

CLASSIFICAÇÃO DE MOVIMENTOS DO PÉ PARA USO EM JOGOS DE RECUPERAÇÃO FÍSICA

Tito Ribeiro de Almeida Guidotti (IC) e Eurico Luiz Prospero Ruivo (Orientador)

Apoio: PIBIC Mackenzie

RESUMO

Exergames, jogos que possuem exercícios físicos como núcleo de sua jogabilidade, podem ser usados como ferramentas pela fisioterapia. Entretanto, eles dependem que estado do jogador, ou seja, o conjunto de seus movimentos, seja corretamente classificado. Redes neurais se apresentam como classificadores ideais à tarefa, e por serem rápidos de serem treinados, permitem testes de uma gama de configurações diferentes.

Este projeto busca criar um recurso que facilite a criação de jogos para recuperação física, cujo controle dependa de qualquer combinação dos seguintes movimentos realizados pelo pé: dorsiflexão plantar, flexão plantar, repouso, eversão e inversão. Para isso foi montada uma papete com acelerômetro para registrar dados do movimento do pé. Com ela, feita uma coleta de amostras de cada um desses 5 movimentos, cujos resultados foram usados para modelar, treinar e validar uma rede neural para classificar dentre eles. Foi criada uma interface acessível para que esse classificador possa ser usada por jogos, e criado um protótipo de jogo como exemplo. Demonstrou-se assim a viabilidade do uso de uma rede neural para a classificação dos movimentos propostos e que a biblioteca produzida pode facilmente ser integrada a jogos.

Palavras-chave: Exergames, classificação, redes neurais

ABSTRACT

Exergames, games that have physical exercises as the core of its gameplay, can be used as tools by physiotherapy. But they depend on the correct classification of the player's status, in other words, the player's movements. Neural networks present themselves as ideal classifiers to the scenario, and because they can be quickly trained, allow to test a range of different configurations.

This project aims to creating a resource to ease the development of physical recuperation games, whose controls depends on any combination of the following feet movements: plantar dorsiflexion, plantar flexion, rest, eversion and inversion. On that purpose, a shoe with a built-in accelerometer was built, to register data of the feet movement. Using it, samples were registered of each of those 5 movements, producing a dataset used to model, train and validate a neural network to classify between then. An accessible interface was created so that the classifier may be used by games, and a game prototyped as an example. Thus was

demonstrated the viability of using a neural network on the classification of the proposed movements, and that the produced library can be easily integrated to games.

Keywords: Exergames, classification, neural networks.

1. INTRODUÇÃO

Alguns problemas físicos requerem um tratamento fisioterapêutico que envolve repetição de exercícios. Para alguns públicos - crianças em particular - esse tratamento pode ser melhorado pela introdução de jogos que incentivem a prática desses exercícios e até ajudem o fisioterapeuta a documentar o processo (SANPABLO et al, 2022). Esses jogos que envolvem o exercício físico como núcleo de sua jogabilidade são chamados de exergames.

Este trabalho foca na síndrome do pé torto congênito, condição em que a criança nasce com um ou ambos os pés tortos (DOBBS, GURNETT, 2009). Tratamentos modernos, como o método de Ponseti (PONSETI, SMOLEY, 1963), exigem que sejam feitos muitos exercícios dos seguintes movimentos do pé: dorsiflexão plantar (levantar ponta do pé); flexão plantar (levantar o calcanhar); eversão (pés inclinados para dentro, solas para fora); inversão (pés inclinados para fora, solas para dentro).

Um jogo que tente fazer com que o jogador realize esses movimentos deve ser capaz de distinguir qual deles está sendo feito a cada momento, e ainda um movimento neutro: repouso (pés relaxados).

Distinguir esses movimentos é uma tarefa mais complexa do que aparenta a primeira vista, devido as particularidades do movimento de cada pessoa, e das divisões pouco precisas de onde acaba um movimento e onde começa outro; por exemplo, se o pé está com a ponta levantada ao mesmo tempo que levemente inclinado para dentro, poderia ser classificado tanto como uma dorsiflexão ou inversão.

