação do sinal não é um processo simples de ser efetuado, pois cada movimento realizado pode ter durações diferentes, então para determinar o início e o término do sinal, em alguns casos, não é uma tarefa trivial [10].

IV. EXTRAÇÃO DE CARACTERÍSTICAS

Características ou atributos são informações de um conjunto (trecho) de dados obtidas através de equações matemáticas, com o objetivo de reduzir a quantidade de dados para os classificadores. As informações fornecidas pelas características, são comumente divididas em dois grupos: domínio do tempo e domínio da frequência [11], [12].

Dentre várias, pode-se citar: AAC, DASDV, MAV, RMS, SSI e IAV, todas do domínio do tempo.

A. Average Amplitude Change - AAC

O seu valor calculado é definido como a média do tamanho cumulativo da forma de onda do sinal em um determinado segmento [11]. Seu valor é calculado através da equação 1:

$$AAC = \frac{1}{N} \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (1)$$

em que x_i representa o valor do sinal em um segmento i e N representa o tamanho deste sinal.

B. Difference Absolute Standard Deviation Value - DASDV

O valor calculado é o desvio padrão do comprimento de onda do sinal. Este valor é calculado através do desvio padrão da diferença entre as amostras adjacentes, através da equação 2:

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} - x_i)^2} \quad (2)$$

em que x_i representa o valor do sinal em um segmento i e N representa o tamanho deste sinal.

C. Mean Absolute Value - MAV

O valor é calculado através da detecção do ponto de disparo do sinal. É calculado através da média do valor absoluto do sinal, através da equação 3:

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (3)$$

em que x_i representa o valor do sinal em um segmento i e N representa o tamanho deste sinal.

D. Root Mean Square - RMS

Esta característica está relacionada com a "força" do sinal, sendo modelada em alguns casos como um processo aleatório gaussiano de amplitude modulada. É calculado através da raiz quadrada dos quadrado médio do sinal, através da equação 4:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4)$$

onde x_i representa o valor do sinal em um segmento i e N representa o tamanho deste sinal.

E. Simple Square Integral - SSI

É utilizada para definir como um índice utilizado para analisar a potência proveniente em um sinal, sendo obtida através da soma dos valores quadrados, através da equação 5:

$$SSI = \sum_{i=1}^N x_i^2 \quad (5)$$

em que x_i representa o valor do sinal em um segmento i e N representa o tamanho deste sinal.

F. Integral of Absolute Value - IAV

É utilizado para estimar a intensidade do sinal. Esta característica é utilizada normalmente em sinais com aparência ruidosa e estocástica [13]. O valor é calculado através da soma de todos os valores absolutos da amplitude do sinal em um segmento, apresentada na equação 6:

$$IAV = \sum_{i=1}^N |x_i| \quad (6)$$

onde x_i representa o valor do sinal em um segmento i e N representa o tamanho deste sinal.

V. CLASSIFICADORES

Foram utilizados neste trabalho Redes Neurais Artificiais (RNAs) e os classificadores RF (Random Forest - Floresta de Decisão Aleatória) e LR (*Logistic Regression* - Regressão Logística).

As RNAs são uma importante ferramenta dentro da inteligência artificial, assim como no aprendizado de máquina. Com os avanços dos últimos anos, tornaram-se uma grande aliada na solução de problemas de classificações, previsões e reconhecimento de padrões [14].

Diante da sua popularização, as RNAs passaram por diversas melhorias, advieram de um único Perceptron capaz de resolver apenas problemas lineares, resultando em redes robustas e altamente capazes de solucionar questões complexas [14], [15].

São exemplos de arquiteturas de RNAs: MLP (*Multilayer Perceptron* - Perceptron de Múltiplas Camadas), ELM (*Extreme Learning Machine* - Máquina de Aprendizado Extremo), e LSTM (*Long Short-Term Memory* - Redes de Memória de Longo e Curto Prazo).

Em relação aos demais classificadores, LR e RF, são algoritmos de aprendizado de máquina amplamente utilizados, capazes de resolver problemas de classificação e análise de dados [16], [17].

