

MODELO DE CLASSIFICAÇÃO AUTOMÁTICA PARA O ÍNDICE DE CONICIDADE VIA REDES NEURAIS ARTIFICIAIS (RNAs)

AUTOMATIC MODE TO OBTAIN THE CONICITY INDEX THROUGH ARTIFICIAL NEURAL NETWORKS (RNAs)

Giovana Xavier Pinto¹, Jhonatan Cabrera Piazzentin², Alfredo Bonini Neto²

¹Faculdade da Alta Paulista (FADAP), Fisioterapia, Tupã, SP. ²Faculdade de Ciências e Engenharia-FCE/UNESP, Engenharia de Biosistemas, Tupã, SP.
E-mail: giovanax07@hotmail.com

RESUMO – A concentração de gordura na região abdominal está intimamente ligada a risco de doenças cardiovasculares e metabólicas. Para isso o índice de conicidade (IC) representa um indicador de obesidade abdominal, sendo considerado um bom indicador para avaliar os fatores de risco cardiovasculares. Diante disso algumas ferramentas computacionais como as redes neurais artificiais (RNAs) vem sendo utilizada com a finalidade de analisar dados de modo inovador. O objetivo deste estudo foi obter o (IC) por meio das (RNAs) utilizando como variáveis de entrada peso, altura e circunferência da cintura e como variável de saída, partes das amostras do (IC). A metodologia constou em uma coleta de dados para obtenção das variáveis, sendo que a rede utilizada para este trabalho foi a Multilayer Perceptron com algoritmo backpropagation para fase de treinamento da rede. A rede teve um bom desempenho com erro de 6.69×10^{-3} para o treinamento e 7.10×10^{-3} para o diagnóstico.

Palavras-chave: doenças cardiovasculares; obesidade abdominal; ferramentas computacionais.

ABSTRACT – The concentration of fat in the abdominal region is closely linked to the risk of cardiovascular and metabolic diseases. For this, the conicity index (CI) represents an indicator of abdominal obesity, being considered a good indicator to evaluate the cardiovascular risk factors. Therefore some computational tools such as artificial neural networks (ANNs) have been used for the purpose of analyzing data in an innovative way. The objective of this study was to obtain the (CI) through the (RNAs) using as input variables weight, height and waist circumference and as output variable, parts of the CI samples. The methodology consisted of a data collection to obtain the variables, and the network used for this work was the Multilayer Perceptron with backpropagation algorithm for the training phase of the network. The network performed well with error of 6.69×10^{-3} for training and 7.10×10^{-3} for diagnosis.

Keywords: cardiovascular diseases; abdominal obesity; computational tools.

Recebido em: 16/08/2017
Revisado em: 18/09/2017
Aprovado em: 25/09/2017

1. INTRODUÇÃO

Atualmente a obesidade é considerada como um grave problema na Saúde Pública mundial, pois apresenta alto crescimento nas últimas décadas em várias pessoas (ROSA et al., 2005; RIBEIRO FILHO et al., 2006) ela é definida como uma patologia caracterizada pelo excesso de gordura corporal no organismo (WHO, 2000). O excesso de peso especialmente na região abdominal predispõe ao surgimento de fatores de risco cardiovasculares tais como dislipidemias, hipertensão arterial, resistência à insulina e diabetes, favorecendo uma eventualidade de eventos cardíacos, principalmente aqueles de origem coronariana (KANNEL et al., 2002; TONSTAD; HJERMANN, 2003).

Os problemas cardiovasculares são considerados a principal causa de morte em indivíduos adultos (CHOR; FONSECA; ANDRADE, 1995). Diante disso ferramentas antropométricas vêm sendo utilizadas, umas delas a circunferência da cintura utilizada na avaliação do excesso de peso e da obesidade abdominal (WHO, 1998), sendo aplicada no (IC) proposto por Valdez (1991).

O (IC), representa um indicador de obesidade abdominal, estando relacionado com as mudanças que ocorrem no perfil lipídico, sendo considerado como um bom indicador para avaliar os fatores de risco (PITANGA; LESSA, 2007). A faixa teórica do (IC) é de 1,00 a 1,73 para adultos. O (IC) ele

aumenta de acordo com o acúmulo na região de gordura abdominal, quanto mais próximo ao 1,73 indica risco de desenvolvimento de doenças cardiovasculares (VALDEZ et al., 1993).