Em um trabalho anterior (BAPTISTA et al, 2021), foi criada uma "papete inteligente", um sapato com um sensor para controlar um jogo, buscando trabalhar esse problema ao menos em um eixo: dorsiflexão - repouso - flexão. O paciente usava uma papete com um giroscópio amarrado em sua extremidade, e era lido o vetor de aceleração angular do sensor por um arduino. Somente um dos eixos (o eixo Y) desse valor era comparado com dois limites pré-definidos encontrados empiricamente para determinar qual movimento estava sendo feito; em seguida era transmitido via serial (USB) para o computador os valores "-1", "0" ou "1" para indicar o estado do pé. Esse valor era usado para controlar um jogo e registrar o quão bom foi o paciente em seguir um exercício pré-definido.

O trabalho possui algumas limitações: a classificação foi feita de maneira bastante específica ao jogo, sem grande potencial de ser adaptada a outros exercícios necessários ao tratamento; a única analítica que poderia vir dos dados transmitidos pela papete era o sucesso ou fracasso na execução do exercício (sem ângulos de alcance); a papete tinha aparência de improvisada, e as crianças ficavam com medo de levar choque.

2. METODOLOGIA

Para obter os dados da movimentação do pé, foi usada uma nova versão da papete inteligente, capaz de ler a posição do pé, tratar o que for possível nela mesma e repassar para um computador, onde estaria em execução um jogo que usasse tais dados.

Ela foi construída usando-se: um sensor MPU-6050, usado para se obter a rotação do pé; uma bateria recarregável de lítio de 3.6V, pareada com uma placa de carregamento TP4056, para alimentar o dispositivo; e uma placa de desenvolvimento NodeMCU, compatível com Arduino mas dotada de conexão Wi-Fi, responsável administrar o sensor e repassar os dados para o computador. Essas peças foram presas em uma placa de solda, com o NodeMCU sobre o sensor e a placa de carregamento para otimizar o uso de espaço e proteger as conexões internas. Esse conjunto foi colado na papete no ponto analisado como mais próximo do "centro" de rotação do pé: o osso tálus (NESTER, 1998).

