



21 - 25
AGOSTO DE 2016
FORTALEZA - CEARÁ

ABORDAGEM DE MÁQUINA DE APRENDIZADO EXTREMO APLICADA À BIOMECÂNICA DA NATAÇÃO

Marcos Cesar Gritti, cesargritti@gmail.com¹

Rafael Commim Busatto, rafael_busatto@yahoo.com.br²

Leandro dos Santos Coelho, leandro.coelho@pucpr.br³

¹Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), Universidade Federal do Paraná (UFPR), Curitiba, PR, Brasil

²Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS), Escola Politécnica, Pontifícia Universidade Católica do Paraná (PUCPR), Curitiba, PR, Brasil

³Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS), Escola Politécnica, Pontifícia Universidade Católica do Paraná (PUCPR) e Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), Universidade Federal do Paraná (UFPR), Curitiba, PR, Brasil

Resumo: A análise biomecânica aplicada à natação competitiva é uma área de pesquisa emergente, onde abordagens estatísticas em união com campos da computação natural têm sido adotadas para a obtenção de modelos aptos a capturar as dinâmicas complexas dos atletas, de modo a servir como base em pesquisa ou até mesmo como indicadores de desempenho. Neste âmbito, destacam-se as Redes Neurais Artificiais (RNAs), que vêm mostrando, nas últimas décadas, resultados atrativos para uma vasta gama de problemas. Este trabalho tem como objetivo empregar a utilização de uma abordagem de RNA, conhecida por Máquina de Aprendizado Extremo, do inglês Extreme Learning Machine (ELM), na obtenção de um modelo caixa preta apto a representar as dinâmicas de um atleta através de dados experimentalmente coletados. Como a ELM possui pesos sinápticos e polarizações determinados de forma aleatória, utiliza-se o algoritmo estocástico, pertencente ao grupo de algoritmos de inteligência de enxames, denominado Otimização por Enxame de Partículas (Particles Swarm Optimization, PSO), de forma a otimizar os parâmetros de entrada da rede. Em paralelo, a eficiência do PSO é comparada a um algoritmo de busca cooperativa conhecido como Algoritmo de Migração Auto Organizável (Self Organizing Migrating Algorithm, SOMA). Os resultados mostram que ambas as metaheurísticas, empregadas na otimização dos parâmetros da ELM, apresentam resultados promissores. Conforme indicado pelo Erro Médio Quadrático e pelo critério de determinação R^2 , o método ELM-SOMA, para o âmbito da biomecânica, mostra-se mais atrativo do que o ELM-PSO por obter, em geral, modelos de melhor qualidade. Em contrapartida, se a margem de erro não é estreita, o ELM-PSO é apto a obter resultados aceitáveis com baixo custo computacional.

Palavras-chave: Algoritmo de Migração Auto Organizável. Biomecânica. Máquina de Aprendizado Extremo. Otimização por Enxame de Partículas.

1. INTRODUÇÃO

As análises biomecânicas, que utilizam a mecânica clássica para explicar os fenômenos de transporte dos organismos vivos, já são utilizadas há muitos anos. Remontam à antiguidade clássica, onde Aristóteles registrou as primeiras observações sobre o ato de caminhar do Homem e dos animais, na tentativa de determinar a ação dos membros inferiores e patas contra o solo. Nos tempos atuais, desempenham um papel fundamental no projeto de próteses, análises clínicas e até mesmo em alguns campos da robótica, por exemplo, servindo como base teórica no desenvolvimento de humanoides.

Na área competitiva, equipes de apoio, as quais realizam análises biomecânicas, objetivam-se a orientar nadadores à perfeição na coordenação de seus movimentos, de modo a tornar o nado do próprio mais eficiente. O desempenho de um nadador, conforme Maglisho (1999), não se baseia somente na velocidade média de nado, mas também no seu ritmo contínuo, de forma a reduzir fadigas e consequentemente o cansaço físico do atleta.

