Uma abordagem baseada em Redes Neurais Artificiais para o auxílio ao diagnóstico de doenças meningocócicas

Fabrício de Oliveira Costa ¹ Luciene Cristina Soares Motta ² José Luiz Thomaselli Nogueira ²

Resumo: Quando se trata de doenças meningocócicas, a atuação médica necessita ser ágil para detectar corretamente o agente etiológico envolvido no processo infeccioso e, consequentemente, instruir os procedimentos terápicos adequados, pois a protelação no atendimento ou um erro de diagnóstico pode ocasionar graves sequelas ou o óbito do paciente. Neste escopo, o objetivo deste trabalho é apoiar o processo de decisão médica no diagnóstico da moléstia supracitada, através de uma Rede Neural Artificial, verificando sua eficácia e a melhor convergência entre uma configuração baseada em uma rede supervisionada, modelo Multilayer Perceptron com aprendizado por retropropagação, e um mapa auto-organizável, cuja aprendizagem ocorre de modo não supervisionado. Os resultados elencados indicam a eficiência da técnica Multilayer Perceptron no diagnóstico diferencial das variadas classes de doenças meningocócicas.

Palavras-chave: Doença meningocócica. Multilayer Perceptron. Kohonen.

Abstract: When it comes to meningococcal disease, the medical action needs to be agile to detect the etiological agent involved in the infectious process and, therefore, instruct the appropriate therapies procedures, because the delay in care or an error in diagnosis can lead to serious sequels or the patient's death. In this scope, the objective of this work is to support decision-making in the medical diagnosis of this disease, through Artificial Neural Network, verifying its efficiency and better convergence between a configuration based on a supervised network, Multilayer Perceptron with backpropagation learning and a self-organizable map model, which learning occurs in a non-supervised mode. The results listed indicate the efficiency of the technique Multilayer Perceptron in the diagnosis of various types of meningococcal disease.

Keywords: Meningococcal disease. Multilayer Perceptron. Kohonen.

1 Introdução

Em doenças meningocócicas, cuja origem infecciosa pode ser veloz e fatal, é crucial o atendimento rápido e eficaz objetivando um diagnóstico específico e preciso, que possa instruir procedimentos profiláticos apropriados. Dessa forma, a utilização de um modelo que apoie a avaliação inicial do paciente e auxilie o diagnóstico correto da doença pode ser considerada um grande diferencial para a introdução do tratamento adequado. Nesse sentido, o presente trabalho propõe uma modelagem do processo decisório médico no diagnóstico das enfermidades supracitadas, utilizando para este fim uma abordagem conexionista, oriunda da Inteligência Artificial, para simular o processo de decisão médica.

Atualmente, os sistemas de informação são encontrados rotineiramente na área médica, incluindo os softwares especializados em auxílio ao diagnóstico médico [1]. Na maioria dos casos, estes sistemas auxiliam os profissionais na tomada de decisão, uma vez que podem armazenar e processar um volume de dados acentuado.

doi: 10.5335/rbca.2010.008

 $^{^{1}\}text{Prefeitura Municipal de Silva Jardim, Diretoria de Tecnologia da Informação, Praça Amaral Peixoto, n^{\circ} 46, Silva Jardim (RJ) - Brasil {fabchess@gmail.com}$

²Escola de Ciência e Tecnologia, Unigranrio, Rua Prof. José de Souza Herdy, n° 1160, Duque de Caxias (RJ) - Brasil {luciene.motta, jose.nogueira}@unigranrio.edu.br}

Excedendo a manipulação de informação por parte de sistemas convencionais, faz-se necessária a utilização de sistemas computacionais que possuam certo grau de inteligência para inferir sobre os dados preexistentes, fornecendo 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 se traduz na letalidade do paciente em questão. É importante ressaltar que a utilização desta modelagem na aferição da moléstia, constatada sua proporcional indefectibilidade, vislumbrará um acréscimo de confiabilidade clínica e, consequentemente, um percentual menor de letalidade.

