

## Desenvolvimento de módulos inerciais para avaliação da prática esportiva e sua aplicação em um skate

## Development of inertial modules for assessment of sports practice and its application on a skateboard

### RESUMO

Luan Gabriel dos Santos Ayres  
[luansayres@hotmail.com](mailto:luansayres@hotmail.com)  
Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil

Sérgio Luiz Stevan Junior  
[sstevanjr@gmail.com](mailto:sstevanjr@gmail.com)  
Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil

O skate está em pauta, pois em 2020 se tornará uma modalidade olímpica e dessa forma fica evidente a necessidade de desenvolvimento de técnicas mais precisas para julgar, monitorar e treinar. Foi elaborado um sistema para a detecção e categorização de manobras realizadas em um skate utilizando sensores inerciais. O protótipo foi baseado em dois principais componentes: sensor MPU-9250 e um microcontrolador ESP01. O protótipo final consiste em três caixas, duas com os inerciais e uma com os componentes, as caixas com os sensores foram posicionadas próximo as extremidades do skate (*nose e tail*), enquanto a central foi colocada abaixo do centro do mesmo. Assim foram realizadas três manobras, *ollie*, *nollie* e *backflip* 180, estas manobras foram repetidas por um voluntário, dez vezes cada. Os dados passam por um filtro passa baixa de 6 Hz Butterworth de 5ª ordem, sendo em seguida processados por meio de uma rede neural MLP. Em seguida foi efetuado a categorização dos dados e manobras, sendo que a rede obteve com isso 92% de acerto em testes realizados. Espera-se em trabalhos futuros aumentar esse índice de acerto, coletando um número maior de manobras e com uma quantidade maior de voluntários.

**PALAVRAS-CHAVE:** Skate. Redes neurais. Avaliação sensorial.

Recebido:

Aprovado:

**Direito autorial:** Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



### ABSTRACT

Skateboarding is on the agenda, by 2020 it will become an olympic sport and thus the need to develop more precise techniques for judging, monitoring and training. A system was developed for the detection and categorization of maneuvers performed on a skateboard using inertial sensors. The prototype was based on two main components: MPU-9250 sensor and an ESP01 microcontroller. The final prototype consists of three boxes, two with the inertial and one with the components, the boxes with the sensors were positioned near the edges of the skate (*nose and tail*), while the central was placed below the center of the skateboard. Thus, three maneuvers were performed, *ollie*, *nollie* and *backflip* 180, these maneuvers were repeated by one volunteer, ten times each. The data is passed through a butterworth 6 hz low pass filter and then processed through an MLP neural network. Then the data and maneuvers were categorized, and the network obtained 92% success in tests performed. Future work is expected to increase this hit rate by collecting more maneuvers and more volunteers.

**KEYWORDS:** Skate. Neural networks. Sensory evaluation.

## INTRODUÇÃO

No esporte há sempre a busca pela melhoria na performance, segundo Brzostowski e Szwach (2018) por meio de inerciais essa melhoria pode ser obtida de maneira mais acentuada. Sensores estes que possuem baixo valor de aquisição, e que podem fornecer dados para diversas aplicações, entre elas a instrumentação de um skate, para análise e reconhecimento de manobras.

Hoje o skate é uma modalidade esportiva e olímpica sendo adicionado à lista de esportes dos jogos olímpicos de 2020 (TOCOG, 2019). Assim fica claro o potencial do skate e como podem ser desenvolvidos projetos para auxiliar na busca pelo desempenho.

Para o julgamento das manobras, utilizam-se apenas a análise de vídeo em um critério mais técnico atualmente, propõe-se nesse projeto utilizar sensores inerciais para avaliação e categorização dessas manobras. Segundo Groh et al (2017) inerciais são sensores de baixo valor de aquisição que permitem uma análise em tempo real. Sendo que a mobilidade de sistemas com câmeras é baixa, requerendo também uma capacidade de processamento elevada para o processamento dos dados (BRZOSTOWSKI; SZWACH, 2018).

A aplicação visualizada neste projeto está na utilização destes equipamentos para a classificação de manobras realizadas em um skate por meio da aquisição e tratamento de dados, para que futuramente o sistema possa ser aperfeiçoado e utilizado para se realizar melhoria no desempenho desse esporte.

