

# Using Artificial Neural Networks to Classify Treadmill Running Patterns in High-Performance Sports

Sergio Baldo Junior<sup>1</sup>, Renato Tinós<sup>1</sup>, Paulo Roberto Pereira Santiago<sup>2</sup>

<sup>1</sup>Departamento de Computação e Matemática, FFCLRP, Universidade de São Paulo (USP), Ribeirão Preto, SP, Brasil

<sup>2</sup>Laboratório de Biomecânica e Controle Motor (LaBioCoM), Escola de Educação Física e Esporte, Universidade de São Paulo (USP), Ribeirão Preto, SP, Brasil

sergiobaldo@usp.br, rtinos@ffclrp.usp.br, paulosantiago@usp.br

**Abstract.** *The identification of running patterns, especially those associated to fatigue, can assist in designing more efficient workouts and preventing injuries in high performance sports. However, this task is not trivial due to the complexity of the patterns. An interesting alternative is to use Machine Learning methods, such as Artificial Neural Networks (ANNs), to classify running patterns. In this research, force signals are obtained by sensors coupled to the base of a low-cost open source treadmill. The goal is to indicate to the user the occurrence of fatigue during training based on running patterns. Different attributes are extracted from the time signals generated during training sessions. The examples are then classified by an ANN. The experimental results indicate that the ANN is able to classify running patterns with good accuracy. Experiments considering different scenarios indicate that the efficiency of the classifier was influenced by the day and stage of the training sessions.*

**Resumo.** *Conseguir classificar padrões de corrida, principalmente aqueles associados à fadiga, pode auxiliar na elaboração de treinos mais eficientes e na prevenção de lesões em esportes de alto rendimento. Todavia, essa tarefa não é trivial devido à complexidade dos padrões. Uma alternativa interessante é utilizar métodos de Aprendizado de Máquina, como Redes Neurais Artificiais (RNAs), para classificar padrões de corrida. Nesta pesquisa, sinais de força são obtidos por sensores de carga acoplados à base de uma esteira ergométrica open source de baixo custo. O objetivo é indicar ao usuário a ocorrência de fadiga durante o treinamento com base nos padrões de corrida. Diferentes atributos são extraídos dos sinais temporais gerados durante sessões de treino. Os exemplos obtidos são então classificados por uma RNA. Os resultados experimentais indicam que a RNA é capaz de classificar com boa acurácia os padrões de corrida. Experimentos considerando-se diferentes cenários indicam que a eficiência do classificador foi influenciada pelo dia e etapa das sessões de treinamento.*

## 1. Introdução

O número de pessoas que adotam a corrida como uma forma de prática esportiva tem crescido nos últimos anos. Os motivos da crescente procura estão principalmente relacionados com os benefícios físico, mental, financeiro e de facilidade de acesso da corrida [LAKOMY *et al.* 1987]. Atletas experientes, de diferentes modalidades, também utilizam a corrida em diversos tipos de treinamento. Em oposição aos benefícios da corrida, depara-se com um elevado índice de lesões osteomioarticulares [PONS-VILLANUEVA *et al.* 2010]. Apesar de algumas controvérsias, existem indícios científicos indicando que o impacto do pé no solo é diretamente relacionado com as chances de lesões em praticantes de corrida [MCCORMICK *et al.* 2012]. Esta constatação denota a importância de uma análise criteriosa da força de reação do solo, principalmente como uma possível variável de controle da intensidade da corrida durante sessões de treinamento de atletas amadores e profissionais [HEISE & MARTIN, 2001].

Além do aspecto da lesão, o impacto com o solo também apresenta relação com a economia de energia e com desempenho [GRUBER *et al.* 2013], [OGUETA-ALDAY *et al.* 2014]. Em trabalhos científicos de grande repercussão, pesquisadores em [BRAMBLE & LIEBERMAN, 2004] e [LIEBERMAN *et al.* 2010] sugeriram que o padrão de corrida com o contato do pé no solo de “antepé” e descalço, i.e., sem o uso de calçado específico de corrida, é mais eficiente em comparação ao padrão de “retropé” com calçado. Os estudos analisaram a eficiência baseada na economia de energia, desempenho de propulsão e menor risco de lesão.