A modelagem através da mecânica clássica, chamada de modelagem caixa branca, é capaz de explicar vários fenômenos físicos observáveis na natureza, os quais, em geral, apresentam comportamento linear, ou até mesmo comportamentos não lineares de complexidade razoável. Porém, quando o objetivo é encontrar um modelo matemático preditivo de algo complexo, a modelagem caixa branca passa ser uma tarefa árdua, ou até mesmo de solução analítica inexistente. Neste âmbito surge a utilidade das Redes Neurais Artificiais (RNAs) que, apesar de não retornarem uma equação explícita, apresentam resultados promissores no mapeamento multidimensional de dados que apresentam não linearidade, independente do grau desta. Os modelos identificados por RNAs são denominados caixa preta, pelo fato de que, uma vez obtido o modelo, este não é reversível a fatores inteligíveis.

Esse trabalho tem por objetivo empregar a utilização de RNA para a identificação das dinâmicas de nado de atletas competitivos. Mais especificamente, utiliza-se uma abordagem de RNA conhecida por Máquina de Aprendizado Extremo, do inglês *Extreme Learning Machine* (ELM), que tem a capacidade de transformar o problema de treinamento da rede em um simples sistema de equações lineares. A abordagem ELM não considera o ajuste dos parâmetros da camada de entrada da rede, e por este motivo, metaheurísticas de otimização são adotadas de modo a aperfeiçoar os modelos finais obtidos. Os algoritmos empregados a otimizar os pesos sinápticos da RNA são a Otimização por Enxame de Partículas e o Algoritmo de Migração Auto Organizável.

O algoritmo SOMA vem apresentando bons resultados desde sua criação. Foi utilizado em Coelho e Alotto (2009) para a otimização de um dispositivo conhecido por solenoide de Loney, que consiste em um gerador de campo magnético extremamente uniforme.

O restante deste artigo está organizado da seguinte forma. Na Seção 2 uma breve revisão teórica sobre RNAs é apresentada, assim como a abordagem ELM. A Seção 3 dedica-se a contextualizar o âmbito de otimização e os algoritmos utilizados no presente trabalho. Na Seção 4 são apresentadas a metodologia de aquisição dos dados e os parâmetros utilizados nos algoritmos para a obtenção dos resultados. A Seção 5 é dedicada a apresentação e análise dos resultados; por fim, a Seção 6 contém comentários sobre trabalhos futuros e a conclusão dos autores sobre o trabalho de pesquisa.

2. REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através de experiência. Foram desenvolvidas, originalmente, na década de 40, pelo neurofisiologista Warren McCulloch e pelo matemático Walter Pitts, onde elaboraram um modelo de resistores variáveis e amplificadores operacionais representando conexões sinápticas de um neurônio biológico, o que motivou Frank Rosenblatt a criar a primeira geração de RNAs (HU e HWANG, 2001).

São frequentemente utilizadas para detectar tendências que são complexas para serem percebidas por analistas. Podem ser utilizadas para problemas de classificação, regressão e agrupamento de dados (*data clustering*). Seu sucesso provém da sua flexibilidade para mapeamentos multidimensionais não lineares de entrada e saída, em conjunto com sua capacidade de aproximação universal (HAYKIN, 2008).

O modelo biológico de um neurônio, apresentado na Fig. (1), resume-se em um somatório de entradas, captadas pelos dendritos, amplificadas por pesos sinápticos e aplicadas a uma função, linear ou não, chamada de função de ativação, cujo sinal de saída é transmitido pelas terminações do axônio. As sinapses são estruturas elementares que tem por funcionalidade mediar interconexões entre neurônios, podendo ocorrer, usualmente, de forma química. A representação matemática do neurônio, ilustrada na Fig. (2), é definida como:

$$u = \theta_0 + \sum_{i=1}^m x_i \theta_i \quad (1)$$

$$y = f(u) \quad (2)$$




Figura 1. Neurônio biológico




Figura 2. Modelo matemático do neurônio.

2.1. Máquina de Aprendizado Extremo

A Máquina de Aprendizado Extremo, do inglês, *Extreme Learning Machine* (ELM), foi proposta por Huang *et al.* (2004), onde os autores a apresentaram em uma comparação de métodos de treinamento para a aplicação de RNAs no diagnóstico de pacientes com diabetes. A abordagem apresentada no trabalho mostrou ter menor custo computacional do que o clássico método de treinamento de redes denominado Método Descida de encosta, que se baseia no Algoritmo da Retropropagação do Erro (*Error BackPropagation*, BP), como também em relação à Máquina de Vetores Suporte, além de obter resultados promissores.

