UMA PROPOSTA BASEADA EM INTELIGÊNCIA COMPUTACIONAL PARA AUXILIAR OS DISCENTES EM MEDICINA NO DIAGNÓSTICO DAS DOENÇAS MENINGOCÓCICAS

Fabrício de O. Costa[1], Allan da S. Larangeiras[2], Luciene C. S. Motta[3], José L. T. Nogueira [4]

Abstract *— The meningococcals disease have distinct origins and they need a fast diagnosis and effective for reduce the commitment of the patient. Therefore, a artificial intelligence based system can contribute, for both of professionals and students of the area, to a initial analysis of the symptoms of the meningococcal more accurated disease and, therefore, on the checking of the conduct more appropriated for your treatment. Before that, the actual proposal suggests a intelligent computational system on medical decision taken on meningococcal disease detection, employing to this end, a artificial intelligence tecnique known as Neural Networks. The professionals and students of the medical area have a helper tool, which are capable to improve knowledge and provide a less death index or sequel on the patients, once a time that the same will be a allied on the fast introduction and precised of the suitable treatment to each class of this disease.*

Index Terms — Redes Neurais Artificiais, Multilayer Perceptron, Backpropagation, meningite, doença meningocócica, processo decisório médico.

INTRODUÇÃO

As doenças meningocócicas possuem fonte infecciosa diversa, cujo poder de letalidade é variante. A eficácia em seu tratamento é almejada por um diagnóstico específico e preciso que possa instruir procedimentos terápicos adequados ao respectivo agente etiológico.

Este artigo propõe uma modelagem do processo decisório médico destas enfermidades, utilizando uma técnica computacional inteligente denominada Rede Neural Artificial, de modo a simular a gestão decisória médica.

Os Sistemas de informação são encontrados abundantemente em medicina, estando disponíveis ferramentas especialmente desenvolvidas para o auxílio ao diagnóstico médico [8]. Estes softwares assistem aos profissionais na detecção da enfermidade, uma vez que podem armazenar e processar um grande volume de dados.

Destarte, a utilização de sistemas computacionais que possuam certo grau de inteligência para inferir sobre os dados pré-existentes, fornece ao profissional de área médica uma visão mais específica, com o intuito de apoiar sua decisão, uma vez que a urgência de uma avaliação correta para introduzir o tratamento adequado condiz com a redução da letalidade. Salienta-se que a utilização desta abordagem na aferição da moléstia, acarretará um acréscimo de confiabilidade clínica e especialização por parte do corpo acadêmico discente, foco do presente trabalho.

BASE CONCEITUAL

DOENÇAS MENINGOCÓCICAS

Esta moléstia ocorre através de inflamações das meninges, que são membranas que recobrem o cérebro, e pode ser ocasionada por diversos agentes etiológicos, sendo os mais representativos as bactérias e vírus. Cabe ressaltar que sua maior incidência é constatada em crianças de até 18 meses, pois seus organismos não possuem anticorpos suficientemente desenvolvidos para atuar defensivamente.

Conforme supracitado, as doenças meningocócicas podem ser oriundas de diversas fontes, tais como bactérias, vírus, fungos e agentes não-infecciosos e podemos destacar como agentes bacterianos mais representativos a *Neisseria meningitidis, Mycobacterium tuberculosis, Haemophilus influenzae* e *Streptococcus pneumoniae*. As meningites bacterianas constituem um quadro extremamente grave e seu processo infeccioso pode ocasionar seqüelas tais como: perda de audição, distúrbio de linguagem, retardo mental, anormalidade motora e distúrbios visuais [6][10].

1 Fabrício de Oliveira Costa, Gerente de Projetos de TI da Prefeitura Municipal de Silva Jardim, Praça Amaral Peixoto, nº 46, Centro, CEP 28820-000, Silva Jardim, RJ, Brasil, fabchess@gmail.com
2 Allan da Silva Larangeiras, Diretor de TI da Prefeitura Municipal de Silva Jardim, Praça Amaral Peixoto, nº 46, Centro, CEP 28820-000, Silva Jardim, RJ, Brasil, alarangeiras@gmail.com
3 Luciene Cristina Soares Motta, Professora Adjunta Mestre I, Universidade do Grande Rio, Rua Prof. José de Souza Herdy, nº 1160 – 25 de Agosto – CEP 25071-202, Duque de Caxias, RJ, luciene.motta@unigranrio.edu.br
4 José Luiz Thomaselli Nogueira, Professor Assistente I, Universidade do Grande Rio, Rua Prof. José de Souza Herdy, nº 1160 – 25 de Agosto – CEP 25071-202, Duque de Caxias, RJ, Jose.nogueira@unigranrio.edu.br