Em seu estudo mais recente, Lieberman *et al.* (2010) embasaram suas afirmações investigando a medida “transiente de impacto” no momento do contato do pé no solo. Os autores descobriram que os valores de impacto transiente eram significativamente menores quando adotado um padrão de pisada de “antepé”, mesmo sem o uso de um calçado com tecnologia de amortecimento. Seguindo essa tendência, gigantes da indústria de calçados esportivos criaram modelos minimalistas para corredores de “antepé”, tendo como fundação o conceito *barefoot running* popularizado por Lieberman e colaboradores.

Os apontamentos anteriores deixam evidente a importância da investigação da corrida por meio de métodos inovadores, de análise dos padrões de corrida, baseados em medidas diversas como, por exemplo, relacionadas à força exercida no solo pelos corredores. Ações neste sentido estão cada vez mais presentes nos grandes laboratórios de pesquisa e nos grandes centros de treinamento do mundo. Em especial, conseguir identificar as possíveis alterações de padrões durante a corrida ocasionados por fadiga é de extrema importância. Tal identificação pode auxiliar na elaboração de treinos mais eficientes e na prevenção de lesões. Porém, detectar alterações no movimento de corrida é geralmente uma tarefa complexa, pois exige um elevado nível de percepção do observador/treinador, além da subjetividade, não existe um marcador chave para definir a fadiga.

Dada a complexidade dos padrões de corrida relacionados à fadiga, algumas soluções que fazem uso de modelos computacionais para a classificação automática de padrões de corrida surgiram recentemente. Por exemplo, em [PEREIRA *et al.* 2015], um modelo computacional baseado em Redes Complexas foi proposto para verificar modificações de padrões corporais durante a corrida em esteira ergométrica, com

especial interesse na ocorrência de fadiga. No estudo, os autores utilizaram muitas variáveis associadas à corrida. Vale ressaltar que o estudo não teve como objetivo identificar alterações que precediam a ocorrência da fadiga. Além disso, as variáveis avaliadas não foram processadas em tempo real durante os testes de corrida. A aplicação do método durante sessões de treinamento de corredores é, portanto, limitada, diferentemente de métodos que forneceram *feedback* auditivo [TATE & MILNER, 2017] ou visual [AGRESTA & BROWN, 2015] com o objetivo de proporcionar melhoras na biomecânica de corrida.

Tais constatações apontam que uma alternativa interessante para verificar as modificações dos padrões durante a corrida é por meio de técnicas de Aprendizado de Máquina operando em tempo real, i.e., durante o treino de corrida. Na presente pesquisa, a proposta foi utilizar Redes Neurais Artificiais (RNAs) para classificar padrões de corrida de maneira *online*, podendo estas sinalizar a ocorrência de fadiga, alertando assim preventivamente o aparecimento de sinais iniciais que levam a lesões. As RNAs têm sido amplamente utilizadas em inúmeras aplicações, com destaque para aquelas que envolvem aproximação de funções, previsão de séries temporais, classificação e processamento de linguagem natural [HAYKIN, 2001].

Assim, o objetivo deste estudo foi desenvolver um método baseado em RNA do tipo Perceptron Multicamadas (MLP) para a identificação de padrões de corrida associados à fadiga em uma esteira ergométrica *open source* de baixo custo. A metodologia proposta neste trabalho é apresentada na Seção 2. A Seção 3 apresenta os resultados obtidos nos experimentos, enquanto a Seção 4 apresenta as conclusões e trabalhos futuros.

## 2. Metodologia

A Figura 1 apresenta um fluxograma das etapas para a realização desta pesquisa, e que serão discutidas nesta seção. A pesquisa realizada é integrante de um projeto que visa à construção de uma esteira ergométrica *open source* de baixo custo e dotada de sensores de força.

