

AVALIAÇÃO DA GRAVIDADE DA MALÁRIA UTILIZANDO REDES NEURAIS: UM ESTUDO COMPARATIVO

L. M. Almeida, M. G. F. Costa e C. F. F Costa Filho

Universidade Federal do Amazonas, Manaus, Brasil
e-mail: larissaalmeida68@gmail.com

Resumo: A abordagem mais eficiente contra a propagação da malária é um tratamento adequado da doença e realizado em tempo hábil por um especialista. Devido a restrições geográficas, no entanto, a opinião de especialistas está, muitas vezes, indisponível ou não pode ser acessada em tempo hábil. Nesse estudo, mostra-se o desenvolvimento de um sistema inteligente de suporte ao diagnóstico da malária, que tem como principal objetivo auxiliar o diagnóstico de médicos não especialistas ou como ferramenta para o ensino-aprendizado. O banco de dados utilizado é constituído por 30 pacientes nigerianos com diagnóstico da malária confirmada. Na construção do sistema, três técnicas de reconhecimento de padrões são comparadas: redes neurais regularizadas, redes neurais com parada antecipada e redes neurais utilizando o erro médio quadrático como critério de parada. O melhor resultado obtido, acurácia de 83,3%, foi obtido com redes neurais regularizadas utilizando a estratégia *leave-one-out* de teste e treinamento. Comparativamente, a acurácia dessa técnica foi superior a outro resultado previamente publicado na literatura.

Palavras-chave: Malária, Sistema de Suporte ao Diagnóstico, Redes Neurais, Regularização, Parada Antecipada.

Abstract: *The most efficient strategy for the treatment of malaria is an adequate treatment, performed on time by an expert. Due to geographical limitations, nevertheless, an expert diagnostic is usually not available. In this study, an intelligent diagnosis support system for malaria is developed, aiming assist non-expert physicians or as an educational tool. The database used is comprised of 30 Nigerian patients with confirmed malaria diagnosis. For developing the diagnosis support systems, three pattern recognition techniques were compared: regularized neural networks, early stopping neural network and neural network with mean square error as stopping criteria. The best accuracy, 83.3%, was obtained with regularized neural network using the leave-one-out strategy for training and testing. Comparatively, the accuracy of this technique was higher than the accuracy of other result previously published in the literature.*

Keywords: *Malaria, Diagnosis Support System, Neural Networks, Regularization, Early Stopping.*

Introdução

Os sintomas da malária podem, muitas vezes, ser confundidos com os sintomas de outras doenças tropicais, resultando em erros diagnósticos que contribuem para o

aumento da morbidade e mortalidade [1]. Esta situação é agravada pela elevada taxa de pobreza, falta de infraestrutura educacional e médica, má formação e falta de um número suficiente de médicos. Nesse contexto, justifica-se o desenvolvimento de uma ferramenta para auxílio ao diagnóstico, que enderece as ambiguidades e incertezas associadas com os sintomas da doença [2].

Os sistemas de suporte ao diagnóstico são conhecidos por melhorar o desempenho médico, reduzir custos e melhorar o prognóstico dos pacientes [3,4,5]. Sistemas de apoio ao diagnóstico utilizam os dados do paciente para gerar um conselho específico e sugestões para o praticante, simulando o processo de raciocínio humano. Nos últimos anos, os seguintes sistemas foram desenvolvidos para suporte ao diagnóstico da malária [2, 6, 7, 8].

Em [6] os autores utilizaram redes neurais e redes bayesianas para o diagnóstico de malária assintomática. A base de dados foi constituída por 580 pacientes, pertencentes a três classes: não infectados, infectados e sintomáticos e infectados e não assintomáticos. Um conjunto de 7 variáveis de entrada foi utilizado: idade, sexo, número de malárias anteriores, resultado do exame interleucina 10, resultado do exame interferon gama, tempo vivendo na área endêmica e se dormia em rede ou não. Os melhores resultados foram obtidos com redes neurais: sensibilidade de 67,5% e especificidade de 92,5%.

Em [8] os autores desenvolveram um sistema para diagnóstico e tratamento da malária. Dispondo de uma interface amigável com o usuário, o sistema inicialmente coleta informações clínicas do paciente que permitem a um sistema baseado em regras inferir se o paciente encontra-se ou não infectado com o *plasmodium falciparum*. Em caso positivo, o módulo de avaliação da gravidade da malária é acionado. Para esse módulo, novas informações são coletadas, como o resultado da contagem do número de parasitas. Dependendo da gravidade da malária, o sistema emite então recomendações adequadas para o tratamento.