## MATERIAL E MÉTODO

Para obtenção dos dados cinéticos do skate durante manobras, inicialmente cogitou-se na utilização de diversos módulos. Por uma opção com baixo valor de aquisição e praticidade, foram escolhidos para o protótipo final o inercial MPU-9250, o módulo ESP-01 e uma bateria de lítio como opção de praticidade.

O módulo MPU-9250 é um dispositivo que apresenta um acelerômetro com três graus de liberdade, um giroscópio com três graus de liberdade e um magnetômetro com três graus de liberdade. Estes sensores apresentam também baixo nível de ruído se comparado a outros sensores do mesmo tipo, foram utilizados dois módulos neste protótipo, a utilização de dois módulos permite que se possa realizar a comparação com a utilização de um único sensor.

Como microcontrolador e transmissor foi utilizado o dispositivo ESP-01, este módulo apresenta transmissão sem fio através de rede WIFI com velocidade suficiente para o projeto.

Para a utilização dos componentes com a bateria de lítio foi necessário adicionar ao projeto um carregador de bateria, um conversor DC/DC para elevar a tensão e um regulador para ajustar a tensão em 3,3V para os componentes.

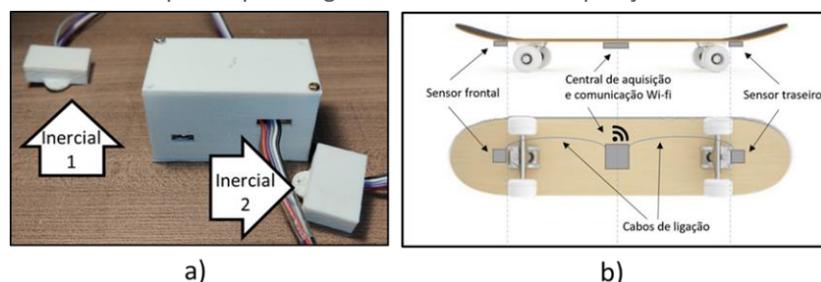
Para que a aquisição de dados e transferência dos mesmos ao computador fosse possível, foi elaborado um código na interface Arduino. No código foi

necessário modificar a precisão e escala do acelerômetro e giroscópio para uma escala de 8G para o acelerômetro, ou seja a medição máxima nesta escala é de 8 vezes a aceleração da gravidade, e de 1000°/s para o giroscópio, sendo assim possível um giro de até 1000° em um segundo em qualquer um dos eixos, estes valores foram definidos através de testes e com base na bibliografia.

Foi utilizado uma rotina com interrupção no código do microcontrolador, dessa forma é possível controlar o tempo de aquisição dos dados de maneira precisa. Com o tempo da interrupção sendo definido em 0,01s, ou seja, configurado para uma aquisição em 100 Hz, frequência essa escolhida sabendo-se da rápida duração das manobras, é então necessária uma frequência de aquisição mais elevada para assim poder capturar as características das manobras realizadas.

Esse protótipo consiste em três caixas, um com a central e duas com os inerciais, posicionados nas extremidades do skate, como pode ser visto na Figura 1.

Figura 1 – Caixa com protótipo na figura a e skate com a disposição das caixas na figura b



Fonte: Autoria própria (2019).

Na caixa central da figura 1a, encontram-se o microcontrolador, a bateria, o carregador da bateria, o conversor DC/DC e o regulador de tensão. A caixa central é posicionada no centro do skate na parte inferior, os sensores são posicionados um em cada *nose* do skate como pode ser visto na figura 1b.

Para a requisição da transferência utilizou-se o software MATLAB no computador, através de uma rotina cria-se uma conexão UDP, conectando-se ao ESP-01. A partir da conexão, começa o recebimento, armazena-se a partir do segundo pacote, utiliza-se um filtro passa baixa de 6 Hz Butterworth de 5ª ordem para remover ruídos de alta frequência em seguida os dados são armazenados.