A fim de ajudar na classificação e análise de dados, reconhecimento de padrões, análise de imagens entre outros, os modelos computacionais (RNAs) vem ganhando grande destaque no mundo acadêmico. Definidas como sistemas inspirados na estrutura real de um neurônio biológico de organismos inteligentes (HAYKIN, 1999), tendo uma característica relevante, ou seja, à capacidade de aprender através de exemplos, denominados de conjunto de treinamento, sendo estes apresentados a ela durante a etapa de treinamento (HAYKIN, 2001).

A principal virtude das (RNAs) é a capacidade de generalização, isto é, gerar respostas desejadas a dados de entrada não conhecido, a fim de alcançar, um objetivo desejado. Essa capacidade torna possível resolver problemas computacionais complexos (AMBRÓSIO, 2002). Sendo assim, o objetivo do presente trabalho foi obter o (IC) por meio das (RNAs), com as variáveis de entrada, circunferência da cintura (m), peso (kg) e estatura (m), a fim de obter a variável de saída desejada, o (IC). Neste sentido, após o treinamento da rede, ou seja, os pesos W_i todos ajustados, não foi necessário mais

utilizar a fórmula (equação 1) para calcular o (IC) e sim de forma automática.

2. METODOLOGIA

A coleta de dados foi realizada em um posto de saúde de um município do interior do estado de São Paulo no mês de julho com 124 voluntários adultos de ambos os sexos com idade entre 18 a 88 anos. Para a obtenção do (IC), foi preciso coletar as

$$IC = \frac{\text{circunferência da cintura (m)}}{0.109 \sqrt{\frac{\text{peso(kg)}}{\text{altura (m)}}}} \quad (1)$$

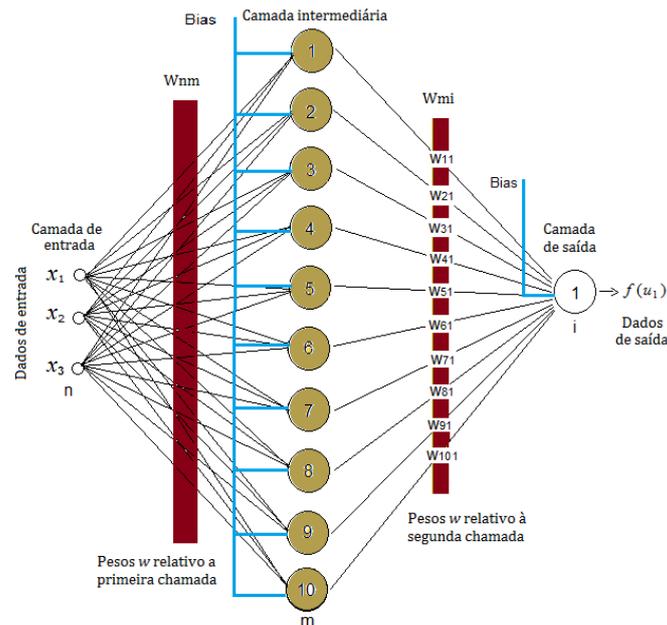
Redes Neurais Artificiais (RNAs)

Uma rede neural típica é composta de n neurônios na camada de entrada, m neurônios na camada intermediária e i neurônios na camada de saída, também conhecida como *Multilayer Perceptron* (MLP) do tipo *feed forward* (não recorrente, sem realimentação). Os dados de entrada para este trabalho foram fixados $n=3$ (Circunferência da cintura, Peso, e altura)

variáveis como circunferência da cintura, peso e altura. Para o cálculo do (IC) foi utilizada a fórmula proposta por Valdez (1991), utilizando as variáveis obtidas e aplicando-as na seguinte fórmula matemática:

camada de entrada. Para a camada intermediária foi decidido utilizar pelos autores uma configuração para m , $m=10$ e por fim $i=1$ (partes das amostras do IC). Como valor de saída foi utilizado apenas um neurônio que representa o índice de conicidade. A Figura 1 representa a rede neural multicamadas utilizadas neste trabalho.

Figura 1. RNA com 10 neurônios na camada intermediária.



Segundo Haykin (1999) uma função de ativação ou função restritiva é um fator limitante que define a amplitude de saída a um valor finito. No presente trabalho para a saída da camada intermediária foi utilizada a função tangente hiperbólica (2) cujos valores

$$f(u) = (1 - e^{-\lambda u}) / (1 + e^{-\lambda u}) \quad (2)$$

Em que λ é uma constante arbitrária e corresponde a inclinação da curva.

$$f(u) = u \quad (3)$$

A plataforma utilizada para a implementação computacional da RNA, bem como para a obtenção dos resultados, foi o software Matlab (MATHWORKS, 2017). Esta ferramenta permite o desenvolvimento de algoritmos bem com a utilização de pacotes prontos (toolbox) que possuem fácil

estão em um intervalo que é definido entre $[-1,1]$ e para a camada de saída foi utilizada a função linear (3), cujos valores são maiores que um e representam os valores de saída para o índice de conicidade.

assimilação, além de ser amplamente utilizada na engenharia.