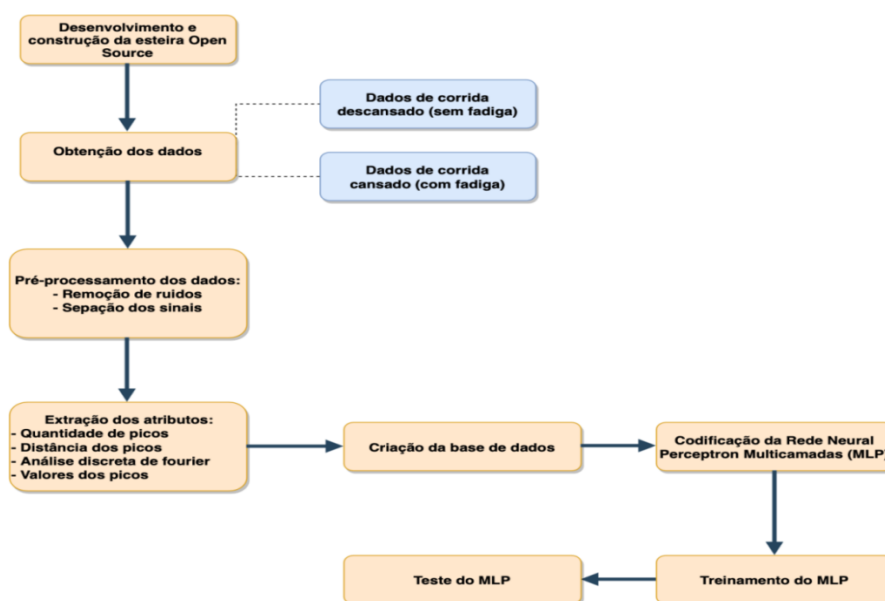



Figura 1. Etapas da metodologia aqui proposta.

## 2.1. Esteira Ergométrica


A esteira *open source* conta com quatro células de cargas CTR, com capacidade de 1 tonelada força (MK Controle e Instrumentação LTDA - São Paulo, Brasil). As células são dispostas na base da esteira, sendo, portanto, utilizadas como sensores de força. Os sinais captados por cada célula de carga passam por um amplificador de sinal MKTC-05 (MK Controle e Instrumentação LTDA – São Paulo, Brasil) antes de serem enviados por canais diferentes para uma placa de aquisição de dados analógico/digital (National Instruments – Austin, Texas, EUA), para gravação de dados na frequência de 1 GHz.

A esteira é composta principalmente por: i) estrutura metálica superior (onde se fixam o motor, rolos e lona); ii) estrutura metálica inferior (onde se fixam os módulos de força e de controle de inclinação); iii) rolos; iv) lona; v) suporte do motor. A Figura 2 apresenta uma foto da esteira, bem como uma das células de carga acoplada à base. A Figura 3 apresenta o sistema de aquisição e o amplificador.



**Figura 2. Esteira *open source* (esquerda). A esteira possui quatro sensores de força (células de carga) acoplados às bases de apoio (direita).**

Para a aquisição dos sinais da força vertical em tempo real foi utilizado o *software* MATLAB juntamente com os pacotes de aquisição de dados *DAQ acquisition*. Com a utilização deste programa foi possível criar um algoritmo para a captura dos sinais vindos do sistema de aquisição, e salvar os dados desses sinais em arquivos do tipo ASCII.

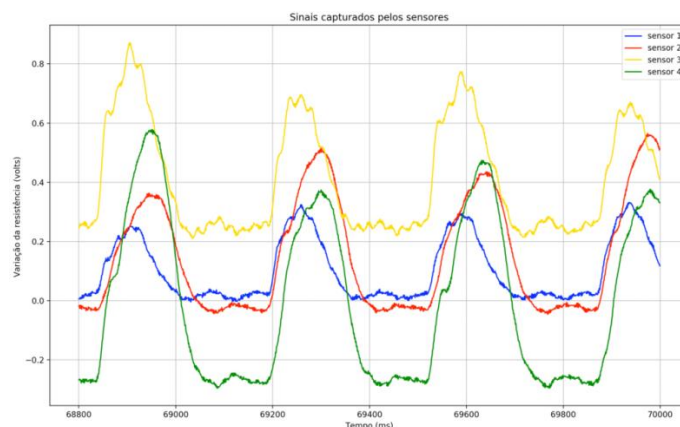


**Figura 3. Caixa construída para receber os condicionadores de sinais e o sistema de aquisição de força das células de carga.**