Após testes realizados no sistema e subsequentemente a validação, seguiu-se para a coleta de dados com um voluntário com experiência no skate. Foram realizadas as manobras: *ollie*, *nollie* e *backflip* 180, constituindo 10 repetições de cada manobra, com aquisição de 100 Hz nos dois inerciais, cada manobra foi adquirida em uma janela de dez segundos. A representação da manobra *ollie* é apresentada na figura 3 e da *backflip* 180 é apresentada na figura 2.

Figura 2 – Realização da manobra *backflip* 180



Fonte: wikiHow (2019).

Figura 3 – Realização da manobra *ollie*



Fonte: wikiHow (2019).

As manobras *ollie* e *nollie* apresentam diversas semelhanças, a diferença encontra-se no pé e no *nose* que sobe, na *ollie* o *nose* da frente sobe, enquanto na *nollie* o que ocorre é o inverso, mandando para cima o *nose* da parte traseira do skate.

Depois de capturados pelo sistema, os dados foram normalizados e retiradas as suas características para que em seguida os mesmos pudessem ser processados por uma rede neural MLP, para que assim o sinal pudesse ser categorizado. Após realizados os testes definiu-se a característica MAV (*mean absolute value*) como a mais promissora baseado em índices de acerto.

O conjunto a ser testado tem 30 elementos, utilizando 12 elementos para treinamento, 8 para validação e mais 10 para teste. Após testes realizados utilizando 1 a 30 neurônios, escolheu-se a utilização de 22 neurônios, pois neste valor a média de acertos é maior. Então para validar essa escolha, a rede rodou 20 vezes, obtendo assim um conjunto de matrizes de confusão que ao serem interpretadas demonstram a eficácia da classificação.

### RESULTADOS E DISCUSSÃO

A coleta de dados do teste real ocorreu utilizando-se do protótipo com a ajuda de um voluntário com experiência no skate. Foram realizadas três manobras, *Ollie*, *Nollie*, *Backflip* 180. Na figura 4 há imagens mostrando a realização das manobras por um voluntário.

Figura 4 – Realização das manobras *ollie*, *nollie* e *backflip* 180 pelo voluntário



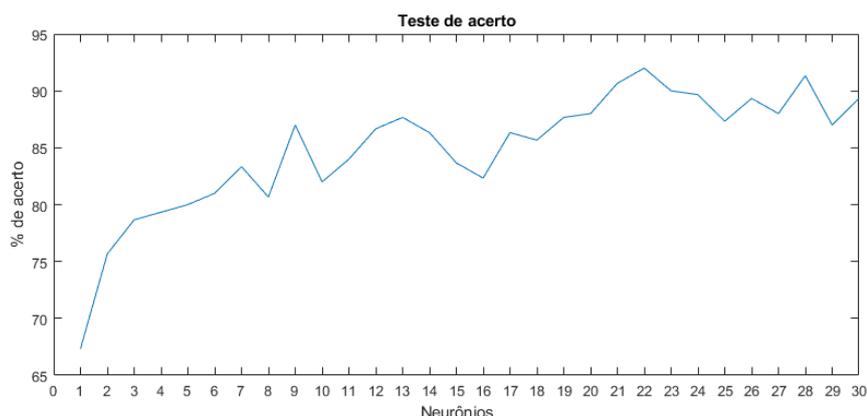
Fonte: Autoria própria (2019).

Foi necessário então definir a característica mais adequada para o projeto, ou seja, que obtivesse maior índice de acerto. Em testes realizados com as características ACC, DASDV, Sinal Integrado, MAV, RMS, SSI e WL, definiu-se a característica MAV, *mean absolute value* (PHINYIMARK; PHUKPATTARANONT;

LIMSAKUL, 2012). Sendo a característica ideal por obter um maior índice de acerto (80,78%).

Para que pudesse ser escolhido quanto neurônios a rede utilizaria, a rotina da rede neural foi compilada 10 vezes com a característica MAV, depois foram adquiridas as taxas de acerto no período de testes da rede, para cada neurônio, utilizando de 1 a 30 neurônios, obteve-se como resultado o gráfico da figura 5, neste gráfico o eixo horizontal representa a quantidade de neurônios testada e o eixo vertical a porcentagem de acerto com cada uma das quantidades.

Figura 5 – Taxa de acerto da rede utilizando a característica MAV



Fonte: Autoria própria (2019).