Este artigo está organizado da seguinte forma: a seção 2 fornece embasamento teórico acerca dos temas explorados no trabalho; a 3 apresenta a metodologia dos experimentos; a 4 retrata os resultados obtidos, assim como a análise dos mesmos; a seção 5 expõe as conclusões e elenca propostas futuras relacionadas ao tema, seguida das referências bibliográficas.

2 Base conceitual

Esta seção fornecerá conceitos teóricos sucintos acerca das doenças meningocócicas e modelos de redes neurais artificiais empregados neste trabalho.

2.1 Doenças meningocócicas

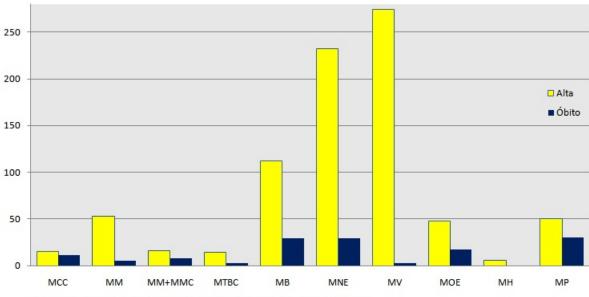
As doenças meningocócicas manifestam-se através do processo inflamatório das meninges e podem ser ocasionadas por diversos agentes etiológicos, tais como bactérias, vírus, fungos e agentes não infecciosos. Podemos destacar como agentes bacterianos mais representativos a *Neisseria meningitidis*, com maior recaimento entre 5 e 29 anos, *Mycobacterium tuberculosis*, *Haemophilus influenzae*, cuja incidência é maior na faixa etária de um mês a cinco anos, e *Streptococcus pneumoniae*, em maiores de 29 anos.

A disseminação das doenças meningocócicas ocorre, de maneira geral, pela exposição ao mesmo ambiente físico ou ao contato direto com gotículas e secreções oriundas das vias respiratórias dos pacientes infectados. A infecção tuberculosa pode gerar complicações que incitem o surgimento da meningite tuberculosa. Os sintomas mais frequentes são presença de febre, cefaleia, vômitos e indícios de exacerbação das meninges. Esta irritação pode ser verificada pelo 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 consequência da elevação da nuca, estando o paciente deitado [2].

De modo geral, as meningites assépticas, que são originadas com uma maior representatividade por enterovírus [2], não estão correlacionadas a um alto índice de letalidade. Porém, o mesmo não acontece com doenças meningocócicas ocorridas em decorrência da ação infecciosa originada por bactérias, pois se constituem em graves lesões ao sistema nervoso central [3], levam a um quadro extremamente grave e podem ocasionar sequelas, tais como perda de audição, distúrbio de linguagem, retardo mental, anormalidade motora e deficiências visuais [2], [3]. Verifica-se uma incidência elevada dos agentes etiológicos desta classe em seres humanos em idade pediátrica, conduzindo, indubitável e invariavelmente, a uma elevada taxa de mortalidade e sequelas [4].

A Figura 1 exibe um comparativo entre o número de óbitos e altas ocorridos no estado do Rio de Janeiro no ano de 2008. As siglas apresentadas na ilustração são descritas como: MM - meningococemia; (MM+MMC) - doença meningocócica com meningococemia; (MTBC) - meningite tuberculosa; (MB) - meningite por outra bactéria; (MNE) - meningite não especificada; (MV) - meningite viral; (MOE) - meningite por outra etiologia; (MH) - meningite por Haemophilus e (MP) - meningite pneumocócica.

Assim, como pode ser observado na Figura 1, as informações demonstram uma alta taxa de mortalidade concernente às infecções bacterianas (meningococemia, meningite meningocócica, meningite meningocócica com meningococemia, meningite bacteriana e meningite pneumocócica).



Fonte: Sistema de Informações de Agravos Nacionais - Sinan

Figura 1. Taxa de mortalidade no estado do Rio de Janeiro em 2008

2.2 Redes neurais artificiais

Informações de todas as partes do organismo são enviadas ao cérebro continuamente, o qual atua como ponto central de todo o sistema nervoso. Esse fluxo informativo é analisado apropriadamente e as decisões cabíveis são providenciadas. Parte constituinte desse complexo processo é o número expressivo de células nervosas, denominadas "neurônios". Denotando-se sucintamente, a composição de um neurônio é detentora de 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.