Figura 1 – Diagrama do circuito da papete

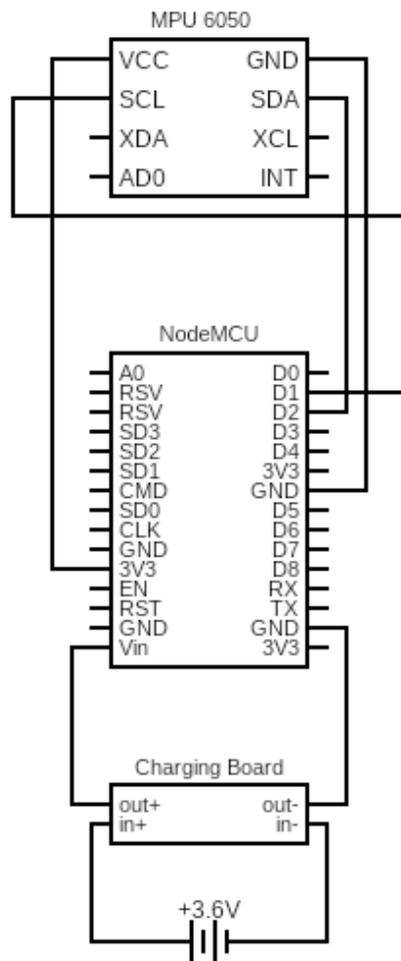


Figura 2 – Montagem do circuito

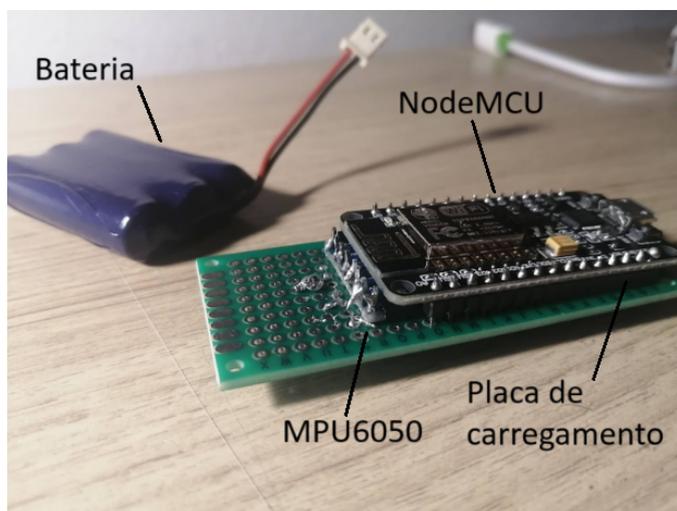


Figura 3 – Papete direita

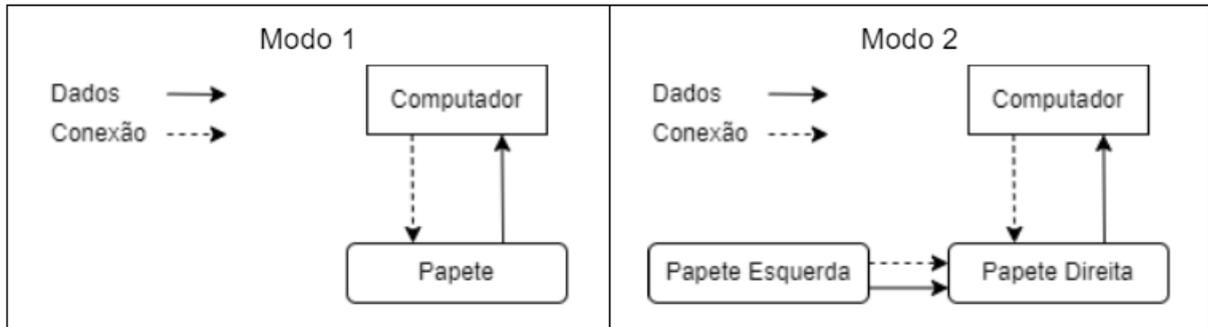
O software foi dividido em duas partes: na papete, a que transmite os dados, feita com a linguagem do Arduino (baseada em C++) e a que recebe e interpreta os dados, escrita em Rust. Rust foi escolhido por ser uma linguagem portátil e com um rico ecossistema de bibliotecas. A comunicação entre essas partes foi projetada para funcionar cabeada ou não.

Na comunicação cabeada, via USB, o software pode procurar conexões para poder funcionar logo que a papete for conectada, ou escolher uma porta manualmente, para evitar problemas como colisões (mais de um software tentando usar a mesma porta). Por essa conexão, a papete envia serialmente dados atualizados em intervalos. As duas papetes podem ser conectadas ao mesmo tempo.

A comunicação sem fio é dividida em dois modos. No primeiro, a papete abre uma rede WI-FI, na qual o computador se conecta. A papete transmite os dados então via UDP para o dispositivo conectado. Esse modo funciona com uma papete por vez. O segundo modo foi pensado para as duas papetes ao mesmo tempo: a direita age como servidor, e a outra se conecta a ela. A papete-cliente transmite à papete-servidor os próprios dados; o computador se conecta a esta para receber dados das duas, do mesmo jeito que faria para receber só de uma. A desvantagem

desse modo é que exige que as duas papetes estejam ligadas, independente de se somente uma vai ser usada.

Figura 4 – Modos de conexão sem fio



O MPU-6050 produz 3 dados: um vetor de aceleração angular, um vetor do giroscópio e um valor de temperatura. Durante os testes, se mostrou como relevante somente a aceleração, quando tratada como:

$$rotX = \tan^{-1}(\sin(-acelX) * \cos(\sqrt{acelY^2 + acelZ^2}))$$

$$rotZ = \tan^{-1}(acelY * \cos(acelZ))$$

Sendo $rotX$ e $rotY$ as rotações que buscamos obter, nos eixos lateral e frontal do pé, respectivamente; $acelX$, $acelY$ e $acelZ$ os três componentes do vetor aceleração, lido pelo sensor (dfrobot.com, s.d.) e \tan^{-1} a função arco tangente. A papete transmite as duas rotações obtidas dois valores, junto com um caractere que indica qual lado que é: 'E' (esquerdo) ou 'D' (direito).

Foi feita a coleta de amostras de cada um dos movimentos, cerca de 500 de cada de uma unica pessoa. O paciente recebia instruções de como posicionar o pé e indicava quando estivesse pronto. Durante o próximo segundo, eram resgistradas dez vezes o valor transmitido pela papete.