## 2.2. Base de Dados

O treinamento do MLP é do tipo supervisionado. Os dados de entrada do MLP são obtidos extraindo-se características dos sinais de força gerados durante sessões de

corrida. A Figura 4 mostra um exemplo dos sinais adquiridos por cada sensor de força. Para as saídas desejadas utilizadas durante o treinamento e teste, utiliza-se a percepção subjetiva de esforço [BORG, 1982]. Para a construção das bases de dados, um voluntário realizou sessões de treinos de 70 segundos na esteira, mantendo-se velocidade constante. Ao final de cada sessão, o voluntário informou qual a sua percepção de esforço durante o exercício. A escala utilizada para a percepção subjetiva de esforço varia de 1 a 10. Aqui, duas classes foram definidas baseando-se nos valores da escala: i) classe “descansado” para valores de 1 a 5; ii) classe “cansado” para valores de 6 a 10.



**Figura 4. Exemplos de sinais obtidos por cada sensor de força. Os sinais que aparecem no gráfico foram obtidos no final de cada sessão de treino.**


Para a construção da base de dados, o voluntário realizou treinos em três dias distintos. No primeiro dia, foram realizadas 10 sessões de treino, sendo 5 sessões classificadas como “descansado” e 5 sessões como “cansado”. No segundo dia, ocorreram apenas 5 sessões, pois o voluntário sentiu dores durante os treinos. Neste dia, foram 4 sessões indicando “descansado” e 1 sessão indicando “cansado”. No terceiro dia, foram realizadas novamente 10 sessões, sendo 4 da classe “cansado” e 6 da classe “descansado”. Cada sessão durava 70 segundos.

A partir dos dados obtidos, foi desenvolvido um programa escrito em linguagem de programação Python3.7.7 para suavizar os ruídos presentes nos sinais de força. O programa desenvolvido utilizou um filtro digital de *Butterworth* de ordem 4, com frequência de corte de passa-baixo de 59 Hz, disponível na biblioteca *scipy*. A Figura 5 mostra os sinais captados pelo primeiro sensor antes e depois da aplicação do filtro para os últimos passos de uma sessão de treino. Após a aplicação do filtro, foram selecionados os sinais referentes aos últimos 40 passos de cada um dos 4 sensores.

Posteriormente, os sinais dos sensores foram divididos em dois: para os passos com o pé direito e para os passos para o pé esquerdo. Isto foi feito pois, quando ocorre o contato com o pé direito na esteira, as forças nos sensores 1 e 2 são maiores, ao passo que o contrário ocorre para o pé esquerdo. A Figura 6 mostra a disposição dos sensores na esteira.

Para a extração das características utilizadas pelo classificador, foram utilizados sinais da série temporal correspondentes a dois passos consecutivos. A cada dois passos, os valores médios das características descritas na Seção 2.2 são utilizados. Ao final de cada sessão, 10 amostras (média de dois passos), foram obtidas, cada qual dividida em


um conjunto para o pé direito e outro para o esquerdo. A Figura 7 mostra um exemplo de dois passos para o sensor 1, com o contato na esteira com o pé direito. Desta forma, para os três dias de treinamento, foram obtidas 250 amostras, sendo 130 da classe “descansado” e 120 da classe “cansado”. Diferentes partições destas amostras foram consideradas durante o treinamento e teste do MLP (ver Seção 3).