Em [2] os autores utilizaram uma base de dados constituída por 30 pacientes nigerianos com diagnóstico confirmado de malária, com o objetivo de diagnosticar o grau de gravidade da malária. Um conjunto de 22 variáveis foi utilizado para avaliação do grau de gravidade. A avaliação foi realizada de forma independente com as metodologias *Analytic Hierarchy Process* (AHP) e Método Difuso (*Fuzzy*). Cada paciente recebeu um diagnóstico de gravidade variando de 1 a 5, distribuídas da seguinte forma: gravidade 1 – nenhum

paciente; gravidade 2 – 2 pacientes; gravidade 3 – 13 pacientes; gravidade 4 – 13 pacientes e gravidade 5 – 2 pacientes. O padrão ouro adotado foi o diagnóstico de um especialista. Os autores reportaram uma acurácia de 80%.

No trabalho proposto, com o objetivo de melhorar o diagnóstico do grau de gravidade da malária, pretende-se avaliar o desempenho de três técnicas baseadas em redes neurais na base de dados utilizada em [2]. Essas técnicas diferiram em relação ao critério de parada: erro médio quadrático, regularização e critério de parada antecipado.

Materiais e métodos

Um conjunto de 22 sintomas foi utilizado para o diagnóstico da gravidade da malária: febre, sudorese, tremor, dor de cabeça, dor muscular, dor nas costas, dor nas juntas, calafrio, náusea, delírio, cansaço, sonolência, tontura, vômito, diarreia, desidratação, desconforto gástrico, respiração anormal, tosse, perda de apetite, olhos amarelados, indisposição. Em cada um dos 30 pacientes esses sintomas foram classificados como: 1 – muito fraco, 2 – fraco, 3 – moderado, 4 – intenso ou 5 – muito intenso. No diagnóstico dos pacientes, a gravidade da malária foi classificada numa faixa variando de 1 a 5, onde 1 significa pouca gravidade e 5, alta gravidade.

Redes neurais com 3 camadas, com arquitetura $1-n-1$, foram utilizadas para o diagnóstico da gravidade. Utilizaram-se quatro valores para o número de neurônios n da camada intermediária: 1, 10, 14 e 45. Os três últimos foram calculados utilizando-se a regra do valor médio [9], regra da raiz quadrada [10] e regra de Kolmogorov [11], respectivamente.

O algoritmo de treinamento utilizado foi o de Levenberg Marquardt [12].

Três critérios de parada foram utilizados para as redes neurais: critério do erro médio quadrático [13], regularização [14,15,16] e critério de parada antecipado [17].

Ao utilizar-se o erro médio quadrático, o treinamento foi encerrado quando o mesmo atingia um valor de 10^{-2} .

Na regularização, com o objetivo de trabalhar-se com redes mais estáveis (com valores de pesos menores), modifica-se o critério de parada do erro médio quadrático, introduzindo-se um fator proporcional à soma dos quadrados dos pesos, conforme mostrado na expressão (1).

$$msereg = \gamma mse + (1 - \gamma) msw \quad (1)$$

em que:

γ – taxa de desempenho, varia entre 0 e 1.

mse – erro médio quadrático.

$$msw = \frac{1}{n} \sum_{j=1}^n w_j^2 \quad (2)$$

O critério de parada expresso em (1) faz com que o desempenho da rede tenha pesos menores e isso força a resposta da rede para ser mais suave, melhorando o grau de generalização da rede.

Como a base de dados é pequena, para os dois primeiros critérios de parada descritos anteriormente, utilizaram-se as seguintes metodologias de treinamento e teste: *leave-one-out* e *10-fold-cross-validation* [18]. Na

metodologia *leave-one-out* a rede neural é treinada com os dados de 29 pacientes e testado com os dados de 1 paciente. Como temos 30 pacientes, esse processo é repetido 30 vezes e uma média do desempenho é calculada. Na metodologia *10-fold-cross-validation*, o conjunto de pacientes é dividido em 10 grupos de 3 pacientes. A rede é treinada com dados de pacientes de 9 desses grupos e testado com os dados de pacientes do décimo grupo. Como temos 10 grupos, esse processo é repetido 10 vezes e uma média do desempenho é calculada.

O critério de parada antecipado caracteriza-se por dividir o conjunto de dados em 3 grupos: treinamento, teste e validação. Nesse trabalho, cada um desses conjuntos foi formado por 10 pacientes. A principal característica deste método é que quando o erro médio quadrático do conjunto de validação cresce por seis iterações seguidas, o treinamento é finalizado [17].