Como classificador do movimento, foi escolhida uma rede neural, pela versatilidade e uso em classificadores semelhantes, para projetos trabalhando com dados relativos ao corpo humano (MANFREDO et al, 2016). A rede é composta por 3 nós de entrada e 5 de saída; um para cada uma das posições. Todas as funções de ativação são sigmóides idênticas:

$$f(x) = \frac{1}{1+e^{-x}}$$

Sendo γ um número entre 0 e 1, para determinar a intensidade da curva. A saída, depois de normalizada, é uma porcentagem de confiança na classificação do movimento atualmente sendo feito pela papete. Se o paciente estiver realizando uma dorsiflexão plantar, por exemplo, a saída ideal seria: [1; 0; 0; 0; 0]. Mas também seria uma saída correta: [0,62; 0,03; 0,11; 0,07; 0,17].

Foi feita uma análise de sensibilidade para determinar a melhor estrutura para o classificador, variando-se a quantidade de camadas ocultas (de 1 a 3), a quantidade de nós por camada oculta (de 10 a 50; em saltos de 10) e a variável γ da função de ativação (de 0,6 a 1,0; em saltos de 0,1). A estrutura escolhida dessa análise seria aquela com o menor número de nós, mas que atingisse a maior precisão.

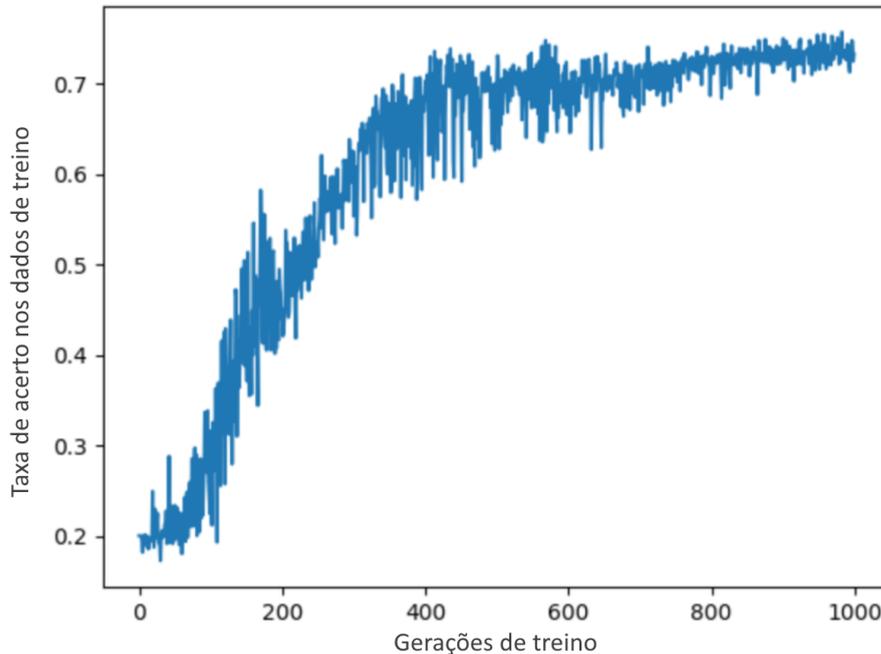
As entradas da rede são as inclinações e o pé que está sendo avaliado. Devem estar entre 0 e 1, para a rede funcionar corretamente. Por serem resultantes da função arco tangente, as inclinações enviadas pela papete são no intervalo de $-\pi$ a π . Portanto para ficarem entre 0 e 1 devem ser normalizadas:

$$norm(x) = \frac{0,5x}{\pi} + 0,5$$

Na terceira entrada, é passada à rede 1 ou 0 para representar, respectivamente, o pé esquerdo ou direito.

A rede foi treinada por retropropagação, com tamanho de lote 30 e em 500 gerações de treino. Esse número de gerações foi encontrado experimentalmente, observando-se onde que a precisão da rede se estabilizava.

Figura 5 – Curva de treinamento, com a geração no eixo x e precisão no y, se estabilizando por volta de 50 gerações



Como a coleta foi feita inteiramente com um único par de papetes, com sensores fixos em sua estrutura, a coleta de dados é toda referente a esse dispositivo. Para remediar isso e poder aplicar em diferentes configurações de hardware, ou mesmo em pacientes que a estrutura do pé impede que o seu movimento seja detectado corretamente, existe uma rotina de "calibração": coleta de 10 a 15 amostras de cada movimento e usa um algoritmo de aprendizado por transferência na estrutura previamente obtida da rede. Para isso, travam-se os pesos e vieses das primeiras camadas, e treina-se somente o resto.