A. Perceptron de Múltiplas Camadas (MLP)

A rede neural Perceptron de Múltiplas Camadas (MLP) tem como característica principal, a presença de pelo menos uma camada escondida entre a camada de entrada e a de saída [14], [18]. Além disso, a MLP é caracterizada por realizar o ajuste dos pesos sinápticos utilizando majoritariamente o algoritmo *backpropagation* cujo método consiste em dividir o treinamento em duas fases:

- *forward*: nesta fase, os pesos sinápticos são fixos e o sinal se propaga pela rede, percorrendo-a cada camada até a saída;
- *backward*: já aqui, um sinal de erro é produzido pela comparação entre a saída obtida e a desejada, o gradiente da função de erro é calculado e utilizado para definir o nível de ajuste dos pesos dos neurônios [15] levando a uma queda no erro de saída.

Uma MLP possui uma alta versatilidade podendo ser um aproximador universal de funções. Deste modo, é aplicada em reconhecimento de padrões, previsão de séries temporais, otimização de sistemas, dentre outros [19].

B. Máquina de Aprendizado Extremo (ELM)

As Máquinas de Aprendizado Extremo foram desenvolvidas para trabalhar com alta eficiência, buscando um processamento menor do que das MLPs [20]. Deste modo, fica evidente que ambas possuem uma grande similaridade, podendo ser capazes de aproximar qualquer função contínua, não-linear e diferenciável [21].

No que diz respeito às diferenças entre ELM e MLP, pode-se afirmar que elas estão contidas essencialmente no processo de aprendizagem, visto que esta possui métodos de otimização para geração e ajuste de pesos e aquela possui pesos gerados de maneira aleatória na camada intermediária, não havendo os ajustes dos mesmos antes da saída [22]. Dessa maneira, o processo de ajuste se resume a encontrar os pesos da camada de saída por meio de soluções do tipo fórmula fechada com utilizar a pseudo-inversa de Moore-Penrose [23].

C. Rede Long Short-Term Memory (LSTM)

A rede LSTM foi proposta em 1997 por Hochreiter e Schmidhuber, e tinha como objetivo utilizar uma rede neural que aprende a armazenar informações em intervalos de tempo prolongados, por meio de retro-propagação recorrente, o que na época levava muito tempo para processar. A estrutura da rede LSTM é composta por portões multiplicativos que aprendem a abrir e fechar o acesso ao fluxo de erro constante [24].

A componente de memória da rede LSTM é chamada de célula de memória, o que basicamente indica quando se realiza uma cópia de um intervalo de tempo para outro. As novas informações são acrescentadas na memória e são atualizadas. Dessa maneira as expressões do gradiente não se acumulam ao longo do tempo [25]. As unidades de chaveamento ou portões são vetores que controlam o fluxo das informações da LSTM por meio da multiplicação de cada elemento do vetor de informações correspondente, como a seguir [26]:

- Porta de esquecimento: decide se cada elemento da célula de memória será lembrado ou apagado;
- Porta de entrada: decide quando atualizar cada elemento da célula de memória, com os novos valores de entrada;
- Porta de saída: decide quando elemento da célula de memória será transferido para memória de curto prazo.

D. Rede Neural com Função de Base Radial (RBF)

A Rede Neural com Função de Base Radial é uma estrutura em que as entradas de informação da rede são inseridas na camada intermediária única que contém as funções de ativação de base radial, destacando o uso da função Gaussiana, além de uma camada de saída linear [27], [28]. Em relação ao seu treinamento, a RBF realiza-o de maneira não supervisionada na camada intermediária por meio de métodos de *clustering*. A camada de saída é ajustada, por exemplo, utilizando o tradicional *backpropagation* [14].

No que diz respeito ao processamento desta rede, algumas pesquisas ressaltam a sua rapidez para o aprendizado. Entretanto, a rede ainda não se mostra tão eficaz para lidar com valores constantes e padrões de treinamento com erro, fazendo com que a RBF interpole erroneamente [29]. Apesar desses problemas, também é um aproximador universal de funções capaz de realizar classificação de padrões, sendo considerada robusta para lidar com *outliers* [14], [30].