O contágio ocorre através de exposição ao mesmo ambiente físico de um enfermo ou ao contato direto com gotículas e secreções oriundas das vias respiratórias dos pacientes infectados. Uma infecção tuberculosa pode produzir inúmeras dificuldades que estimulem o surgimento da meningite tuberculosa [10].

Algumas características clínicas são apresentadas em pacientes infectados, tais como a presença de febre, cefaléia, vômitos e indícios de lesão das meninges. A constatação desta irritação pode ser verificada através do surgimento do Sinal de *Kernig*, cuja resposta é obtida em flexão da articulação do joelho, e Sinal de *Brudzinsk*, que é a dobra involuntária da perna e a flexão da coxa referente à bacia como conseqüência da elevação da nuca, estando o paciente deitado [10].

As meningites virais, originadas com uma maior representatividade por enterovírus [10], geralmente não estão correlacionadas a um alto índice de letalidade. Porém, o mesmo não acontece com as meningites causadas pela ação infecciosa originada por bactérias, pois se constituem em graves lesões ao Sistema Nervoso Central [6]. É constatado um percentual elevado dos agentes etiológicos bacterianos em crianças, conduzindo invariavelmente a uma elevada proporção de óbitos dentre os pacientes acometidos pelas meningites [2][12]. Cabe ressaltar que as seqüelas ocasionadas pelas lesões meningocócicas bacterianas é de ordem muito elevada [7].

REDE NEURAL ARTIFICIAL

O cérebro é o componente centralizador do sistema nervoso central, capaz de recepcionar e tratar todos os estímulos oriundos das variadas partes do organismo. A recepção destas informações é minuciosamente analisada e enviada ao devidos atuantes. Este processo intricado é decorrente de inúmeras conexões entre as células nervosas existentes no cérebro, ressaltando a grande quantidade das mesmas. Estes componentes nervosos são intitulados neurônios, em cuja composição, basicamente, encontramos axônios, que são prolongamentos condutores de impulsos do corpo celular para as extremidades, e dendritos, cuja função é recepcionar os estímulos nervosos ambientais ou originários de outras células nervosas.

Devido à sua complexa formação nervosa, constituída de inúmeras conexões neuronais, o cérebro humano é capaz de processar dados paralelamente e de forma não-linear, diferentemente do padrão binário atualmente encontrado nos dispositivos computacionais.

Estas interconexões nervosas são capazes de acumular todo o processo de aprendizagem envolvido no recebimento e tratamento dos estímulos nervosos. A associação de várias células nervosas frente a estímulos já presenciados pode ser imaginada como correntes interconectadas por um vasto número de elos. Esta corrente estará intimamente conectada ao receber um estímulo semelhante, produzindo respostas previamente armazenadas.

Sendo assim, uma Rede Neural Artificial é um conjunto de instruções modelado a partir da análise do funcionamento de certas áreas do cérebro humano, com a expectativa de alcançar resultados significativos quanto ao processo envolvido em todo o acúmulo de aprendizado. A composição e comportamento das células nervosas são responsáveis pelo acúmulo de experiência da Rede, assim como seu análogo biológico.

O surgimento do modelo *Perceptron*, composto de múltiplas camadas, proporcionou a confecção de redes neurais que se baseiam no conceito de assistência por parte de um supervisor ou professor. Esta modelagem permite a classificação de padrões complexos, resolvendo o problema de separação linear do modelo *Perceptron* de camada única, tornando seu uso em problemas concretos, uma vez que os mesmos exigem modelagens não-lineares intricadas [1][5].

METODOLOGIA

As informações utilizadas na presente pesquisa foram cedidas pela Secretaria de Vigilância Epidemiológica da Cidade do Rio de Janeiro, e seus respectivos dados representam casos verídicos contendo classificações variadas de doenças meningocócicas, compreendidas no biênio 2007-2008.