Para validar o classificador, foi feito um teste k-pastas, com $k = 10$. Nesse teste, os dados coletados são embaralhados e divididos em dez partes (ou pastas). Cada uma destas é avaliada contra o classificador treinado nas nove outras.

Por fim, foi feito um jogo simples usando o motor de jogos Unity, usando a API pública da papete, para demonstrar o funcionamento da interface. Ele só usa os movimentos de dorsiflexão, repouso e flexão (eixo vertical de movimentação do pé),

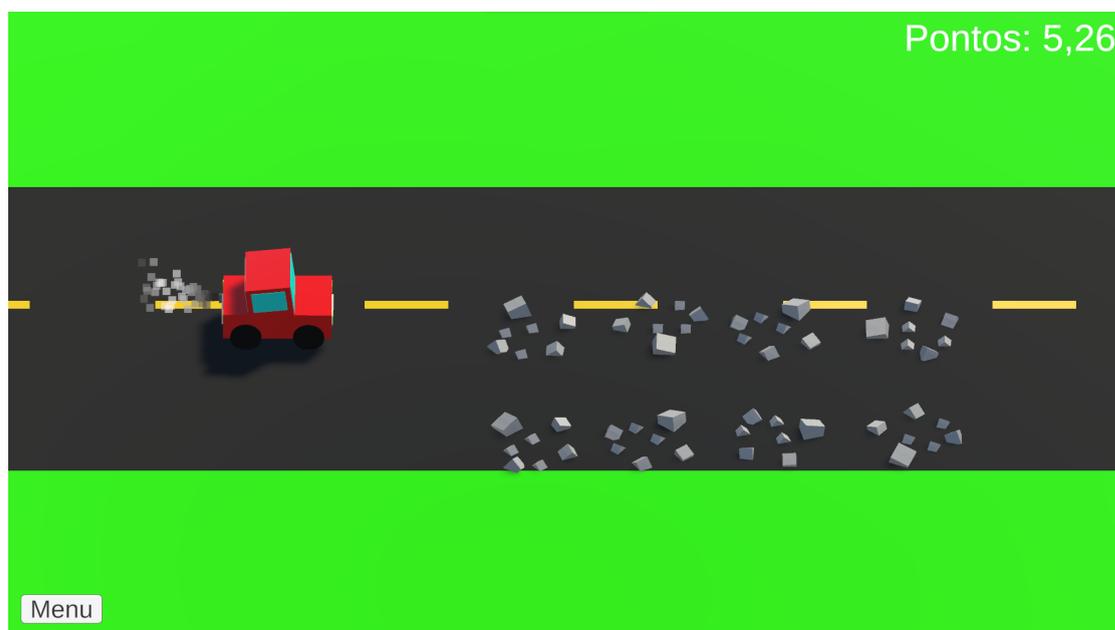
seguinte a mesma estrutura do jogo feito anteriormente (BAPTISTA et al, 2021): há uma sequência pré-determinada de movimentos a ser feita pelo paciente. Essa sequência é armazenada em um documento de texto, que pode ser rapidamente modificado para se adequar a diferentes sequências de exercícios.

O jogo funciona da seguinte maneira: há um carro que a câmera virtual segue, seguindo na horizontal em relação a tela. Enquanto ele segue, obstáculos (representados por pedregulhos) surgem na estrada. Quando o jogador move o pé, o carro consegue se deslocar entre três posições (acima, centralizado e abaixo), cada uma representando uma das possíveis posições detectadas (dorsiflexão, repouso e flexão). A transição do carro não é imediata, para não interromper a imersão do jogador, mas feita através de uma interpolação linear, de modo que a velocidade de deslocamento é diretamente proporcional à distância de onde está para até o seu destino. Caso o jogador não consiga se desviar, a é aplicado um efeito de “tremedeira” na tela, movendo a câmera numa alta frequência de ida e volta. Ao final da sequência, o jogador recebe uma pontuação de acordo com a proximidade do que conseguiu fazer com o exercício proposto.

Figura 6 – Tela de início do jogo de demonstração



Figura 7 – Jogo durante uma partida; as pedras no caminho indicam que o jogador deve fazer uma dorsiflexão plantar



3. RESULTADO E DISCUSSÃO

Feitas as 75 combinações possíveis de camadas ocultas, nós por camada e γ , aquela que atingiu o objetivo de máxima precisão com o menor número de nós foi: 2 camadas ocultas de 30 nós, com $\gamma = 1$.