3. RESULTADOS

Para os resultados da (RNAs) foram utilizados 124 dados antropométricos, os 100 primeiros dados foram utilizados para o treinamento para que a rede consiga adaptar

seus pesos de modo que as (RNAs) possam classificar ou estimar dados que não fizeram parte no processo de treinamento. Os 24 dados restantes foram utilizados para o processo e diagnóstico da rede, isto é a fase de teste.

Treinamento da RNA

O algoritmo de treinamento utilizado neste trabalho foi o *backpropagation* (retropropagação do erro) com treinamento supervisionado com algumas modificações (aproximação do mínimo da função erro pelo método de Newton) denominado de *Levenberg-Marquardt* (HAGAN; MENHAJ, 1994), o qual considera a aprendizagem da rede a partir de dados de entrada e suas respectivas saídas desejada (alvo) (BRAGA; CARVALHO; LUDERMIR, 2007).

O treinamento consiste em conhecer um alvo a ser acertado para que a rede

$$MAE = \frac{1}{t} \sum_{j=1}^t (Y_{j \text{ obtida}} - Y_{j \text{ desejada}}) \quad (2)$$

O gráfico da figura 1(a) apresenta a performance da rede durante o processo de treinamento, nota-se que para cada iteração o MAE diminui e oitava iteração converge para um valor próximo ao erro pré-estabelecido na rede (0.01). O valor atingido foi de 0.00669 com 8 iterações.

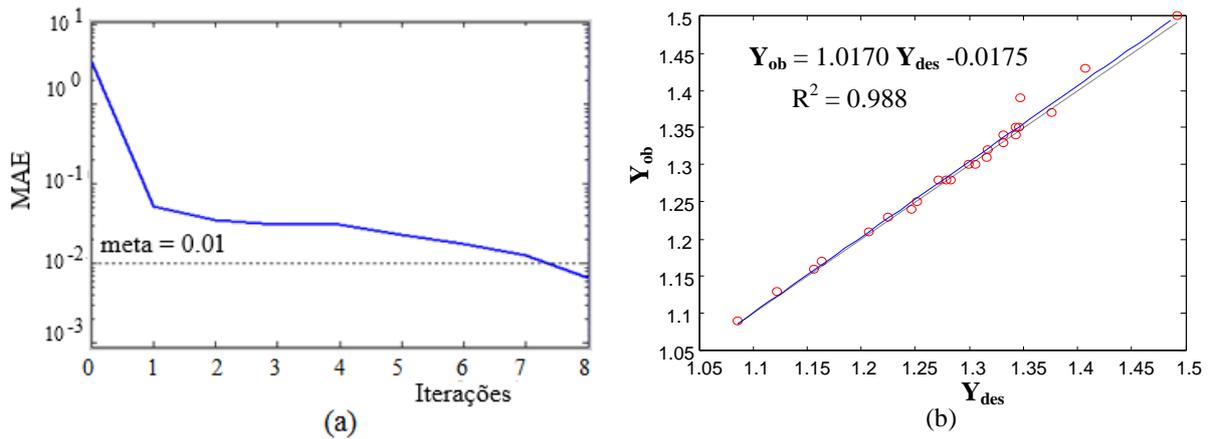
Para validação da rede, a figura 1(b) (regressão linear simples) descreve a relação

consiga adaptar seus pesos de modo que, posteriormente, no processo de operação, conhecido também como diagnóstico da rede, possa se classificar ou estimar dados que não fizeram parte no processo de treinamento. Portanto, pode-se dizer que, a aprendizagem de uma RNA se dá pelo ajuste de seus pesos, W_i , durante o treinamento e em função de dados de entrada cujas saídas são conhecidas.

Os critérios de parada relacionados ao treinamento da rede foram pré-estabelecidos da seguinte forma: número máximo de iterações igual a 100; o valor a ser obtido para o erro quadrado médio (MAE, do inglês *Mean Absolut Error*) da equação (2) igual a 0.01 (validação da rede) e o tempo máximo de treinamento igual a 10 segundos, conforme a tabela 1.

entre as variáveis Y_{des} (saída desejada) e Y_{ob} (saída obtida) com $m = 10$. Observa-se que o valor do R^2 (grau de ajuste para o modelo) é de 0.988, mostrando que aproximadamente 98,8% da variável Y_{ob} consegue ser explicada em relação a Y_{des} , ou seja, mais homogêneo são os dados (PAGANO; GAUVREAU, 2012).