**Figura 5. Últimos quatro passos captados pelo sensor 1 antes e depois da aplicação do filtro. Superior: sinal não filtrado. Inferior: sinal filtrado.**



**Figura 6. Desenho esquemático de duas vistas da esteira instalada.**



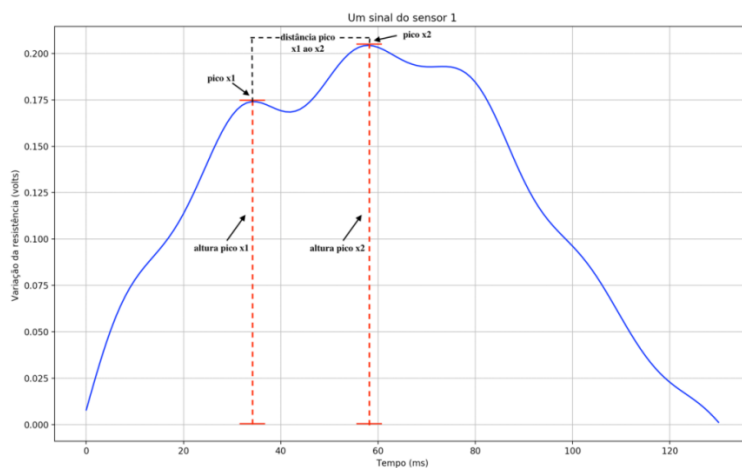
**Figura 7. Exemplo de dois passos consecutivos para o sensor 1, com o contato na esteira com o pé direito.**

## 2.2. Escolha de atributos de entrada do MLP

Para a extração das características relevantes das séries temporais, duas estratégias foram adotadas: i) entrevista com um pesquisador, especialista na área de esportes; ii) estudo na literatura relacionada à extração de características para classificação de arritmia cardíaca com sinais de eletrocardiograma (ECG) [ANWAR *et al.* 2018]. Esta última foi feita devido às semelhanças entre a forma dos sinais de força e os de ECG. Por fim, atributos de dois tipos foram obtidos. Os do primeiro tipo são atributos relativos à forma dos sinais. Os atributos de forma são:

- Quantidade de picos no sinal;
- Altura do maior pico;
- Altura do segundo maior pico;
- Distância do maior pico para o segundo maior pico;

A Figura 8 mostra como os atributos de forma são extraídos para cada passo.



**Figura 8. Atributos de forma obtidos a partir dos sinais de força.**

Os atributos do segundo tipo são obtidos por meio da análise de Fourier. Para tanto, foram consideradas as 10 primeiras amplitudes obtidas pela aplicação da transformada de Fourier nas amostras (correspondentes a um passo). A aplicação da análise de Fourier foi feita a partir de um programa construído na linguagem de programação em Python3. Tanto para os atributos de forma como para os atributos obtidos pela análise de Fourier, a média para dois passos é considerada, i.e., uma amostra é formada pela média dos valores para dois passos consecutivos, como explicado anteriormente.

Cada sensor resultou em 28 atributos, sendo 14 (4 de forma e 10 da análise de Fourier) para cada pé (direito e esquerdo). Também foram utilizados 8 atributos de forma adicionais, sendo estes obtidos pela média dos sinais de todos os sensores para cada pé, i.e., 4 para o direito e 4 para o esquerdo. No total, 120 atributos foram utilizados como entradas do MLP. A Tabela 1 mostra o conjunto de atributos utilizados.