A abordagem é restringida a redes com apenas uma camada oculta, as quais são denominadas, do inglês, *Single Layer Feedforward Networks* (SLFNs). Desta maneira, é convencional representar a ELM através das equações

$$X = \begin{bmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{m1} & \cdots & x_{mn} \end{bmatrix} \quad (3)$$

$$Z = [1 \quad -X \quad -] \quad (4)$$

$$u = Z\theta \quad (5)$$

$$H = [1 \quad -f(u) \quad -] \quad (6)$$

$$\hat{y} = H\beta \quad (7)$$

onde X é a matriz de entrada, Z é a matriz *design* da entrada (a matriz original de entrada acrescentada/concatenada a um vetor coluna de constantes), u é a combinação linear de entrada da rede, $f(\cdot)$ é uma função de ativação genérica, H é a matrix *design* da camada intermediária e por fim, a predição $\hat{y}$ é escrita como uma combinação dos vetores pertencentes a saída da camada oculta.

Uma das principais características da ELM, que foram provadas pelos autores Huang *et. al* (2004), é de que os pesos sinápticos de entrada e os *bias* da camada oculta podem ser escolhidos aleatoriamente se a função de ativação $f(\cdot)$ for infinitamente diferenciável. A SLFN, neste caso, é transformada em um sistema linear, onde os coeficientes β da combinação linear são estimados através da pseudo-inversa generalizada de Moore-Penrose. A metodologia se assemelha a obtenção de um modelo de regressão utilizando o Método dos Quadrados Mínimos, como pode ser visto na Eq. (8).

$$\beta = H^+y \quad (8)$$

3. OTIMIZAÇÃO

Os algoritmos de otimização têm por finalidade encontrar uma solução ótima para problemas multidimensionais de complexidade elevada, em paralelo, visam despendar menor tempo na obtenção desta. Abordagens modernas de otimização utilizam mecanismos inteligentes de busca, normalmente de forma interativa com uma população de indivíduos que tem a capacidade de trocar informações e buscar, de forma cooperativa, a solução ótima do problema. Esse grupo de algoritmos classificam-se como metaheurísticas, pois podem ser utilizados de forma genérica na solução de uma vasta gama de problemas, sem ser necessária a adaptação do código, nem o cálculo de derivadas parciais.

Para que cada indivíduo de uma população tenha capacidade de avaliar seu estado atual (saber se a posição experimentada na atual iteração é melhor do que a da anterior) é necessário agregar a ele um mecanismo de auto avaliação. Este mecanismo, para abordagens de otimização, é denominado de Função Objetivo e tem por finalidade descrever o problema a ser resolvido, de forma que o algoritmo possa mensurar seu estado de solução.

O termo Função Objetivo, do inglês *Fitness Function*, foi utilizado originalmente por pesquisadores na área de Algoritmos Genéticos, âmbito o qual se baseia na Teoria de Evolução de Charles Darwin, referindo-se a aptidão do indivíduo.

3.1. Otimização por Enxame de Partículas

A Otimização por Enxame de Partículas, do inglês *Particles Swarm Optimization* (PSO), é um algoritmo da área da inteligência de enxames (*Swarm Intelligence*) inspirado no voo coletivo de pássaros e em cardume de peixes.

O princípio básico de seu funcionamento se deve à interatividade social entre os indivíduos do enxame, decisões singulares e presença de memória. Cada indivíduo do grupo, chamado de partícula, lembra-se da melhor posição já experimentada por si e da melhor posição conhecida pelo enxame.

O algoritmo foi proposto por Kennedy e Eberhart (1995), onde as seguintes equações discretas, baseadas na cinemática Newtoniana, foram apresentadas:

$$V_{k+1}^{(p)} = V_k^{(p)} + c_1 (pbest^{(p)} - X_k^{(p)}) + c_2 (gbest - X_k^{(p)}) \quad (9)$$

$$X_{k+1}^{(p)} = X_k^{(p)} + V_k^{(p)} \quad (10)$$

onde $V_k^{(p)}$ e $X_k^{(p)}$ representam, respectivamente, a velocidade e a posição da partícula p no instante k , $pbest^{(p)}$ é a melhor posição já experimentada pela partícula p (memória cognitiva), $gbest$ é a melhor solução encontrada pelo enxame (conhecimento social), por fim, c_1 e c_2 são números aleatórios uniformemente distribuídos no intervalo $[0; c_k^*]$. As constantes c_1^* e c_2^* são nominadas, nesta ordem, de constante cognitiva e constante de sociabilidade do enxame.