Figura 2. (a) Desempenho da rede no processo de treinamento, (b) análise de regressão



A tabela 1 a seguir apresenta o desempenho obtido pela rede de treinamento. A quantidade máxima de iterações pré-estabelecida de início foi de 100 iterações quantidade variável estabelecida de acordo com testes feitos pelos autores que perceberam que o treinamento da rede convergia em poucas iterações, ou seja, estipularam um valor considerável para que houvesse um limite

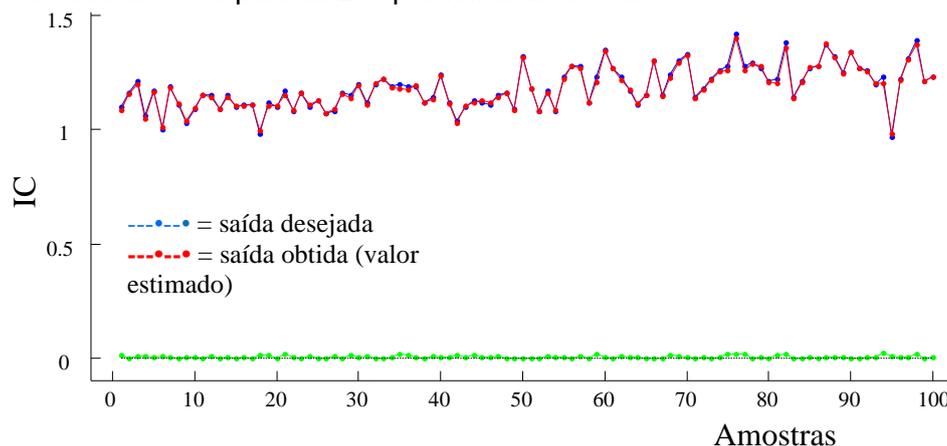
(critério de parada) para a fase de treinamento da rede, juntamente com um erro de 0.01 e tempo de 10 segundos. Após ser feito o treinamento da rede, na oitava iteração o modelo convergiu para um erro menor do que o pré-estabelecido 0.00669 em um tempo de 1 segundo. Sendo assim, o modelo obteve boa convergência uma vez comparada aos valores pré-estabelecidos.

Tabela 1. Valores especificados para o treinamento da rede.

Critérios de parada	Valores pré-estabelecidos	Valores atingidos no treinamento da rede
Iterações	100	8
Erro	0.01	0.00669
Tempo (s)	10 s	1 s

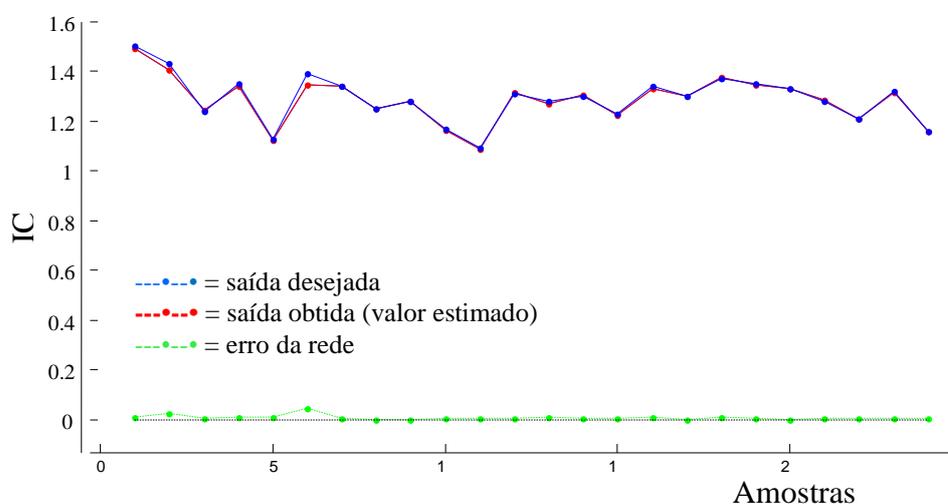
A figura 3 apresenta os resultados do treinamento para o índice de conicidade. Nota-se que a saída obtida (Y_{ob}) é praticamente igual à saída desejada (Y_{des})

apontando um erro médio de 6.69×10^{-3} , acarretando em um bom treinamento.