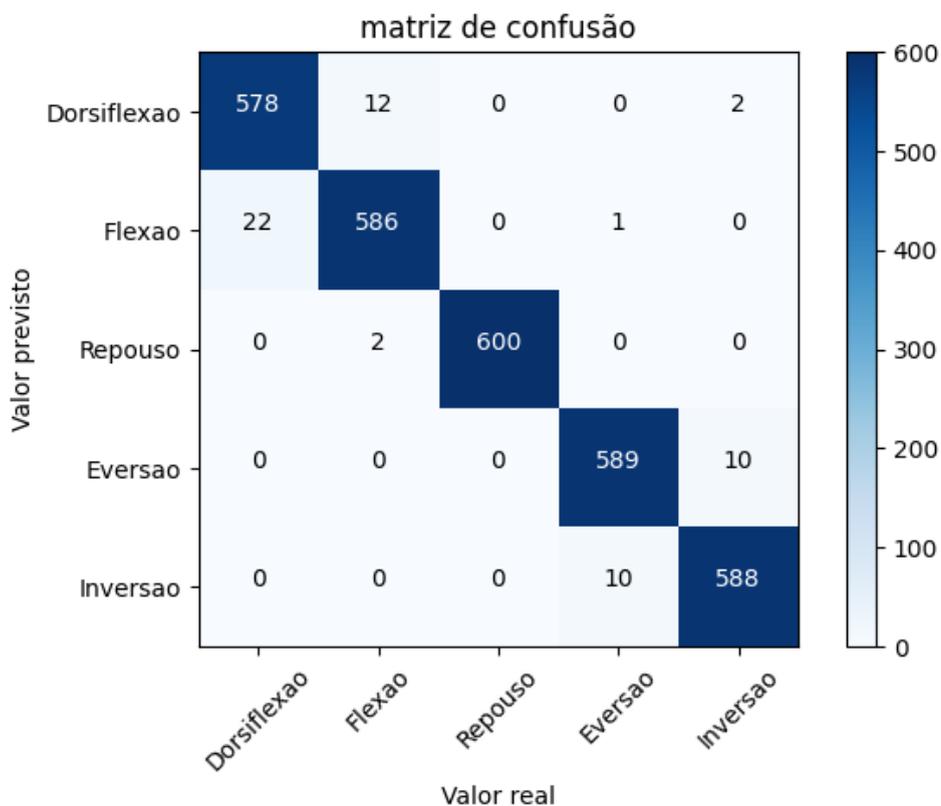
Tabela 1 – Análise de sensibilidade, representando a precisão de treino (entre 0 e 1)

Nós \ γ	0,6	0,7	0,8	0,9	1
1 camada oculta					
10	0,829	0,790	0,790	0,810	0,790
20	0,829	0,810	0,790	0,790	0,790
30	0,790	0,790	0,790	0,790	0,790
40	0,800	0,829	0,790	0,790	0,790
50	0,800	0,790	0,790	0,790	0,790
2 camadas ocultas					
10	0,829	0,829	0,829	0,790	0,810
20	0,829	0,779	0,829	0,850	0,920

30	0,860	0,829	0,899	0,870	0,990
40	0,810	0,870	0,910	0,990	0,990
50	0,829	0,879	0,860	0,990	0,990
3 camadas ocultas					
10	0,850	0,819	0,829	0,870	0,889
20	0,910	0,829	0,990	0,970	0,990
30	0,970	0,970	0,990	0,990	0,990
40	0,920	0,990	0,990	0,990	0,990
50	0,990	0,990	0,990	0,990	0,990

O teste de k-pastas resultou em uma média de acertos de 98,1% e um desvio-padrão de 0,777%. No jogo de demonstração, essa precisão resultou em um controle responsivo do carro.

Tabela 2 – Matriz de confusão, com todas as previsões do teste de k-pastas



O primeiro protótipo da nova versão da papete repetia alguns dos problemas da anterior, como conexões sensíveis e expostas e aparência improvisada. Integrar o

hardware em um unico pacote demonstrou facilitar o seu uso, principalmente ao introduzir a terceiros.