O algoritmo PSO, na última década, tem recebido atenção por pesquisadores devido a sua fácil implementação, baixo custo computacional e desempenho promissor. Muitas modificações têm sido propostas nos últimos anos, como por exemplo, a atualização dinâmica de c_1 e c_2 durante a evolução do algoritmo, a inserção de inércia na Eq. (9), limitadores de velocidade, entre outras. Mais detalhes, conceitos básicos, como também um breve histórico de evolução da área de pesquisa podem ser encontrados em Valle (2008).

O presente estudo utilizou o *Dynamic Particles Swarm Optimization* (DPSO), o qual utiliza o conceito de inércia e considera um fictício período de amostragem no processo de integração discreta da cinemática Newtoniana, resultando em:

$$V_{k+1}^{(p)} = W V_k^{(p)} + \left(c_1 (pbest^{(p)} - X_k^{(p)}) + c_2 (gbest - X_k^{(p)}) \right) t \quad (11)$$

$$X_{k+1}^{(p)} = X_k^{(p)} + V_k^{(p)} t \quad (12)$$

3.2. Algoritmo de Migração Auto Organizável

O Algoritmo de Migração Auto Organizável, do inglês *Self-Organizing Migrating Algorithm* (SOMA), é algoritmo estocástico do âmbito de otimização com foco em pesquisas recentes, proposto por Zelinka e Lampinen (2000). É baseado em busca cooperativa, onde todos os indivíduos da população movem-se em direção ao líder do grupo (aquele que, até dado momento, experimentou a melhor solução). É custoso computacionalmente comparado ao PSO, porém, é menos suscetível à “maldição da multidimensionalidade”.

Seu mecanismo de atualização de posição é dado por:

$$\vec{X}_m^i = \vec{SP}_m^i + t(\vec{LP} - \vec{SP}_m^i)\vec{PV} \quad (13)$$

onde $\vec{X}_m^i$ e $\vec{SP}_m^i$ são, respectivamente, a posição temporária e a posição inicial do indivíduo i na migração m , $\vec{LP}$ é o vetor posição do líder na atual etapa de migração, t representa um ganho escalar e $\vec{PV}$ é um vetor de perturbação.

Para cada indivíduo do grupo, exceto o líder, em cada etapa de migração, são criados n vetores migratórios utilizando diferentes valores de ganho t , onde $n = step/PL$, sendo $step$ o tamanho do passo em direção ao líder e PL (*path length*) o ganho de comprimento do vetor direcional não unitário $(\vec{LP} - \vec{SP}_m^i)$. Nota-se que, a escolha de $PL = 1$ pode levar a uma busca redundante de soluções, ou seja, os indivíduos na etapa de migração têm a possibilidade de se deslocar à exata posição do líder. De forma a garantir a inexistência de redundâncias, é comum utilizar $PL = 2,1$.

O vetor de perturbação $\vec{PV}$ é gerado em cada etapa de movimentação. Este tem por finalidade modificar a direção do vetor de busca $(\vec{LP} - \vec{SP}_m^i)$. A Equação (14) demonstra o mecanismo para a geração das perturbações.

$$PV_j = \begin{cases} 1, & \text{se } R_j < PRT_j \\ 0, & \text{caso contrário} \end{cases} \quad (14)$$

onde R_j é um valor aleatório uniformemente distribuído no intervalo $[0; 1]$ e PRT_j é a probabilidade de ocorrência de perturbação.

4. METODOLOGIA

Para a coleta de dados, utilizou-se um dinamômetro fixado ao nadador através de um corda e um colete de modo a mensurar a força de empuxo total realizada pelo atleta. Como o sensor mede a componente tangencial ao nível da água (considera-se um medidor ideal, ou seja, em um ponto de vista Euclidiano, atuam apenas forças perpendiculares ao eixo das ordenadas), é possível notar um comportamento periódico em que cada período representa, aproximadamente, a força de empuxo resultante da movimentação de um dos braços do nadador. Uma representação pictórica do procedimento de coleta de dados é apresentada na Fig. 2.