Figura 3. Fase de treinamento para as 100 primeiras amostras**Diagnóstico (teste) da rede**

Uma vez todos os pesos W_i obtidos pelo processo de treinamento, passamos agora para a fase do diagnóstico da rede, ou seja, simular as 24 amostras restantes que

não fizeram parte do treinamento. A figura 4 a seguir apresenta os resultados do diagnóstico da rede. Pode-se observar que a saída obtida está praticamente igual a saída desejada.

Figura 4. Diagnóstico da rede para 24 amostras**4. CONCLUSÃO**

Foi desenvolvido um modelo de classificação automático para o (IC), através de uma Rede Neural Artificial (RNA). Foi utilizado como dados de entrada a circunferência da cintura, peso e altura e como saída da rede o índice de conicidade

(IC). Pode-se concluir que as (RNAs) tiveram um bom desempenho para obter o (IC) aos dados que não fizeram parte do treinamento com erro de 7.10×10^{-3} .

REFERÊNCIAS

AMBRÓSIO, P. E. Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões

- intersticiais pulmonares. 2002. Dissertação (Mestrado) - Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da USP, Ribeirão Preto, 2002.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. Redes neurais artificiais: teoria e aplicações. 2. ed. Rio de Janeiro: LTC, 2007.
- CHOR, D.; FONSECA, M. J. M.; ANDRADE, C. R. Doenças cardiovasculares. Comentários sobre a mortalidade precoce no Brasil. Arq Bras Cardiol., v. 64, p. 15-19, 1995.
- HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. IEEE Transactions on Neural Networks, v.5, n.6, p. 989-993, 1994. <https://doi.org/10.1109/72.329697>
- HAYKIN, S. Neural Networks: a comprehensive foundation. New York: MacMillan, 1999.
- HAYKIN, S. Redes neurais: princípios e prática. 2. ed. Porto Alegre: Bookman, 2001.
- KANNEL, W. B. et al. Risk stratification of obesity as a coronary risk factor. Am J Cardiol., v.90, p.697-701, 2002. [https://doi.org/10.1016/S0002-9149\(02\)02592-4](https://doi.org/10.1016/S0002-9149(02)02592-4)
- MATHWORKS. MATLAB (MATrix LABORatory). 2017. Disponível em: <<http://www.mathworks.com>>. Acesso em: 2 ago. 2017.
- PITANGA, F. J. G.; LESSA, I. Associação entre indicadores antropométricos de obesidade e risco coronariano em adultos na cidade de Salvador, Bahia, Brasil. Rev Bras Epidemiol., v.10, n.2, p.239-248, 2007. <https://doi.org/10.1590/S1415-790X2007000200011>
- PAGANO, M.; GAUVREAU, K. Princípios de Bioestatística. São Paulo: Cengage Learning, 2012. 506p.
- RIBEIRO FILHO, F. F. et al. Gordura visceral e Síndrome metabólica: mais que uma simples associação. Arq Bras Endocrinol Metab., v.50, n.2, p.230-38, 2006. <https://doi.org/10.1590/S0004-27302006000200009>
- ROSA, E. C. et al. Obesidade visceral, hipertensão arterial e risco cárdio renal: uma revisão. Arq Bras Endocrinol Metab., v.49, n.2, p.196-204, 2005. <https://doi.org/10.1590/S0004-27302005000200005>
- TONSTAD, S.; HJERMANN, I. A high risk score for coronary heart disease is associated with the metabolic syndrome in 40-year-old men and women. J. Cardiovasc Risk., 10:129-135, 2003. <https://doi.org/10.1177/174182670301000208>
- VALDEZ, R. A simple model-based index of abdominal adiposity. J Clin Epidemiol., v.44, n.955-6, 1991.
- VALDEZ, R. et al. A new index of abdominal adiposity as an indicator of risk for cardiovascular disease. A cross-population study. Int. J. Obes. Relat. Metab. Disord., v. 17, n. 2, p. 77-82, 1993. [https://doi.org/10.1016/0895-4356\(91\)90059-I](https://doi.org/10.1016/0895-4356(91)90059-I)
- WHO. Obesity: preventing and managing the global epidemic. WHO: Geneva, 2000. (WHO Technical Report Series, n. 894)
- WHO. Obesity: preventing and managing the global epidemic. Report of a WHO Consultation. Geneva: World Health Organization, 1998. (Technical Report Series, n. 894)