Dessa forma, o cérebro humano possui a capacidade de processamento de informações de uma maneira totalmente diferente do padrão lógico digital, atuando de forma não linear e paralela, em razão das suas estruturas nervosas elementares [5].

O processo de aprendizagem é realizado através de inúmeras conexões neuronais no cérebro humano. A associação de múltiplos neurônios a alguma experiência vivenciada pode ser imaginada como correntes interconectadas por um vasto número de elos, as quais estarão intimamente conectadas ao receber um estímulo semelhante, produzindo respostas previamente armazenadas.

Uma rede neural artificial é um conjunto de hardware e software modelado a partir do funcionamento de determinadas áreas do cérebro humano com a expectativa de alcançar resultados significativos quanto à aprendizagem. Esta rede se baseia na composição e comportamento dos neurônios, cuja função é imprescindível, assim como no modelo biológico, sua fonte inspiradora.

2.2.1 O modelo Multilayer Perceptron e o aprendizado por retropropagação

O advento do modelo Perceptron, composto de uma única camada, proporcionou a confecção de redes neurais que se baseiam no conceito de assistência por parte de um supervisor ou professor. Porém, esta modelagem permite apenas a classificação de padrões separáveis linearmente, tornando seu uso pouco comum em problemas concretos, uma vez que exigem modelagens não lineares intricadas [5, 6].

Em redes Perceptron de camadas únicas, o aprendizado é realizado pela correção de erro, de forma supervisionada, conforme evidenciado em (1):

$$e_k = d_k - y_k, \tag{1}$$

Destarte, *k* representa um estímulo qualquer; *e* evidencia o sinal indicativo de erro; *d*, a saída almejada e *y*, a saída atingida após a entrada.

O fator de ajuste incidido sobre o peso sináptico w_{kj} do neurônio k no tempo n, bem como a sua respectiva taxa de aprendizado, simbolizada por η , é expresso em (2):

$$\Delta w_{kj}(n) = \eta e_k(n) x_j(n), \tag{2}$$

Uma rede composta de múltiplas camadas permite a transformação do problema inicial não linear numa situação perfeitamente tratável pela camada de saída, uma vez que possui uma ou diversas camadas intermediárias, cuja função é tornar a complexidade não linear em linear. Os valores de entrada se irradiam sequencialmente entre as camadas existentes na rede e descrevem, de modo geral, o Perceptron de camada única.

O algoritmo de aprendizagem por retropropagação de erro surgiu como elucidador da deficiência de estimativa e cálculo do erro das camadas ocultas, uma vez que o cálculo de correção de erro em redes Perceptron da camada única se produz através da diferença entre a saída almejada e a atual. A retropropagação de erro baseia-se na estimativa de erro das camadas intermediárias, observando-se a influência da mesma no erro da saída. Portanto, o cálculo realizado do erro de saída é repassado para a camada oculta, proporcionando o reajuste dos pesos sinápticos.

Dado um conjunto de treinamento no passo exposto à camada de saída, representado por (x(n), d(n)), onde x(n) simboliza os valores de entrada e d(n), a saída desejada, é efetuado o cálculo local induzido e os sinais funcionais são disparados para as camadas seguintes. O campo local para o neurônio j na camada l é representado por (3)

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(n) y_i^{(l-1)}(n), \tag{3}$$

no laço n, $y_i^{(l-1)}(n)$ é a função de saída do neurônio i, alocado na camada anterior l - l, e $w_{ji}^{(l)}(n)$ é peso do neurônio j da camada l, sustentado pelo nó i do disposto no layer supracitado.