Figura 3. Procedimento de coleta de dados

Cada teste teve duração de 1 minuto, a um período de amostragem de 0,1 s. Todos os dados obtidos foram tratados, de modo a desconsiderar o comportamento transitório presente no início de cada teste. É possível notar que nadadores experientes tendem a ter ritmo constante de nado, portanto, a força de empuxo total para este caso é um sinal quase periódico. De maneira análoga, um nadador inexperiente, tende a apresentar como saída comportamentos caóticos. Também é importante ressaltar que nadadores em mau condicionamento físico tendem a apresentar um comportamento semelhante a sistemas variantes no tempo. De modo a demonstrar como o ritmo constante de nado afeta o nível de complexidade do modelo, escolheram-se dois conjuntos de dados, sendo que o primeiro é referente a um nadador experiente e o segundo a um nadador iniciante. Estes serão referenciados nos resultados como Atleta 1 (Experiente) e Atleta 2 (Inexperiente).

Na etapa de estimação dos modelos, utilizou-se a tangente hiperbólica como função de ativação da camada oculta da ELM. Vários modelos foram estimados variando-se a quantidade de neurônios na camada oculta. Por motivos de simplificação, optou-se por apresentar, na Seção 5, somente os melhores resultados obtidos por cada método de otimização. Os parâmetros utilizados pelas metaheurísticas na otimização dos pesos sinápticos e polarizações de entrada da ELM são apresentados na Tab. 1 (DPSO) e na Tab. 2 (SOMA).

Tabela 1. Parâmetros do algoritmo DPSO, utilizado pelos autores.

Partículas	Iterações	c_1^*	c_2^*	W	t
30	50	$0,5 \rightarrow 0,2$	$2 \rightarrow 0,5$	$0,9 \rightarrow 0,4$	0,35

Tabela 2. Parâmetros do algoritmo SOMA, utilizados pelos autores.

Tamanho da População	Migrações	$step$	PL	PRT
30	50	0,21	2,1	0,45

5. RESULTADOS

Apresentam-se a seguir nas Figs. 4, 5, 6 e 7 e as Tab. 3 e 4, os resultados obtidos pelos métodos PSO e SOMA para os nadadores A e B. Para que a comparação fosse justa, a semente de geração de números aleatórios foi configurada de forma que ambos os algoritmos contivessem as mesmas condições iniciais. Nas Tabs. 3 e 4, os resultados são representados em termos de R^2 (Coeficiente de Correlação Múltipla) e MSE (*Mean Squared Error*).




Figura 4. Resultados obtidos pela ELM otimizada pelo algoritmo PSO para o Atleta 1.




Figura 5. Resultados obtidos pela ELM otimizada pelo algoritmo SOMA para o Atleta 1.




Figura 6. Resultados obtidos pela ELM otimizada pelo algoritmo PSO para o Atleta 2.

Tabela 3. Métricas obtidas para o modelo do Atleta 1.

Algoritmo	Neurônios	Conjunto de Treinamento		Conjunto de Validação	
		MSE	R ²	MSE	R ²
PSO	30	78,08	95,53%	62,37	96,87%
SOMA	20	70,22	95,99%	77,43	96,60%

Tabela 4. Métricas obtidas para o modelo do Atleta 2.

Otimizador	Neurônios	Conjunto de Treinamento		Conjunto de Validação	
		MSE	R ²	MSE	R ²
PSO	30	56,28	93,48%	201,09	82,18%
SOMA	25	56,64	93,44%	164,34	84,12%




Figura 7. Resultados obtidos pela ELM otimizada pelo algoritmo SOMA para o Atleta 2.

6. CONCLUSÃO

A ELM em conjunto com algoritmos de otimização apresentou resultados aceitáveis, em maior parte dos dados utilizados para identificação, e resultados ótimos, para a minoria dos casos.

Em termos de desempenho considerando o R^2 e o MSE, o método SOMA vence praticamente em todos os testes do PSO, mostrando-se ser, em quesito de qualidade de modelo, o melhor método para trabalhar em conjunto com a ELM. Apesar do método SOMA perder para o PSO em tempo despendido, obteve modelos mais simples (menos neurônios) apresentando quase as mesmas métricas.