A partir disso, escolheu-se a utilização de 22 neurônios e com esta quantidade foi obtido 92% de acerto da rede em testes. Em seguida a rotina de rede neural foi compilada 20 vezes com 22 neurônios, somando-se as matrizes de confusão adquiridas obteve-se a tabela 1.

Tabela 1 – Matriz de confusão

|                     |                     | Manobras identificadas pela rede |               |                     |
|---------------------|---------------------|----------------------------------|---------------|---------------------|
|                     |                     | <i>Ollie</i>                     | <i>Nollie</i> | <i>Backflip 180</i> |
| Manobras realizadas | <i>Ollie</i>        | 52                               | 12            | 2                   |
|                     | <i>Nollie</i>       | 7                                | 57            | 4                   |
|                     | <i>Backflip 180</i> | 0                                | 2             | 64                  |

Fonte: Autoria própria (2019)

Nesta matriz de confusão pode-se observar que existe alguma confusão para identificação da manobra *Ollie* e *Nollie*, tal erro pode ter ocorrido pela semelhança entre as duas manobras, pois a diferença entre elas está em qual *nose* do skate sobe e qual desce. Já a manobra *Backflip 180* apresenta grandes diferenças com as demais e por isso obteve-se um pequeno erro na classificação.

De acordo com a matriz de confusão, obtiveram-se 78,79% de precisão para se identificar um *Ollie*, 83,82% de precisão na identificação de um *Nollie* e 96,97% de precisão para a identificação de um *Backflip 180*, valores estes obtidos em comparação das manobras identificadas pela rede com as manobras realizadas pelo voluntário.

## CONCLUSÃO

O objetivo desse projeto foi a aquisição de dados de manobras realizadas em um skate e assim categorizá-las adequadamente. Tal objetivo foi cumprido, entretanto vários foram os problemas enfrentados.

No projeto houveram o desenvolvimento e avaliação de protótipos até a chegada do último em que obtiveram-se os dados, problemas como tamanho, peso, problemas de confiabilidade, entre outros, foram sendo resolvidos, entretanto ainda restam problemas a serem resolvidos, como a baixa taxa de acerto em algumas manobras causadas possivelmente pela falta de dados e voluntários.

Almeja-se para projetos futuros a redução do tamanho do dispositivo, transformando o protótipo em uma placa única fabricada profissionalmente, bem como também a classificação e testes com uma maior variedade de manobras, além da captação de manobras com mais voluntários, também é interessante fazer a comparação do sistema com um e dois inerciais.

### AGRADECIMENTOS

Agradeço ao professor Stevan por ter dado essa oportunidade para a realização desse trabalho, agradeço também aos meus amigos do CIEBE por estarem sempre dispostos a ajudar, agradeço ao Gustavo, voluntário que realizou as manobras com o skate, agradeço ao CNPq pelo auxílio financeiro e a UTFPR pelo apoio ao desenvolvimento científico.

### REFERÊNCIAS

BRZOSTOWSKI, K.; SZWACH, P. Data Fusion in Ubiquitous Sports Training: Methodology and Application. Wroclaw University of Science and Technology, 2018.

Skateboarding. The Tokyo Organising Committee of the Olympic and Paralympic Games. Disponível em: <https://tokyo2020.org/en/games/sport/olympic/skateboarding/>. Acesso em: 18 de jul. de 2019.

GROH, B. H.; FLECKENSTEIN, M.; KAUTZ, T.; ESKOFIER, B. M. Classification and visualization of skateboard tricks using wearable sensors. Friedrich-Alexander-Universität Erlangen-Nürnberg (FAU), 2017.

Como Dar um Ollie. Equipe wikiHow. Disponível em: <https://pt.wikihow.com/Dar-um-Ollie>. Acesso em: 18 de jul. de 2019.

Como Fazer Manobras de Skate. Disponível em: <https://pt.wikihow.com/Fazer-Manobras-de-Skate>. Acesso em: 19 de jul. de 2019.

PHINYOMARK, A.; PHUKPATTARANONT, P.; LIMSAKUL, C. Feature reduction and selection for EMG signal classification. Prince of Songkla University, 2012