**Tabela 1. Conjunto de atributos utilizados como entrada do MLP.**

	Sensor 1 (S1)		Sensor 2 (S2)		Sensor 3 (S3)		Sensor 4 (S4)		(S1 + S2 + S3 + S4) / 4	
	Sinal do pé direito	Sinal do pé esquerdo	Sinal do pé direito	Sinal do pé esquerdo	Sinal do pé direito	Sinal do pé esquerdo	Sinal do pé direito	Sinal do pé esquerdo	Sinal do pé direito	Sinal do pé esquerdo
Quantidade de picos no sinal	xd1.1	xe1.1	xd2.1	xe2.1	xd3.1	xe3.1	xd4.1	xe4.1	xd5.1	xe5.1
Altura do maior pico	xd1.2	xe1.2	xd2.2	xe2.2	xd3.2	xe3.2	xd4.2	xe4.2	xd5.2	xe5.2
Altura do segundo maior pico	xd1.3	xe1.3	xd2.3	xe2.3	xd3.3	xe3.3	xd4.3	xe4.3	xd5.3	xe5.3
Distância do maior pico para o segundo maior pico	xd1.4	xe1.4	xd2.4	xe2.4	xd3.4	xe3.4	xd4.4	xe4.4	xd5.4	xe5.4
Primeira amplitude obtida da análise de Fourier	xd1.5	xe1.5	xd2.5	xe2.5	xd3.5	xe3.5	xd4.5	xe4.5	x	x
.	.	.	.	.	.	.	.	.	x	x
.	.	.	.	.	.	.	.	.		
Décima amplitude obtida da análise de Fourier	xd1.14	xe1.14	xd2.14	xe2.14	xd3.14	xe3.14	xd4.14	xe4.14	x	x
Total atributos	28		28		28		28		8	

### 2.3. MLP

O programa que utiliza o MLP para classificação *online* dos sinais de força foi desenvolvido na linguagem de programação Python3 com o auxílio da biblioteca *scikit-learn*. O MLP foi treinado por *backpropagation*. Após testes iniciais com variadas configurações, os seguintes parâmetros do MLP foram utilizados:

- Uma camada oculta com 122 neurônios;
- Taxa de aprendizado: 0,001;
- Número de épocas de treinamento: 2000.

A escolha de 122 neurônios na camada oculta foi baseada na regra heurística (1) utilizada em configurações de rede com uma única camada oculta:

$$n_h = n_a + n_c \quad (1)$$

na qual  $n_a$  é o número de atributos (entradas),  $n_c$  é o número de classes e  $n_h$  é o número de neurônios na camada oculta.

Para treinamento do MLP foi utilizada *10-fold cross-validation*. Diferentes configurações da base de dados foram testadas considerando-se que o voluntário correu na esteira em diferentes dias. Estas configurações foram consideradas com o intuito de testar a metodologia em diferentes cenários. São eles:

- Cenário 1: dados do primeiro dia utilizados para treinar o MLP e dados do segundo dia para testá-lo;



- Cenário 2: dados do primeiro dia utilizados para treinamento e dados do terceiro dia para teste;
- Cenário 3: dados do primeiro dia para treinamento (sessões de 1 a 4 e 6 a 9) e teste (sessões 5 e 10);
- Cenário 4: dados do primeiro e segundo dias utilizados para treinamento e dados do terceiro dia para teste;
- Cenário 5: dados do primeiro e terceiro dias utilizados para treinamento e dados do segundo dia para teste.

### 3. Resultados

Os resultados para diferentes cenários são a seguir apresentados. São apresentadas as matrizes de confusão para os exemplos utilizados para teste do MLP.

#### 3.1. Resultados do cenário 1

A matriz de confusão obtida para o cenário 1 é apresentada na Figura 9.

		PREVISTO	
		Descansado	Cansado
R E A L	Descansado	31	9
	Cansado	0	10

**Figura 9. Matriz de confusão para o primeiro cenário.**

A acurácia final foi de 82%. Vale lembrar que, neste cenário, a base de treinamento é obtida a partir de sessões de corrida do primeiro dia, enquanto os dados do segundo dia são usados para o teste. Vale lembrar que, no segundo dia, o voluntário apresentou dores, tendo que finalizar o treino antes do tempo. Assim, a base de teste apresenta um desbalanceamento, tendo mais sinais da classe “descansado”. Para a classe “cansado”, o MLP acertou todos os dados. Para a classe “descansado”, a taxa de acerto foi de 75,5%, sendo 9 amostras classificadas erroneamente como “cansado”.

#### 3.2. Resultados do cenário 2

A matriz de confusão obtida para o cenário 2 é apresentada na Figura 10.