A saída produzida pelo neurônio j na camada l, usando-se uma função sigmoide como a do experimento da presente pesquisa, representa o exposto em $\,$ (4). Na referida equação, $\varphi_j(v_j(n))$ simboliza a derivada da função de ativação vinculada.

$$y_j^{(l)} = \varphi_j(v_j(n)), \tag{4}$$

caso o neurônio *j* esteja na primeira camada intermediária, teremos (5):

$$y_j^{(0)}(n) = x_j(n), (5)$$

e, finalmente, a situação em que o neurônio j possa se situar na camada de saída, conforme expresso em (6):

$$y_j^{(l)} = O_j(n), (6)$$

em seguida calcula-se a correção de erro, denotada pela expressão (7):

$$e_j(n) = d_j(n) - O_j(n). \tag{7}$$

A retropropagação de erros deste algoritmo pode ser visualizada através de (8):

$$\delta^(l)_j(n) = \begin{cases} e^{l'(n)\varphi_j\binom{l'}{j}(n)} \text{neurônio j da saída l'} \\ \varphi_j(v_j^{(l)}(n))\Delta\varphi_k^{l+1}(n)w_{kj}^{(l+1)}(n) \text{nó j da oculta l'} \end{cases}$$
 (8)

e a generalização da regra delta readequa os pesos na camada l, denotado em (9):

$$w_{ii}^{(l)}(n+1) = w_{ii}^{(l)}(n) + \alpha [w_{ii}^{(l)}(n-1)] + \eta \delta_i^{(l)}(n) y_i^{(l-1)}(n), \tag{9}$$

 η é a taxa de aprendizado e α é a constante de momento, utilizada para suprimir mínimos locais através da aceleração da convergência nas áreas de declínio de erros.

2.2.2 Mapas auto-organizáveis

O objetivo de uma modelagem neural utilizando algoritmos eficazes quanto à implementação de mapas auto-organizáveis é modificar o padrão de entrada em um mapa discreto, de maneira não supervisionada, através de um processo adaptativo e ordenado.

Esta modelagem induz os neurônios de saída a concorrerem entre si pela representação da informação. Após a conclusão deste estado competitivo, a rede elege o neurônio vencedor e o adapta de modo a aperfeiçoar a resposta ante ao dado apresentado. Neste ciclo adaptativo, seus vizinhos também são modificados de modo a aperfeiçoar a rede [7]. É louvável a similaridade de seu funcionamento frente às atividades cerebrais.

A função de ativação, nesta modelagem, utiliza a medida da distância euclidiana, exposta em (10)

$$y_i = \sum_{j=1}^n ||x_j - w_{ij}|| \tag{10}$$

para selecionar o neurônio que possuir a menor distância, que será apontado como vencedor da competição. O treinamento consiste em reduzir, progressivamente, a taxa de aprendizado, bem como o raio de sua vizinhança. O neurônio vencedor e suas respectivas células nervosas vicinais atualizam seus pesos através do cálculo expresso em (11)

$$w_{ji}(t+1) = \begin{cases} w_{ji}(t) + \eta(t)(x_i(t) - w_{ji}(t)), \text{se } j \in \Lambda(t) \\ w_{ji}(t), \text{ao contrário} \end{cases}$$
(11)

em que $w_{ji}(t)$ sinaliza o peso da conexão sináptica estabelecida entre a entrada $x_i(t)$ e o nó j. Λ representa o raio de vizinhança do nó vitorioso, assim como $\eta(t)$ evidencia a taxa de aprendizado.

3 Metodologia dos experimentos

O objetivo dos experimentos computacionais realizados neste trabalho é verificar qual modelo se adequa melhor às características do problema estudado, culminando com uma melhor convergência da rede. Para tanto,

utilizou-se o pacote de coleções Weka (Waikato Environment for Knowledge Analysis). Este software, desenvolvido pela Univesidade de Waikato, provê vários algoritmos de aprendizado aplicáveis ao tratamento, treinamento e teste do conjunto de dados [8].

Foi necessário implementar o Weka Classification Algorithms, por ser um plugin desenvolvido para a implementação de algoritmos de redes neurais artificiais e AIS (Artificial Immune System). O auxílio de profissionais da área médica foi necessário para a indicação das características clínicas e laboratoriais apresentadas por pacientes e disponibilizadas no conjunto de dados, bem como esclarecimentos inerentes à classificação das várias etiologias envolvidas no processo de detecção da enfermidade.