Resultados

Na Tabela 1 mostramos uma comparação entre o melhor resultado obtido nesse trabalho, que foi com a rede neural utilizando o critério de regularização, com o melhor resultado obtido em [2], que foi com rede *fuzzy*. Nessa Tabela é mostrado também o resultado da avaliação da gravidade da malária feita por um especialista. A partir dessa Tabela calcula-se a acurácia do método e avaliação da gravidade: Para cada paciente, compara-se o resultado do método com a avaliação do especialista. Se os dois valores forem positivos contabiliza-se um acerto do método.

Os resultados de acurácia obtidos com os métodos propostos nesse trabalho são mostrados na Tabela 2. Matrizes de confusão com os dois melhores resultados obtidos nesse trabalhos são apresentadas nas Tabelas 3 e 4.

Discussão

Observa-se na Tabela 2 que o treinamento *leave-one-out* apresenta os melhores resultados, independentemente do critério de parada utilizado para a rede neural, o método *leave-one-out* utiliza um maior número de pacientes no seu conjunto de treinamento (29 pacientes) do que os outros dois métodos de treinamento e teste (27 pacientes: *10-fold-cross-validation* e 10 pacientes: *10-10-10*). Acreditamos que esse fato justifica as melhores taxas de acerto desse método. De forma oposta, o método de treinamento e teste denominado de *10-10-10* apresenta os piores resultados e, não por acaso, é o método de treinamento e teste que apresenta o menor número de pacientes em seu conjunto de treinamento.

Das Tabelas 3 e 4, pode-se observar que os diversos critérios de parada têm uma pobre generalização ao classificar pacientes com níveis de gravidade 2 e 5. Isso acontece por existir uma amostragem desses casos muito baixa, apenas dois pacientes cada. Na base de dados há uma prevalência de pacientes com níveis de gravidade 3 e 4.

Tabela 1: Comparação dos métodos de avaliação da gravidade da malária, incluindo diagnóstico médico¹, redes neurais regularizadas e o método difuso¹.

Método de Avaliação	Paciente																													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Diagnóstico Médico [2]	4	3	4	4	3	3	4	3	4	3	3	3	2	3	5	4	3	3	4	4	3	4	3	5	4	4	3	2	4	4
Fuzzy [2]	4	3	3	4	3	3	3	3	4	3	3	2	2	3	4	4	3	4	4	4	3	4	3	5	3	4	3	2	4	4
Redes Neurais Regularizadas	4	3	4	4	3	3	4	3	4	3	3	3	2	3	4	4	3	3	4	4	3	5	3	4	4	4	3	3	4	5

Tabela 2: Acurácia dos métodos propostos.

Critério de Parada	Metodologia de Treinamento e Teste	Neurônios na camada Intermediária	Acurácia (%)
Erro médio quadrático	<i>Leave-one-out</i>	1	76.7
		10	66.7
		14	66.7
	<i>10-fold cross validation</i>	45	63.3
		1	53.3
		10	60.0
Parada antecipada	10 - 10 - 10	14	63.3
		45	60.0
		1	60.0
	<i>Leave-one-out</i>	10	70.0
		14	83.3
		45	83.3
Regularização	<i>10-fold cross validation</i>	1	56.7
		10	60.0
	14	10	57.0
		14	57.0
45	60.0		

Tabela 3: Matriz de confusão do método com critério de parada de regularização, 10 neurônios na camada intermediária e treinamento *leave-one-out*.

Classe	Classificação				
	1	2	3	4	5
1	0	0	0	0	0
2	0	1	1	0	0
3	0	0	12	1	0
4	0	0	0	12	1
5	0	0	0	2	0

Verifica-se que a relação entre a quantidade de neurônios na camada escondida não interfere significativamente na acurácia dos métodos. Principalmente na utilização da metodologia com parada antecipada, em que qualquer quantidade de neurônios, apresenta o mesmo resultado para acurácia. 60%.

Através das Tabelas de confusão apresentadas, é notável que o módulo da distância entre os dados

classificados de maneira incorreta e a classe ideal é no máximo de 1, mostrando que o erro na classificação da gravidade é o menor possível.

Em comparação com [2], que apresentou um melhor valor de acurácia de 80%, o melhor resultado obtido nesse artigo para acurácia, 83,3% é levemente superior.

Tabela 4: Matriz de confusão do método com critério de parada do erro médio quadrático, um neurônio e treinamento *leave-one-out*.