E. Random Forest (RF)

Uma árvore de decisão representa uma determinada função que recebe um vetor de entradas e retorna um valor único na saída, uma "decisão". Esta alcança sua saída realizando uma sequência de testes, começando na raiz e seguindo o ramo apropriado até alcançar uma folha [26].

O modelo de *Random Forest* é uma árvore de decisão em que são executadas etapas extras para tornar o conjunto de K árvores mais diversificada e reduzir a variância. O principal objetivo é variar aleatoriamente as "escolhas de atributos". Cada ponto de divisão, na hora de construir a árvore, seleciona uma amostra aleatoriamente de atributos e então, calcula-se qual deles gera o melhor resultado de ganho de informação [26], [31].

F. Logistic Regression (LR)

A *Logistic Regression* é um método de classificação mais eficiente para problemas binários e lineares simples, porém é possível utilizar em modelos com multi-classe. Por ser de fácil implementação é um modelo amplamente empregado para a classificação de dados [32].

Dessa forma, pode-se definir a LR como um modelo estatístico costumeiramente usado para classificação e análise preditiva. A regressão logística estima a probabilidade de uma determinada ocorrência de um evento, com base no conjunto de dados de variáveis independentes [33].

G. Métricas de avaliação

Para se avaliar o resultado dos classificadores, um figura de mérito é comumente utilizada [34]: acurácia. Como o tamanho de cada classe é o mesmo, então ao utilizar o cálculo da acurácia, não se tem a limitação da métrica, pois o conjunto de dados esta balanceado de forma que cada classe uma das 3 classes apresenta-se com 10 repetições cada. Além disso a acurácia permite que seja possível realizar uma comparação direta de diferentes modelos de classificação, em que um modelo com uma acurácia mais alta geralmente é considerado mais indicada em termos gerais de classificação.

VI. METODOLOGIA

O procedimento metodológico pode ser resumido em etapas de instrumentação do skate, definição do protocolo experimental (manobras), aquisição de sinais, pré-processamento dos dados e aplicação de classificadores. As etapas de instrumentação, definição das manobras e procedimento experimental foram realizadas anteriormente [35], no qual apresentou-se um sistema com dois sensores inerciais para a aquisição dos dados e foram aquisitados dados de 3 manobras. Baseado nos dados anteriormente obtidos, este trabalho teve como objetivo avaliar um novo procedimento de processamento de dados e a aplicação de vários classificadores, além de analisar a importância do uso de mais de 1 sensor. A Figura 3 ilustra um resumo das etapas realizadas, sendo as duas primeiras por [35].

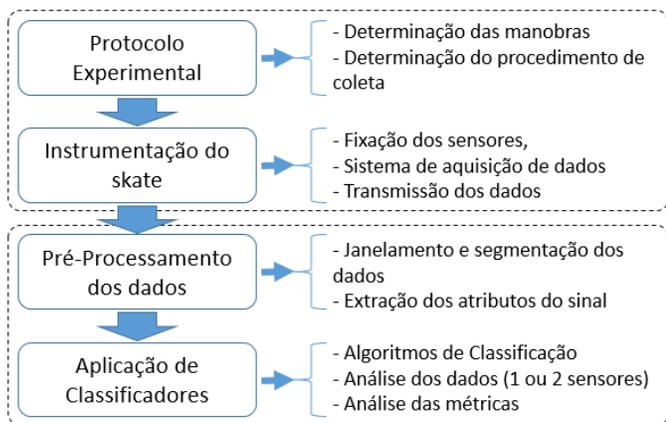


Figura 3. Fluxograma do projeto da classificação das manobras de skate.

A utilização dos dois sensores foi avaliada para analisar se poderia haver a melhoria da obtenção dos dados, ou aprimoramento no conjunto de dados obtidos de modo a obter-se melhores resultados na classificação das manobras.