O conjunto de informações utilizadas na presente pesquisa foi cedido pela Prefeitura do município do Rio de Janeiro, através de sua Secretaria de Vigilância Epidemiológica. Os dados representam casos reais contendo classificações variadas de doenças meningocócicas, compreendidas no período de 2007 a 2008. Após uma criteriosa análise nestes dados apoiada por profissionais da área médica, foram selecionados 125 registros para treinamento e testes da rede, além de sete classes de doenças meningocócicas, a saber: meningococemia, meningocócica, tuberculosa, ocasionada por outra bactéria, asséptica, acarretada por outra etiologia e pneumocócica. O número de casos registrados da meningite acarretada pela bactéria *Haemophilus influenzae* foi considerado insuficiente para o consequente treinamento, sendo desconsiderada a sua classificação. O baixo número de acometimentos por este agente infeccioso detectado nesta base de dados torna evidente as ações nacionais de vacinação implementadas em prol de sua erradicação [9].

As variáveis relevantes para a classificação foram selecionadas baseadas em informações clínicas e laboratorais. Dentre o conjunto de atributos disponíveis, foram selecionadas 23 características consideradas essenciais, relacionadas a seguir: cefaleia, febre, vômito, convulsão, rigidez de nuca, sinal de Kernig, abaulamento de Fontanela, coma, petéquias, aspecto, cultura, bacterioscopia, aglutinação pelo látex, agente bacteriano, agente asséptico, agente de outra etiologia, sorogrupo, neutrófilo, glicose, leucócito, proteína, leucócito mononuclear e idade do enfermo.

A Figura 2 exibe, sucintamente, os detalhes das informações clínicas e laboratoriais elencadas na modelagem abordada.

Característica	Descrição
Febre, cefaléia intensa, vômitos e	
convulsões e coma	Sintomas clinicos geralmente apresentados
Sinal de Kernig (resposta à flexão do	
joelho), rigidez da nuca	Sinal clinico de irritação meningea
	Verificação, em crianças menores de um ano, da pressão arterial
Abaulamento de Fontanela	intracraniana
	Sinal clinico geralmente caracterizador de infecção pela bactéria Neisseria
Petéquias	Meningitidis
	Dado laboratorial destinado à avaliação do aspecto do liquido
Aspecto do liquor	cefaloraquidiano
	Análise do liquido cefaloraquidiano em busca de agrupamento morfológico
Bacterioscopia	dos agentes, com pequeno indice de especificidade
	Análise do liquido cefaloraquidiano em prol da identificação do agente
Cultura	etiológico (bactérias, fungos e virus)
	Permite, através da análise do liquor, a identificação do agente etiológico
Aglutinação do Látex	através de seus antigenos
Agente Bacteriano, asséptico ou de outra	
etiologia	Classificação do agente
Sorogrupo	Identificação do sorogrupo do agente
Neutrófilo, glicose, leucócito, proteina e	Dados laboratoriais destinados à verificação de alterações no organismo
leucócito mononuclear	frente ao agente etiológico
	As classes de doenças meningocócicas podem variar em função da faixa
Idade	etária

Figura 2. Detalhamento das variáveis

Utilizando a ferramenta Weka, primeiramente foi implementada uma rede seguindo o modelo Multilayer Perceptron com algoritmo de aprendizado por retropropagação de erros. Esta modelagem foi especificada com 23 neurônios na camada de entrada, cujo foco é a representação dos dados clínicos e laboratoriais, oito neurônios na camada oculta e sete na camada de saída, equivalentes aos tipos de doenças meningocócicas a serem classificadas. Também foi estipulada, com propósitos comparativos, uma abordagem baseada no modelo SOM (Self-Organizing Maps), estipulada com uma camada de entrada e saída similar à rede baseada no modelo Multilayer Perceptron adotada anteriormente neste trabalho.