Classe	Classificação				
	1	2	3	4	5
1	0	0	0	0	0
2	0	0	1	1	0
3	0	0	12	1	0
4	0	0	2	11	0
5	0	0	0	2	0

Conclusão

Os resultados mostram que, em geral, a rede neural com critério de parada de regularização, quando comparado aos outros dois critérios de parada, erro médio quadrático e parada antecipada, apresenta melhores resultados para acurácia. Acredita-se que esse resultado deve-se ao fato do mesmo apresentar um conjunto de treinamento com um maior número de pacientes.

Planeja-se, como desdobramento desse trabalho, ampliar o banco de dados junto a instituições médicas especializadas do estado do Amazonas.

Agradecimentos

Parte dos resultados apresentados neste trabalho foram obtidos através do Projeto de Pesquisa e formação de recursos humanos, em nível de graduação e pós-graduação, nas áreas de automação industrial, software para dispositivos móveis e TV Digital, financiado pela Samsung Eletrônica da Amazônia Ltda., no âmbito da Lei no. 8.387 (art. 2º)/91.

Referências

- [1] Bronzan RN, McMorro ML, Kachur SP. Diagnosis of malaria: challenges for clinicians in endemic and non-endemic regions. *Mol Diagn Ther.* 2008; 12(5): 299-306.
- [2] Uzoka FM, Osuji J, Obot O. Clinical decision support system (DSS) in the diagnosis of malaria: A case comparison of two soft computing methodologies. *Expert Systems with Applications.* 2011; 38, 1537-1553.
- [3] Seising, R. From vagueness in medical thought to the foundations of fuzzy reasoning in medical diagnosis. *Artificial Intelligence in Medicine.* 2006; 38, 237–257.
- [4] Wyatt J, Spiegelhalter D. Field trials of medical decision-aids: Potential problems and solutions. In: *Proceedings of the 15th Annual Symposium on Computer Applications in Medical Care of the American Medical Informatics Association*; 1991; Washington, DC. 1991. p. 3-7.
- [5] Szolovits P, Patil RS, Schwartz WB. Artificial intelligence in medical diagnosis. *Annals of Internal Medicine.* 1988; 108(1), 80–87.
- [6] Barros Jr AM, Duarte AA, Netto MB, Andrade BB. Artificial neural networks and Bayesian networks as supporting Tools for diagnosis of asymptomatic Malaria. In: *e-Health Networking Applications and Services (Healthcom), 12th IEEE International Conference*; 2010 Jul 1-3. p: 106-111.
- [7] Chandramohan D, Jaffar S, Greenwood B. Use of clinical algorithms for diagnosing malaria. *Tropical Medicine and International Health.* 2002; 7(1):45-52.
- [8] Suan OL. Computer-aided diagnosis and treatment of Malaria: the imex system. *Comput. Biol. Med.* 1990; 20(5): 361-372.
- [9] Russel SJ, Norvig P. *Inteligência Artificial.* Rio de Janeiro: Campus, 2003.
- [10] Kolmogorov AN. On the representation of Continuous Functions. *Dokl. Acad. Nauk.*; 1957; USSR, 114.
- [11] Kovasc ZL. *Redes Neurais Artificiais: Fundamentos e aplicações.* São Paulo: Edição Acadêmica; 1996.
- [12] More JJ. *The Levenberg-Marquardt Algorithm: Implementation and Theory.* Springer Verlag. 1977; 105-116.
- [13] Blum A, Kalai A, Langford J. Beating the hold-out: bounds for K-fold and progressive cross-validation. In: *COLT '99 Proceedings of the twelfth annual conference on Computational learning theory*; 1999; New York, USA. 1999. p. 203-208.
- [14] Doan CD, Liong SY. Generalization for multilayer neural network Bayesian regularization or early stopping. In: *Proceedings of Asia Pacific Association of Hydrology and Water Resources 2nd Conference*; 2004 Jul 5-8; Singapore.
- [15] MacKay, DJC. A Practical Bayesian Framework for Backpropagation Networks. *Neural Computation.* 1992; 4(3): 448-472.
- [16] MacKay, DJC. Bayesian Interpolation. *Neural Computation.* 1992; 4(3):415-447.
- [17] Demuth H; Beale M; Hagan M. *Neural Network Toolbox User's Guide.* Available from: <http://www.mathworks.com/products/neural-network/description6.html>
- [18] M. Sonka and J. M. Fitzpatrick. *Handbook of Medical Imaging. Volume 2: Medical Imaging Processing and Analysis.* Washington: Spie Press. 2000.