Para ilustrar a característica dos sinais, a Figura 4 ilustra um trecho de dados dos dois sensores inerciais em cada uma das manobras realizadas, onde se pode observar na legenda "AC", representando o acelerômetro e o "GY", o giroscópio. Como cada módulo inercial apresenta 6 graus de liberdade (3 do acelerômetro e 3 do giroscópio), como pode-se observar na legenda da 4.

A base de dados com as manobras do skate utilizada possui 1000 amostras contendo informações dos dois módulos inerciais, ou seja, 1000x12 dados por instante amostrado. Cada uma das 3 manobras foi realizada 10 vezes, totalizando 30 manobras coletadas e uma base de 1000x12x30 dados.

A partir disso, foi realizado o processo de segmentação dos sinais, com o objetivo de ter uma janela com o movimento (manobra) do skate. Após a segmentação foi realizada a extração de característica (atributos) e, por fim, a classificação dos movimentos.

O pré-processamento realizado constituiu uma etapa de janelamento dos dados e posterior normalização dos dados

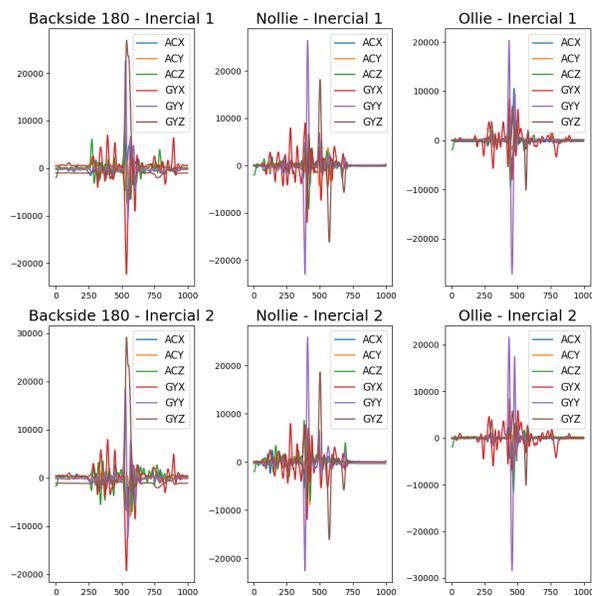


Figura 4. Exemplos de sinais aquisitados das manobras realizadas no skate.

de uma manobra para todos os eixos. Para o presente trabalho foram utilizadas 6 equações para a extração das características no domínio do tempo sendo essas: AAC, DASDV, MAV, RMS, SSI e IAV. Estas características foram escolhidas com base em um trabalho passado utilizando as aquisições das manobras do skate [35].

Sobre os classificadores, para as redes MLP e LSTM foi utilizada a plataforma de *Machine Learning* - (Aprendizado de Máquina) da *Google* o *Tensorflow*, sendo utilizada a biblioteca Keras, diferentemente da rede ELM e a RBF. Quatro diferentes arquiteturas foram utilizadas. A rede MLP é uma rede tradicional para realizar a classificação com ajuste dos pesos sinápticos a cada iteração, a rede RBF é parecida com a rede MLP sendo diferente no modo em que ocorre o treinamento, a rede ELM é uma rede de aprendizado extremo que ajusta os pesos sinápticos com apenas uma iteração e a rede LSTM é uma rede recorrente, fortemente indicada para dados com série temporal.

Embora os dados adquiridos apresentam-se com uma componente temporal, com o processo de segmentação e extração de característica retirou-se esta componente de tempo. Como forma de analisar o comportamento da classificação dos dados, optou-se por estas quatro redes neurais.

Além da utilização das redes neurais para a classificação dos dados, foi realizado também a utilização de classificadores RF e LR, para comparar os resultados desses com os resultados das redes neurais. Ambos foram implementados utilizando a biblioteca *Scikit Learn*, optou-se por utilizar essa biblioteca, pela facilidade de implementação e também por possuir exemplos práticos na linguagem de programação *Python*.