4 Resultados computacionais

O método de validação cruzada foi utilizado no presente artigo de modo a testar e validar as modelagens neurais apresentadas [10]. 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. Para examinar minuciosamente a eficiência da convergência de forma individualizada em relação às classes da referida enfermidade, podem-se observar os dados complementares nas Tabelas 1 e 2, que apresentam, respectivamente, a acurácia detalhada por classe e a matriz de erros pertencente à abordagem baseada no modelo Multilayer Perceptron.

Tabela 1. Acurácia detalhada por classe - MLP

TP Rate	FP Rate	Precision	Recall	F-Measure	Classificação
0.8	0.017	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

Para uma melhor compreensão da tabela citada e posteriores, necessita-se de 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.

Baseado nas informações disponibilizadas pela Tabela 1, nota-se que as classificações atingiram o seguintes percentuais de eficiência: meningococemia - 80%, meningocócica - 82%, tuberculosa - 62,5%, outra bactéria - 70%, asséptica - 100%, outra etiologia - 100%, pneumocócica - 80%. Nota-se um percentual satisfatório na taxa de acerto referente à meningococemia, meningite meningocócica, asséptica, outra etiologia e pneumocócica, demonstrando a eficácia da convergência quanto a estas classificações. Cabe a ressalva de que, excetuando-se a asséptica e outra etiologia neste subgrupo, as demais são ocasionadas por bactérias que sabidamente conduzem a inúmeras complicações, dentre as quais o óbito e sequelas [3, 11, 12].

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 [13]. Esta dificuldade é constatada através da matriz de erro exposta na Tabela 2.

Conforme evidenciado pelos dados correlatos à implementação de uma rede *SOM* expostos na Tabelas 3 e 4, verificou-se os seguintes índices de eficiência das classificações citadas no corrente trabalho: meningococemia - 80%, meningocócica - 70,2%, tuberculosa - 62,5%, outra bactéria - 33,3%, asséptica - 0%, outra etiologia - 57,1% e pneumocócica - 63,6%. A Tabela 4 exibe a matriz de erros pertencente à abordagem baseada em mapas auto-organizáveis.

Os resultados demonstraram que a rede SOM foi eficiente na classificação da meningococemia e obteve

Tabela 2. Matriz de erros - MLP

A	В	С	D	Е	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

Tabela 3. Acurácia detalhada por classe - SOM

TP Rate	FP Rate	Precision	Recall	F-Measure	Class
0.8	0.037	0.667	0.8	0.727	Meningococemia
0.702	0.181	0.717	0.702	0.71	Meningocócica
0.625	0.054	0.455	0.625	0.526	Tuberculosa
0.333	0.036	0.429	0.333	0.375	Outra Bactéria
0	0.026	0	0	0	Asséptica
0.571	0.027	0.571	0.571	0.571	Outra Etiologia
0.636	0.14	0.636	0.636	0.636	Pneumocócica

resposta similar à *MLP* na tuberculosa. Porém, o restante das etiologias obteve uma taxa de acerto inferior se comparadas aos resultados supracitados relacionadas à rede Multilayer Perceptron.

Tabela 4. Matriz de erros - SOM

A	В	С	D	Е	F	G	Classificação
8	0	0	0	2	0	0	A = Meningococemia
2	33	1	0	0	1	10	B = Meningocócica
0	0	5	1	1	1	0	C = Tuberculosa
0	2	1	3	0	1	2	D = Outra Bactéria
1	1	2	1	0	0	0	E = Asséptica
1	0	2	0	0	4	0	F = Outra Etiologia
0	10	0	2	0	0	21	G = Pneumocócica

5 Conclusões

Os experimentos computacionais realizados neste trabalho monstraram que a abordagem conexionista baseada em uma rede Perceptron de múltiplas camadas, composta do algoritmo de aprendizado Backpropagation, foi eficiente quanto à classificação das etiologias consideradas mais nocivas, e sua eficiência detectada se aproxima dos resultados obtidos por seres humanos quanto à classificação de microorganismos patogênicos bacterianos, conforme publicações anteriores [14]. Entretanto, a implementação utilizando uma abordagem baseada em um Mapa Auto-Organizável foi ineficiente quanto à convergência da rede, sendo constatada a necessidade de um supervisor para a otimização da classificação. Podemos visualizar um comparativo de eficiência na classificação do problema em questão na Figura 3.