Figura 8 – Protótipo inicial da papete



Apesar de redes neurais se mostraram capazes de classificar resultados de inclinações lidas por sensor, os dados a serem classificados devem ser tratados de maneira a serem utilizáveis. Durante o desenvolvimento, a maneira de trata-los foi modificada diversas vezes, até experimentalmente ser identificada uma correta. Inicialmente a rede foi treinada com a leitura bruta do sensor; depois, com dados que receberam tratamento delegado a uma biblioteca para drones, que estimava valores gerando ruído; tentando remediar isso, os dados passavam por outra camada de tratamento, que tentava eliminar um dos eixos de rotação. Até serem corretamente tratados pelas fórmulas mencionadas anteriormente, os dados treinavam um classificador que gerava resultados pouco melhor que aleatórios.

Originalmente, o software foi escrito em Python, por causa da disponibilidade de bibliotecas. Mas se a intenção é criar um recurso com grande interoperabilidade com outros programas e para rodar na máquina de fisioterapeutas (e não em servidores), não é uma linguagem adequada.

4. CONSIDERAÇÕES FINAIS

Foi criado um recurso que consegue com uma alta taxa de confiança diferenciar movimentos do pé para uso em jogos para recuperação física.

Futuramente, esse recurso poderia ser estendido para fornecer relatórios mais relevantes do que simplesmente o estado imediato, como alcances históricos de um paciente. Além disso, seria interessante uma validação dos resultados com testes em campo, com portadores da síndrome do pé torto congênito, e uso da biblioteca em outros jogos e plataformas de jogos.

5. REFERÊNCIAS

DOBBS, M.B.; GURNETT, C.A. Update on Clubfoot: Etiology and Treatment. *Clinical Orthopaedics and Related Research*, v. 467, n. 5, p. 1146-1153, 2009. DOI: 10.1007/s11999-009-0734-9. Disponível em: <https://doi.org/10.1007/s11999-009-0734-9>. Acesso em: 11 ago. 2023.

FERREIRA, D. R.; BAPTISTA, C. K.; RODRIGUES, B. da S.; SIQUEIRA, B. C.; BLASCOVI-ASSIS, S. M.; CORRÊA, A. G. Development and Test of a Serious Game for Dorsiflexion and Plantarflexion Exercises of the Feet. *Journal on Interactive Systems*, Porto Alegre, RS, v. 12, n. 1, p. 58–68, 2021. DOI: 10.5753/jjs.2021.1916. Disponível em: <https://sol.sbc.org.br/journals/index.php/jjs/article/view/1916>. Acesso em: 2 ago. 2023.

How To Use a Three-Axis Accelerometer for Tilt Sensing-DFRobot. Disponível em: https://wiki.dfrobot.com/How_to_Use_a_Three-Axis_Accelerometer_for_Tilt_Sensing. Acesso em: 2 ago. 2023.

MANFREDO, A.; MATTEO, C.; HENNING, M. Deep Learning with Convolutional Neural Networks Applied to Electromyography Data: A Resource for the Classification of Movements for Prosthetic Hands. *Frontiers in Neurorobotics*, v. 10, 2016. DOI: 10.3389/fnbot.2016.00009. Disponível em: <https://www.frontiersin.org/articles/10.3389/fnbot.2016.00009>

NESTER, C. J. Review of literature on the axis of rotation at the sub talar joint. *The Foot*, v. 8, n. 3, p 111-118, 1998. DOI: 10.1016/S0958-2592(98)90042-6. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0958259298900426>. Acesso em: 2 ago. 2023.

PONSETI, I. V.; SMOLEY, E. N. The classic: congenital club foot: the results of treatment (1963). *Clinical Orthopaedics and Related Research*, v. 467, n. 5, p. 1133-45, 2009. DOI: 10.1007/s11999-009-0720-2. Disponível em: <https://doi.org/10.1007/s11999-009-0720-2>. Acesso em: 11 ago. 2023

SANPABLO, A. I. P.; ARMENTA-GARCÍA, J.; MUÑIZ, A. F.; PEÑALOZA, A. M.; MENDOZA-ARGUILÉS, A.; RODRÍGUEZ, M. D. Integration of persuasive elements into exergames: Application in the development of a novel gait rehabilitation system for children with musculoskeletal conditions. *Journal of Biomedical Informatics*, v. 132, 2022. DOI: 10.1016/j.jbi.2022.104130. Disponível em: <https://doi.org/10.1016/j.jbi.2022.104130>. Acesso em: 11 ago. 2023.

Contatos:

tito.guidotti@gmail.com

eurico.ruivo@mackenzie.br