Neste trabalho, foram utilizados 4 classificadores: MLP, RBF, ELM e LSTM com três camadas básicas (entrada, intermediária e saída), para a estrutura das redes optou-se

por utilizar uma camada intermediária e a função de ativação tangente hiperbólica. A escolha pela função de ativação tangente hiperbólica foi pelo fato que no projeto da rede neural, utilizou-se uma normalização dos dados entre -1 e 1.

Na execução das redes neurais, foi realizada uma varredura da quantidade de neurônios na camada intermediária, variando os valores entre 72, 82, 92 e 102 neurônios, com o intuito de determinar qual seria a melhor configuração para classificar as manobras no skate. O processo de varredura para a rede RBF foi utilizada com o mesmo processo e com os mesmos valores, para serem utilizados no cálculo da base radial, porém foram divididos por 100, pois invés de ser varredura no número de neurônios é uma varredura no valor de sigma (σ). Na RF foi realizado o mesmo processo de varredura com os mesmos valores, para determinar a quantidade de árvores que compreenderia os melhores resultados para a classificação, também se fixou uma profundidade da árvore como 5, para todas as árvores.

Ao utilizar a plataforma *Tensorflow* com a biblioteca *Keras*, é possível implementar as redes neurais com a separação dos dados para treinamento, validação e teste, neste caso foi dividido em 60% dos dados para o treinamento, 20% para a validação e 20% para o teste. No que diz respeito ao otimizador, foi utilizado o *Adam*, com no máximo 115 iterações.

Para a rede ELM e RBF a abordagem dos dados foi diferente, pois na maneira como a rede foi implementada, ela não apresenta validação, então foi realizada uma distribuição dos dados, diferente das outras duas redes, com 80% dos dados para o treinamento e 20% dos dados para o teste. Para os classificadores RF e LR foi utilizada a mesma proporção na seleção dos dados para o treinamento e para o teste, com os valores 80% para o treinamento e 20% para o teste. A escolha se deu com o intuito de ficar com o mesmo número de dados para os cinco classificadores, sendo justo na análise final na comparação dos resultados.

Dessa maneira as implementações dos classificadores em alguns casos tiveram que serem adaptados, por conta da metodologia empregada nos mesmos, sendo assim as redes neurais com a utilização da biblioteca *Keras*, tiveram a implementação com a mesma estrutura na distribuição dos dados no treinamento e no teste, as redes neurais ELM e RBF tiveram a mesma estrutura na distribuição dos dados, e os classificadores com a biblioteca *Scikit Learn* tiveram também a mesma estrutura na distribuição.

Foram realizadas 3 abordagens diferentes com os dados coletados: com os dados dos dois módulos inerciais; com os dados apenas do módulo inercial frontal (IMU1); e com os dados apenas do módulo inercial traseiro (IMU2). Essas análises foram realizadas para analisar o impacto no posicionamento dos sensores e a influência de cada inercial na aquisição das manobras.

VII. RESULTADOS

Os resultados obtidos com os classificadores estão apresentados nas Tabelas I a III. Nelas, estão indicados os classi-

ficadores utilizados, a melhor taxa de acurácia obtida em 10 rodadas de avaliação realizadas. A Tabela I ilustra os valores para o sensor inercial frontal.

Tabela I
MÉDIA DOS MELHORES RESULTADOS DA CLASSIFICAÇÃO DO MÓDULO INERCIAL FRONTAL.

Classificador	Acurácia
MLP	95.00%
ELM	88.33%
LR	84.90%
RF	83.00%
RBF	79.67%
LSTM	60.00%

Os resultados apresentados permitem observar que a rede neural MLP apresentou-se com a maior acurácia no teste da classificação das manobras, com 95%, seguida da ELM, LR, RF, RBF e LSTM. Nota-se que as redes neurais MLP e ELM conseguiram classificar de forma adequada as manobras, já os classificadores LR e RF e a rede RBF, não alcançaram acurácias satisfatórias na classificação de manobras.

A Tabela II ilustra os resultados dos classificadores com o sensor inercial traseiro (IMU2).

Tabela II
MÉDIA DOS MELHORES RESULTADOS DA CLASSIFICAÇÃO DO MÓDULO INERCIAL TRASEIRO (IMU2).