Em ambas as técnicas empregadas, constatou-se a incapacidade de distinção da meningite tuberculosa em virtude de sua forma intricada de análise quanto à diferenciação das infecções bacterianas, sendo este percentual adequado ao detectado por profissionais de medicina [13]. 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 de ambas as malhas conexionistas quando as variáveis referentes aos dados laboratoriais foram suprimidas da camada de entrada; destarte, estas informações são consideradas altamente relevantes

para a rede.

Sua eficiência constatada se aproxima de resultados encontrados por seres humanos no diagnóstico de classificações bacterianas, conforme trabalhos anteriores [14].

Trabalhos futuros podem ser orientados quanto à avaliação da acurácia de outras técnicas conexionistas e uma nova seleção de variáveis pode ser providenciada com vistas à diminuição do mapeamento da camada de entrada, verificando a relevância das alterações quanto a identificação das classes diagnósticas.

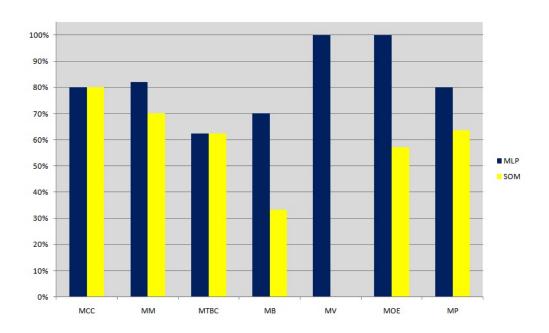


Figura 3. Comparativo de eficiência entre as redes

Referências

- [1] RAZZOUK, D.; SHIRAKAWA, I.; MARI, J. J. Sistemas inteligentes no diagnóstico da esquizofrenia. **Revista Brasileira de Psiquiatria**, v. 22 (Supl. I), p. 35-37, 2000.
- [2] Brasil Ministério da Saúde, Secretaria de Vigilância em Saúde. **Guia de vigilância epidemiológica**. Brasília: Ministério da Saúde, 2005.
- [3] HENRY, J. B. Diagnósticos clínicos e tratamento por métodos laboratoriais. Barueri: Manole, 2008.
- [4] KREBS, V. L. J; TARICCO, L. D. Fatores de risco para meningite bacteriana no recém-nascido. **Arquivos de Neuro-Psiquiatria**, v. 62, p. 630-634, 2004.
- [5] HAYKIN, S. Redes neurais: princípios e práticas. Porto Alegre: Bookman, 2001.
- [6] BRAGA, A. P.; CARVALHO, A. P. L. F; LUDERMIR, T. B. **Redes neurais artificiais**: teoria e aplicações. Rio de Janeiro: LTC Livros Técnicos e Científicos Editora, 2007.
- [7] KOHONEN, T. **Self-organizing maps**. Berlim: Springer, 2001.

- [8] WITTEN, I. H.; FRANK, E. **Data Mining**: practical machine learning tools and techniques. São Francisco: Elsevier, 2005.
- [9] SIMÕES, L. L. P. et al. Impacto da vacinação contra o Haemophilus Influenzae b na redução de meningites em Goiás. **Revista Saúde Pública**, v. 38(5), p. 664-670, 2004.
- [10] GUIMARÃES, A. M. 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**, v. 1, p. 17-24, 2008.
- [11] VIEIRA, J. F. S. Incidência de meningite em pacientes de 0-12 anos no Instituto de Medicina Tropical de Manaus. **Arquivos de Neuro-Psiquiatria**, v. 59, p. 227-229, 2001.
- [12] 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**, v. 56, p. 83-87, 1998.
- [13] FILHO, A. C. II Consenso Brasileiro de Tuberculose Diretrizes Brasileiras para Tuberculose 2004. **Jornal Brasileiro de Pneumologia**, v. 30, (supl. I), 2004.
- [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**, v. 15, p. 379-394, 1981.