As informações clínicas e laboratoriais apresentadas por pacientes e contidas no conjunto de dados foram selecionadas com o auxílio de médicos especializados, bem como esclarecimentos inerentes à classificação das várias etiologias envolvidas no processo de detecção da enfermidade.

Após esta análise minuciosa, foram selecionados 125 casos para treinamento e testes da rede, além de sete classes de doenças meningocócicas, a saber: meningococemia, meningite meningocócica, meningite tuberculosa, ocasionada por outra bactéria, meningite asséptica, acarretada por outra etiologia e meningite pneumocócica.

O número de registros verificados neste conjunto de dados acarretados pela bactéria *Haemophilus influenzae* foi insuficiente para o conseqüente treinamento, desta forma a sua classificação foi desconsiderada. A constatação do baixo número de incidência por este agente etiológico observada nesta base de dados evidencia as ações federais de imunização travadas em busca de sua erradicação devido ao alto número de mortalidade [11].

As variáveis relevantes para a classificação foram selecionadas baseadas em informações clínicas e laboratoriais. Dentre o rol de atributos disponíveis, foram selecionados 23 indicadores considerados essenciais, relacionadas a seguir: cefaléia, febre, vômito, convulsão,

rigidez de nuca, sinal de *Kernig*, abaulamento de *Fontanela*, estado de coma, apresentação de petéquias, aspecto do líquor, cultura do líquor, bacterioscopia do líquor, aglutinação pelo látex do líquor, agente bacteriano, agente asséptico, agente de outra etiologia, sorogrupo, neutrófilo, glicose, leucócito, proteína, leucócito mononuclear e idade do enfermo quando verificada a enfermidade.

Primeiramente foram realizados testes, cujo objetivo foi à verificação da eficiência da modelagem, utilizando o framework *Weka* (*Waikato Environment for Knowledge Analysis*). Este software, licenciado nos termos da *GNU General Public License* e desenvolvido pela Universidade de *Waikato*, provê diversos algoritmos computacionais pertinentes à aprendizagem, processamento, análise, treinamento e teste das informações elencadas[13]. Utilizou-se também a ferramenta *Weka Classification Algorithms*, pois o mesmo é um *plugin* desenvolvido para a implementação de algoritmos de redes neurais artificiais no *Weka*, uma vez que nativamente o mesmo não permite a manipulação adequada destas abordagens.

Com o uso do *Weka*, foi implantada uma rede *Perceptron* de múltiplas camadas, baseando-se no algoritmo de aprendizado por retropropagação de erros. Esta modelagem foi composta de vinte e três neurônios em sua camada de entrada, representando as diversas informações clínicas e laboratoriais, oito neurônios na camada oculta e sete na camada de saída, equivalentes aos tipos de doenças meningocócicas a serem diagnosticadas.

Usou-se a validação cruzada [4] no presente artigo como metodologia para os testes e validação da Rede Neural Artificial empregada. Esta técnica consiste na divisão dos dados, de maneira aleatória, em um conjunto de teste e um de treinamento, sendo este subdividido em grupo de estimação e grupo de validação, empregados em prol da escolha, teste e validação do modelo analisado.

O treinamento, teste e respectiva validação da abordagem conexionista baseada neste Rede Perceptron de múltiplas camadas podem ser visualizados através do exposto na Tabela 1.

Para uma melhor compreensão da tabela supradita, necessita-se um melhor entendimento dos seguintes conceitos: *TP Rate (true positive rate)* refere-se à proporcionalidade de itens positivos classificados de forma correta. *FP Rate (false positive rate)* é referente à taxa de predições incorretas frente ao número total de instâncias. O termo *recall* está relacionado à proporção amostral de uma classe frente ao total da mesma, enquanto *precision* indica a quantidade de amostras de uma classe corretamente classificadas. A medida denominada *f-measure* representa uma média harmônica oriunda dos indicadores *precision* e *recall*.