		PREVISTO	
		Descansado	Cansado
R E A L	Descansado	29	11
	Cansado	20	40

**Figura 11. Matriz de confusão para o segundo cenário.**

O MLP não conseguiu distinguir 11 amostras da classe “descansado” e 20 da classe “cansado”. A acurácia foi de 69%. No cenário 2, a base de dados para teste é composta de 100 amostras, ao passo que no cenário 1 existiam 50 amostras.

### 3.3. Resultados do cenário 3

A matriz de confusão obtida para o cenário 3 é apresentada na Figura 11.

		PREVISTO	
		Descansado	Cansado
R E A L	Descansado	10	0
	Cansado	0	10

Figura 12. Matriz de confusão para o terceiro cenário.

O MLP conseguiu classificar todas as amostras corretamente. Em comparação com os cenários anteriores, as bases de treinamento e teste foram obtidas em um único dia. As quatro sessões iniciais para cada classe foram utilizadas para treinamento, ao passo que a última sessão para cada classe foi utilizada para teste. Quando comparados com os resultados de outros cenários, os resultados do cenário 3 indicam que variações nos padrões de corrida ocorreram nos diferentes dias de treino. Além disso, a percepção subjetiva utilizada para definir a classe desejada dos exemplos pode influenciar na classificação das amostras obtidas nas sessões finais para cada classe (especialmente a sessão 5). Remover as sessões 5 e 10, e considerar exemplos de um único dia, resultou em uma melhora substancial na acurácia do classificador.

### 3.4. Resultados do cenário 4

A matriz de confusão obtida para o cenário 4 é apresentada na Figura 12.

		PREVISTO	
		Descansado	Cansado
R E A L	Descansado	28	12
	Cansado	20	40

Figura 13. Matriz de confusão para o quarto cenário.

Neste cenário, a acurácia foi de 68%. Quando comparado com os resultados para o cenário 2, o erro foi ligeiramente maior, mostrando que acrescentar dados do segundo dia de treino não ajudaram o classificador a melhorar a acurácia para o conjunto de teste obtido com as amostras do terceiro dia.

### 3.5. Resultados do cenário 5

A matriz de confusão obtida para o cenário 5 é apresentada na Figura 13.

		PREVISTO	
		Descansado	Cansado
R E A L	Descansado	28	12
	Cansado	0	10

**Figura 14. Matriz de confusão para o quinto cenário.**

A acurácia aqui foi de 76%. Quando comparados com os resultados do cenário 1, os resultados foram piores, o que indica que acrescentar dados do terceiro dia de treino não ajudaram o classificador a melhorar a acurácia para o conjunto de teste obtido com as amostras do segundo dia.

#### **4. Conclusão**

Neste trabalho, uma metodologia para a classificação *online* de padrões de corrida obtidos a partir de sinais de força obtidos em sensores instalados em uma esteira *open source* de baixo custo é apresentada. O objetivo é indicar ao usuário a ocorrência de fadiga durante o treino, o que pode auxiliar o planejamento dos treinamentos e evitar problemas como aumento na probabilidade de ocorrência de lesões. Um MLP classifica os sinais já pré-processados correspondentes a dois passos do usuário, classificando o padrão da corrida. Foi proposto a utilização de 4 atributos de forma dos sinais e 10 atributos provenientes da análise de Fourier. No total, considerando-se todos os sensores, 120 atributos são utilizados como entradas do MLP. No futuro, Algoritmos Genéticos serão utilizados para a seleção dos atributos mais relevantes para a classificação. Outros atributos deverão ser investigados e considerados.

Os resultados experimentais indicam que o MLP é capaz de classificar com boa acurácia os padrões de corrida. Experimentos considerando-se diferentes bases de treinamento e teste obtidas em diferentes cenários indicam que a eficiência do classificador foi influenciada pelo dia e etapa das sessões de treinamento. Isso ocorre devido principalmente à forma em que os dados foram rotulados. Foi utilizando uma escala subjetiva de esforço (que varia de 1 a 10), sendo os dados rotulados de 1 a 5 para uma classe e de 6 a 10 para outra. Erros ocorreram principalmente para exemplos entre sessões de treinamento para as duas classes (“descansado” e “cansado”) e em dias diferentes. Os melhores resultados do MLP foram alcançados para o cenário 3, em que os exemplos de treinamento e teste foram obtidos: i) no mesmo dia; ii) removendo-se os dados das sessões 5 e 10, i.e., as últimas sessões para cada classe. Assim, um trabalho futuro, será considerar mais classes a partir da escala subjetiva e/ou considerar o problema como um problema de regressão, ao invés de classificação, no qual o MLP deverá ser treinado para prever os valores da escala de esforço. Também, serão investigados cenários com mais usuários, sessões de treinamento e diferentes classificadores.