Classificador	Acurácia
MLP	85.00%
LR	83.10%
RF	80.00%
ELM	78.33%
LSTM	58.33%
RBF	58.33%

Na Tabela II nota-se que a rede MLP foi a que apresentou maior acurácia na classificação das manobras, porém abaixo das taxas obtidas com o IMU1, seguidos da LR, RF, ELM, LSTM e RBF. Para o IMU2, os classificadores LR e RF obtiveram erros menores do que para o sensor inercial IMU1, conseguindo classificar as manobras com taxas superiores a 80%.

A Tabela III apresenta os resultados da classificação com a utilização dos dois sensores inerciais.

Tabela III
MÉDIA DOS MELHORES RESULTADOS DA CLASSIFICAÇÃO COM OS DOIS MÓDULOS INERCIAIS.

Classificador	Acurácia
MLP	91.66%
LR	88.20%
ELM	83.33%
RF	81.40%
RBF	78.33%
LSTM	53.33%

Na Tabela III nota-se que a rede MLP obteve melhor acurácias obtendo 91.66%, seguida da LR, ELM, RF, RBF e LSTM. Os classificadores LR, ELM e RF apresentaram acurácias superiores a 80%.

Nesta perspectiva o sensor instalado na região frontal do skate apresenta-se com resultados de acurácia melhor que o sensor instalado na região traseira, por possíveis dois motivos: a primeira o próprio posicionamento do sensor teve uma influência na aquisição dos dados e dessa maneira influenciou no resultado do classificador; a segunda o próprio método de realização das manobras, pois realizando as manobras com pessoas destra ou canhotas pode ter influenciado, por conta do lado mais confortável de cada pessoa.

Verificou-se o fato da acurácia relacionada ao uso dos dois sensores inerciais não apresentou incremento de acurácia com relação ao melhor caso de análise individual, apontando a influência da posição dos sensores. Como os sensores foram instalados em posições simétricas próximas aos eixos em uma linha longitudinal central, sabe-se que o reposicionamento dos mesmos sob o eixo para evitar danos ao sistema de aquisição vai influenciar nas taxas de acurácia, exigindo análises experimentais mais minuciosas.

É possível notar que a rede MLP apresentou os melhores resultados na classificação, possivelmente pela rede ajustar os pesos em cada iteração, tornando-a mais precisa. Outro fator é que a rede ELM não treina a camada intermediária, já sobre a rede RBF, o processo de treinamento da camada intermediária é de forma não supervisionada, o que pode ter diminuído a precisão e a rede LSTM, por sua vez, é uma rede recorrente, mais indicada para previsão. Os classificadores, analogamente, não são os mais indicados para a solução de um problema como o apresentado, assim os resultados da MLP se destacaram dentre os demais.

VIII. CONCLUSÃO

Uma base de dados de dois sensores inerciais fixados em um skate foi utilizada para avaliar o desempenho de seis classificadores (MLP, ELM, LR, RF, RBF e LSTM) e analisar a contribuição de 2 sensores simetricamente instalados e suas posições. Os resultados apresentados apontaram acurácias de até 95%, permitindo concluir que sistemas baseados em sensores inerciais podem ser promissores para análises de classificação de movimentos como manobras de skatistas.

Adicionalmente, verificou-se que a posição do sensor (frente ou trás) interfere nos procedimentos de classificação, pois ao analisar os sensores de forma isoladamente os dados obtidos no instalado na parte frontal apresentaram melhor desempenho que o instalado na parte traseira. Ainda, análises com ambos os sensores também apresentaram dados de acurácia inferiores aos obtidos somente com o sensor frontal. Note que o desenvolvimento de um sistema sob os eixos evitará danos aos sensores e a central, a qual só foi instalada no centro do skate para avaliação inicial de 2 sensores concomitantes.