Conclui-se que, para processamento *off-line*, a Máquina de Aprendizagem Extrema otimizada pelo Algoritmo de Migração Auto-Organizável é preferível e, para processamento *online*, se escolhe a Otimização por Enxame de Partículas. Contudo, como existem poucos laboratórios de biomecânica de processamento em tempo real, é evidente que o primeiro método é preferível.

O autor deixa em aberto alguns pontos que podem ser melhorados em trabalhos futuros:

O tratamento dos dados utilizados na identificação pode vir a melhorar consideravelmente a qualidade do modelo. Neste âmbito, cita-se a diferenciação dos dados disponíveis, com o intuito de tornar a série estacionária, e a transformação logarítmica, que normaliza a distribuição do erro.

A aplicação de modelos lineares para estimar, se quer que exista, a parcela linear do sistema. Sugere-se utilizar um modelo Auto Regressivo com Médias Moveis em paralelo a uma SLFN treinada pelos métodos abordados neste relatório, de forma a utilizar a RNA para mapear somente os resíduos do modelo.

7. REFERÊNCIAS

- Coelho, L. S., Piergiorgio, A., 2009, "Electromagnetic Optimization Using a Cultural Self-Organizing Migrating Algorithm Approach Based on Normative Knowledge", IEEE Transactions on Magnetics, v. 45, n. 3, pp. 1446-1449.
- Eberhart, R., Kennedy, J., 1995, "A New Optimizer Using Particle Swarm Theory", Proceedings of the 6th International Symposium on Micro Machine and Human Science, pp. 39-43.
- Engelbrecht, A. P., 2005, "Fundamentals of Swarm Intelligence", Wiley.
- Maglischo, E., 1999, "Nadando Ainda Mais rápido", 1st ed., São Paulo, SP : Manole.
- Haykin, S., 2008, "Neural Networks and Learning Machines", 3rd ed., Pearson.
- Hu, Y. H., Hwang, J. -N., 2001, "Handbook of Neural Network Signal Processing", CRC Press.
- Kennedy, J., Eberhart, R., 1995, "Particle Swarm Optimization", IEEE International Conference on Neural Networks, v. 4, pp. 1942-1948.
- Zelinka, I., Lampinen, J., 2000, "SOMA – Self Organizing Migrating Algorithm", Proceedings of 6th MENDEL International Conference on Soft Computing, Brno, Czech Republic, pp. 76-83.

EXTREME LEARNING MACHINE APPROACH APPLIED TO SWIMMING BIOMECHANICS

Marcos Cesar Gritti, cesargritti@gmail.com¹

Rafael Commim Busatto, rafael_busatto@yahoo.com.br²

Leandro dos Santos Coelho, leandro.coelho@pucpr.br³

¹Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), Universidade Federal do Paraná (UFPR), Curitiba, PR, Brasil

²Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS), Escola Politécnica, Pontifícia Universidade Católica do Paraná (PUCPR), Curitiba, PR, Brasil

³Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS), Escola Politécnica, Pontifícia Universidade Católica do Paraná (PUCPR) e Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), Universidade Federal do Paraná (UFPR), Curitiba, PR, Brasil

Abstract. *Biomechanical analysis applied to competitive swimming is an emerging research field, where statistical approaches in combination with Natural Computing paradigms have been adopted to obtain suitable models to capture the dynamics of the athletes. In this context, there are the Artificial Neural Networks (ANNs), which have shown, in recent decades, attractive results for a wide range of fields. This study aims to employ the use of an ANN approach, known as Extreme Machine Learning (ELM), in obtaining a black box mathematical model able to represent the dynamics of an athlete through experimentally collected data. As the ELM has synaptic weights and biases determined randomly, it uses stochastic optimization algorithm belonging to the Particle Swarm Optimization (PSO) and Self Organizing Migrating Algorithm (SOMA) to optimize the ELM parameters input. The results show that both optimization metaheuristics, employed in ELM design showing promising results.*

Keywords: *Self Organizing Migrating Algorithm, Biomechanics, Extreme Learning Machine, Particle Swarm Optimization.*