#### **Agradecimentos**

Os autores agradecem à Pró-Reitoria de Pesquisa da USP (Programa de Apoio a Projetos que Façam Uso de Sistemas Digitais Inteligentes), à FAPESP (Proc.

2020/01022-1, 2013/07375-0 e 2019/07665-4) e ao CNPq (Proc. 305755/2018-8) pelo apoio financeiro.

## Referências

- AGRESTA, C. & BROWN, A. (2015). “Gait Retraining for Injured and Healthy Runners Using Augmented Feedback: A Systematic Literature Review”, *Journal of Orthopaedic & Sports Physical Therapy*, 45(8): 576-584.
- ANWAR, S. M.; GUL M.; MAJID M. & ALNOWAMI M. (2018) “Arrhythmia Classification of ECG Signals Using Hybrid Features”, *Computational and Mathematical Methods in Medicine*, ID 1380348.
- BORG, G. A. (1982). “Psychophysical bases of perceived exertion”, *Medicine & Science in Sports & Exercise*, 14(5): 377-381.
- BRAMBLE, D. M. & LIEBERMAN, D. E. (2004). “Endurance running and the evolution of Homo”, *Nature*, 432(7015): 345-352.
- GRUBER, A. H.; UMBERGER, B. R.; BRAUN, B. & HAMILL, J. (2013). “Economy and rate of carbohydrate oxidation during running with rearfoot and forefoot strike patterns”, *Journal of Applied Physiology*, 115(2): 194-201.
- HAYKIN, S. S. (2001). “*Redes neurais: principios e prática*”, 2ª ed., Bookman.
- HEISE, G. D. & MARTIN, P. E. (2001). “Are variations in running economy in humans associated with ground reaction force characteristics?”, *European Journal of Applied Physiology*, 84(5): 438-442.
- LAKOMY, H. K.; CAMPBELL, I. & WILLIAMS, C. (1987). “Treadmill performance and selected physiological characteristics of wheelchair athletes”, *British Journal of Sports Medicine*, 21(3): 130-133.
- LIEBERMAN, D. E. *et al.* (2010). “Foot strike patterns and collision forces in habitually barefoot versus shod runners”, *Nature*, 463(7280), 531-535.
- MCCORMICK, F.; NWACHUKWU, B. U. & PROVENCHER, M. T. (2012). “Stress fractures in runners”, *Clinics in Sports Medicine*, 31(2): 291-306.
- OGUETA-ALDAY, A.; RODRIGUEZ-MARROYO, J. A. & GARCIA-LOPEZ, J. (2014). “Rearfoot Striking Runners Are More Economical Than Midfoot Strikers”, *Medicine and Science in Sports and Exercise*, 46(3): 580-585.
- PEREIRA, V. H. *et al.* (2015). “Complex network models reveal correlations among network metrics, exercise intensity and role of body changes in the fatigue process”, *Scientific Reports*, 5: 10489.
- PONS-VILLANUEVA, J.; SEGUI-GOMEZ, M. & MARTINEZ-GONZALEZ, M. A. (2010). “Risk of injury according to participation in specific physical activities: a 6-year follow-up of 14 356 participants of the SUN cohort”, *International journal of Epidemiology*, 39(2): 580-587.
- TATE, J. J. & MILNER, C. E. (2017). “Sound-Intensity Feedback During Running Reduces Loading Rates and Impact Peak”, *Journal of Orthopaedic & Sports Physical Therapy*, 47(8): 565-569.