Como trabalhos futuros, esta pesquisa pode ser incrementada realizando a aquisição de mais manobras e também de mais voluntários, permitindo uma base de dados maior e proporcionando estudos mais robustos tanto dos atributos extraídos dos sinais, como análises mais profundas dos parâmetros dos classificadores. Outros fatores importantes, são: o estudo de métodos diferentes da segmentação do

sinal captado pelos inerciais; uso de outros métodos de classificação; e uma verificação mais cautelosa do posicionamento do sensor no skate e suas consequências.

REFERÊNCIAS

- [1] L. Katz, "Inovações na tecnologia esportiva: implicações para o futuro," *Revista Educação Física*, no. 3, pp. 27–32, 2002.
- [2] N. K. Corrêa et al., "Classificação de manobras de skate através de acelerometria e redes neurais artificiais," 2017.
- [3] D. A. Kyriopoulos, "Skate-da proibição às olimpíadas," 2019.
- [4] S. Barris and C. Button, "A review of vision-based motion analysis in sport," *Sports Medicine*, vol. 38, pp. 1025–1043, 2008.
- [5] B. H. Groh, M. Fleckenstein, T. Kautz, and B. M. Eskofier, "Classification and visualization of skateboard tricks using wearable sensors," *Pervasive and Mobile Computing*, vol. 40, pp. 42–55, 2017.
- [6] M. A. Abdullah, M. A. R. Ibrahim, M. N. A. B. Shapiee, M. A. Mohd Razman, R. M. Musa, and A. P. Abdul Majeed, "The classification of skateboarding trick manoeuvres through the integration of imu and machine learning," in *Intelligent Manufacturing and Mechatronics: Proceedings of the 2nd Symposium on Intelligent Manufacturing and Mechatronics—SymptoSIMM 2019, 8 July 2019, Melaka, Malaysia*. Springer, 2020, pp. 67–74.
- [7] J. Fountain and M. Meyers, "Skateboarding injuries," *Sports Medicine*, vol. 22, pp. 360–6, 01 1997.
- [8] "Esp-01 wifi module," 2015. [Online]. Available: <https://www.microchip.ua/wireless/esp01.pdf>
- [9] F. D. Farfán, J. C. Politti, and C. J. Felice, "Evaluation of emg processing techniques using information theory," *Biomedical engineering online*, vol. 9, pp. 1–18, 2010.
- [10] J. Jubany and R. Angulo-Barroso, "An algorithm for detecting emg onset/offset in trunk muscles during a reaction-stabilization test," *Journal of Back and Musculoskeletal Rehabilitation*, vol. 29, no. 2, pp. 219–230, 2016.
- [11] M. A. Oskoei and H. Hu, "Myoelectric control systems—a survey," *Biomedical signal processing and control*, vol. 2, no. 4, pp. 275–294, 2007.
- [12] A. Phinyomark, P. Phukpattaranont, and C. Limsakul, "Feature reduction and selection for emg signal classification," *Expert systems with applications*, vol. 39, no. 8, pp. 7420–7431, 2012.
- [13] H.-P. Huang and C.-Y. Chen, "Development of a myoelectric discrimination system for a multi-degree prosthetic hand," in *Proceedings 1999 IEEE International Conference on Robotics and Automation (Cat. No.99CH36288C)*, vol. 3, 1999, pp. 2392–2397 vol.3.
- [14] I. Da Silva, S. D., and R. Flauzino, *Redes neurais artificiais para engenharia e ciencias aplicadas: curso pratico*. São Paulo, SP, Brasil: Artliber, 2010.
- [15] S. Haykin, *Neural networks and learning machines*. Hamilton, Ontario, Canada: Pearson, 2009.
- [16] G. Biau and E. Scornet, "A random forest guided tour," *Test*, vol. 25, pp. 197–227, 2016.
- [17] M. P. LaValley, "Logistic regression," *Circulation*, vol. 117, no. 18, pp. 2395–2399, 2008.
- [18] H. Siqueira, M. Macedo, Y. d. S. Tadano, T. A. Alves, S. L. Stevan Jr, D. S. Oliveira Jr, M. H. Marinho, P. S. d. M. Neto, J. F. d. Oliveira, I. Luna et al., "Selection of temporal lags for predicting riverflow series from hydroelectric plants using variable selection methods," *Energies*, vol. 13, no. 16, p. 4236, 2020.
- [19] J. Belotti, H. Siqueira, L. Araujo, S. L. Stevan Jr, P. S. de Mattos Neto, M. H. Marinho, J. F. L. de Oliveira, F. Usberti, M. d. A. Leone Filho, A. Converti et al., "Neural-based ensembles and unorganized machines to predict streamflow series from hydroelectric plants," *Energies*, vol. 13, no. 18, p. 4769, 2020.
- [20] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: a new learning scheme of feedforward neural networks," in *2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541)*, vol. 2. Ieee, 2004, pp. 985–990.
- [21] Y. de Souza Tadano, H. V. Siqueira, and T. A. Alves, "Unorganized machines to predict hospital admissions for respiratory diseases," in *2016 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*. IEEE, 2016, pp. 1–6.