Analisando os dados disponibilizados na Tabela 1, verifica-se que a eficiência no diagnóstico das classes atingiu os seguintes percentuais: Meningococemia - 80%, Meningocócica 82%, Tuberculosa - 62,5%, Outra Bactéria - 70%, Asséptica - 100%, Outra Etiologia - 100% e Pneumocócica - 80%. Nota-se um percentual satisfatório na taxa de acerto referente à meningococemia, meningite meningocócica, asséptica, outra etiologia e pneumocócica, demonstrando a real eficácia de classificação quanto a estas classificações. Cabe a ressalva de que, excetuando-se a meningite asséptica e outras etiologias neste subgrupo, as demais são referentes às infecções ocasionadas por agentes bacterianos que, conforme mencionado anteriormente, conduzem a um percentual elevado de óbitos e seqüelas [2][6][12].

TABELA 1
Acurácia

TP Rate	*FP Rate*	*Precision*	*Recall*	*F-Measure*	*Classe*
0.8	00.17	0.8	0.8	0.8	Meningococemia
0.82	0.093	0.854	0.82	0.837	Meningocócica
0.625	0.043	0.5	0.625	0.556	Tuberculosa
0.7	0.026	0.7	0.7	0.7	Outra Bactéria
1	0	1	1	1	Asséptica
1	0.008	0.875	1	0.933	Outra Etiologia
0.8	0.067	0.824	0.8	0.812	Pneumocócica

Baseado na confirmação da eficiência quanto às classificações mais nocivas, projetou-se e desenvolveu-se um sistema para ser disponibilizado em plataforma web, cujos códigos foram escritos em linguagem de programação Java, com a utilização de *frameworks* de desenvolvimento Java *Enterprise Edition*. O *framework Weka* novamente foi utilizado, de modo a prover as funcionalidades da Rede *Perceptron* de Múltiplas Camadas, cuja parametrização foi idêntica às do experimento.

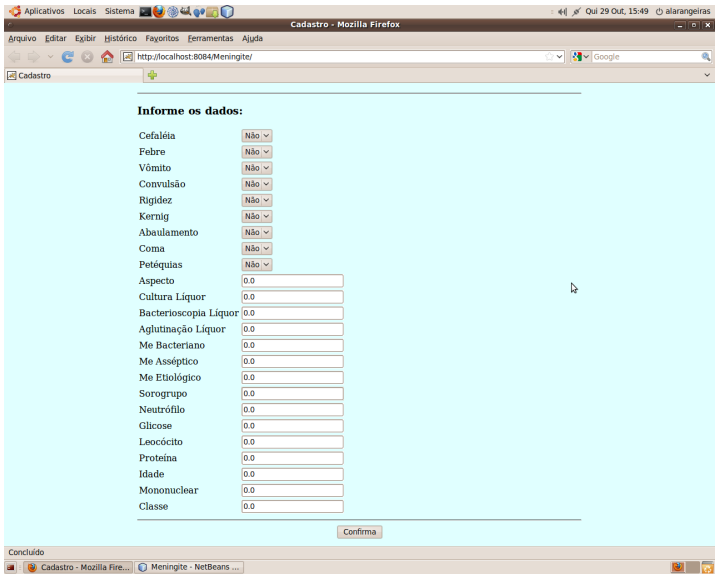

FIGURA 1
Informações pertinentes à classificação

O software apresenta um formulário, representado pela Figura 1, cujo teor representa todas as características clínicas e laboratoriais envolvidas no presente trabalho, de modo a facilitar a indicação dos dados por parte dos usuários do mesmo. Após o seu correto preenchimento, estes dados são apresentados para Rede, cujo aprendizado indicará o diagnóstico mais adequado em sua respectiva tela de resultados, propiciando ao discente o confronto de seu conhecimento frente ao adquirido pela Rede.

TABELA 1
Matriz de Erros

A	B	C	D	E	F	G	Classificação
8	1	0	1	0	0	0	A = Meningococemia
1	**41**	2	1	0	0	5	B = Meningocócica
1	0	**5**	1	0	1	0	C = Tuberculosa
0	0	2	**7**	0	0	1	D = Outra Bactéria
0	0	0	0	**5**	0	0	E = Asséptica
0	0	0	0	0	**7**	0	F = Outra Etiologia
0	6	1	0	0	0	**28**	G = Pneumocócica

CONCLUSÃO

A meningite tuberculosa obteve uma taxa de acerto insatisfatória, porém este desempenho é compatível com o apurado por especialistas em medicina devido à sua complexidade de diferenciação com as infecções bacterianas [3]. Esta dificuldade é constatada através da matriz de erro exposta na Tabela 2.