- [22] C. Deina, M. H. do Amaral Prates, C. H. R. Alves, M. S. R. Martins, F. Trojan, S. L. Stevan, and H. V. Siqueira, "A methodology for coffee price forecasting based on extreme learning machines," Information Processing in Agriculture, vol. 9, no. 4, pp. 556–565, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2214317321000597>
- [23] H. V. Siqueira, L. Boccato, R. Attux, and C. Lyra Filho, "Echo state networks in seasonal streamflow series prediction," Learning and Nonlinear Models, vol. 10, no. 3, pp. 181–191, 2012.
- [24] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural computation, vol. 9, pp. 1735–80, 12 1997.
- [25] P. S. de Mattos Neto, J. F. L. de Oliveira, D. S. d. O. S. Júnior, H. V. Siqueira, M. H. D. N. Marinho, and F. Madeiro, "A hybrid nonlinear combination system for monthly wind speed forecasting," IEEE Access, vol. 8, pp. 191 365–191 377, 2020.
- [26] S. J. Russel and P. Norvig, Inteligencia artificial: uma abordagem moderna. Rio de Janeiro, RJ, Brasil: Grupo Gen, 2022.
- [27] R. N. de Sousa, R. X. de Brito, and J. N. de Sousa Ximenes, "Aplicação da rede neural rbf como mecanismo auxiliador no diagnóstico da doença hlb em espécies cítricas," in Anais da VII Escola Regional de Computação Aplicada à Saúde. SBC, 2019, pp. 55–60.
- [28] N. Silva, I. Siqueira, S. Okida, S. L. Stevan, and H. Siqueira, "Neural networks for predicting prices of sugarcane derivatives," Sugar Tech, vol. 21, pp. 514–523, 2019.
- [29] "Redes neurais de função de base radial robusta," IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), vol. 29.
- [30] M. E. Nakai, P. R. Aguiar, H. Guillardí, E. C. Bianchi, D. H. Spatti, and D. M. D'Addona, "Evaluation of neural models applied to the estimation of tool wear in the grinding of advanced ceramics," Expert Systems with Applications, vol. 42, no. 20, pp. 7026–7035, 2015. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0957417415003280>
- [31] S. E. Jorgensen and B. Fath, Encyclopedia of ecology. Newnes, 2014.
- [32] A. Subasi, Practical machine learning for data analysis using python. Academic Press, 2020.
- [33] "What is logistic regression ?" <https://www.ibm.com/topics/logistic-regression>, accessed: 20/06/2023.
- [34] C. Deina, M. H. do Amaral Prates, C. H. R. Alves, M. S. R. Martins, F. Trojan, S. L. Stevan Jr, and H. V. Siqueira, "A methodology for coffee price forecasting based on extreme learning machines," Information Processing in Agriculture, vol. 9, no. 4, pp. 556–565, 2022.
- [35] L. G. S. Ayres, J. J. A. Mendes Jr., M. L. B. Freitas, L. M. S. Nascimento, L. V. Bonfati, I. F. W. Cordova, F. A. Farinelli, and S. L. Stevan Jr., "Aquisição de dados e categorização de manobras realizadas em um skate," CONET, 2019.