Os experimentos computacionais demonstraram que a abordagem conexionista baseada em uma rede *Perceptron* de múltiplas camadas, composta do algoritmo de aprendizado *Backpropagation*, foi bastante satisfatória quanto à classificação das etiologias consideradas mais nocivas. Sua eficiência constatada se aproxima de resultados encontrados por seres humanos no diagnóstico de classificações bacterianas, conforme trabalhos anteriores [14].

Constatou-se a incapacidade de distinção da meningite tuberculosa em virtude de sua complexa forma de análise quanto a diferenciação às infecções bacterianas, sendo este percentual adequado ao detectado por profissionais de medicina [3]. Os resultados quanto aos acometimentos acarretados por outras bactérias foram inferiores se comparados às classificações do mesmo agente infeccioso. Verificou-se a incapacidade de convergência quando as variáveis referentes aos dados laboratoriais foram suprimidas da camada de entrada, destarte, estas informações são consideradas altamente relevantes para a rede.

O sistema é de fácil utilização por parte dos usuários quanto às informações relacionadas a um caso suspeito, cujo diagnóstico é verificado rapidamente na Rede devidamente treinada, e acredita-se ser uma valiosa ferramenta auxiliadora na disseminação do conhecimento.

Trabalhos futuros podem ser desenvolvidos com vistas à inclusão de novos casos confirmados e verídicos para o conjunto de dados, ocasionando um novo treinamento da rede.

REFERÊNCIAS

[1] Braga, A. P., de Carvalho, A. P. L. F., and Ludermir, T. B.. Redes Neurais Artificiais: Teoria e Aplicações. *LTC - Livros Técnicos e Científicos Editora*, Rio de Janeiro, 2007.

[2] Carvalho, C. M. C. N. Carvalho, O. A. M. Etiologia de meningites bacterianas em uma amostra da população de salvador - Bahia. *Arquivos de Neuro-psiquiatria*, 56(1):83–87, 1998.

[3] Filho, A. C. and et al. II consenso brasileiro de tuberculose - diretrizes brasileiras para tuberculose 2004. *Jornal Brasileiro de Pneumologia*, 30 (supl I), 2004.

[4] Guimarães, A. M. and et al. Módulo de validação cruzada para treinamento de redes neurais artificiais com algoritmos backpropagation e resilient propagation. *Publicatio UEPG – Ciências exatas e da terra, ciências agrárias e engenharias*, 1:17–24, 2008.

[5] Haykin, S.. Redes Neurais: princípios e práticas. *Bookman*, Porto Alegre, 2001.

[6] Henry, J. B.. Diagnósticos clínicos e tratamento por métodos laboratoriais. *Editora Manole*, Barueri, 2008.

[7] Krebs, V. L. J. and Taricco, L. D.. Fatores de risco para meningite bacteriana no recém-nascido. *Arquivos de Neuro-psiquiatria*, 62(3A):630–634, 2004.

[8] Razzouk, D., Shirakawa, I., and Mari, J. J.. Sistemas inteligentes no diagnóstico da esquizofrenia. *Revista Brasileira de Psiquiatria*, 22(supl I):35–37, 2000.

[9] Rumelhart, D. E., Hinton, G. E., and Williams, R. J.. Learning representations by back-propagating errors. *Nature*, 323:533–536, 1986.

[10] Saúde, M.. Guia de vigilância epidemiológica. Distrito Federal, 2005.

[11] Simões, L. L. P. and et al. Impacto da vacinação contra o haemophilus influenzae b na redução de meningites em Goiás. *Revista Saúde Pública*, 38(5):664–670, 2004.

[12] Vieira, J. F. S.. Incidência de meningite em pacientes de 0 - 12 anos no instituto de medicina tropical de Manaus. *Arquivos de Neuro-psiquiatria*, 59(2A):227–229, 2001.

[13] Witten, I. H. and Frank, E.. Data Mining: practical machine learning tools and techniques. *Elsevier*, San Francisco, 2005.

[14] Nery-Guimarães, R., Bittencourt, L. C. M., Pastor, M. V. A., Meningites Virais e Bacterianas no município do Rio de Janeiro. Algumas Considerações sobre o sistema de informações em saúde e sobre a distribuição da doença no espaço urbano. *Revista Saúde Pública*, 15:379-94, São Paulo, 1981.