

UMA ABORDAGEM BASEADA EM REDES PERCEPTRON MULTICAMADAS E RBF PARA A CLASSIFICAÇÃO DE NÓDULOS MAMÁRIOS

Luan de Oliveira Moreira¹; Matheus Giovanni Pires²

1. Bolsista PROBIC, Graduando em Engenharia de Computação, Universidade Estadual de Feira de Santana, e-mail: luanecomp@yahoo.com.br
2. Orientador, Departamento de Ciências Exatas, Universidade Estadual de Feira de Santana, e-mail: mgpires@ecomp.uefs.br

PALAVRAS-CHAVE: Massas nodulares, câncer de mama, Redes Perceptron Multicamadas, Redes de Funções de Base Radial.

INTRODUÇÃO

O câncer de mama tem sido uma das principais causas de mortalidade entre as mulheres em toda a parte do mundo (TAHMOUSH, 2007). A mamografia é o método mais eficaz para detecção precoce da doença. De cada 100 mulheres submetidas a exames para detecção da presença de massas suspeitas do câncer de mama, 80% dos casos apresentam imagens mamográficas que, ao serem analisadas por um radiologista, geram dúvidas para um diagnóstico preciso (GLINGANI & AMBRÓSIO, 2004). Distorções na interpretação e classificação de lesões suspeitas por especialistas implicam em um número maior de biopsias desnecessárias, ou seja, entre 65% a 85% das biopsias de mama são realizadas em lesões benignas (RIBEIRO *et al.*, 2008).

Com o objetivo de auxiliar os especialistas na detecção precoce do câncer de mama, vêm sendo desenvolvidos esquemas denominados *Computer Aided Diagnosis* (CAD). Estes esquemas são sistemas computacionais que auxiliam no diagnóstico de pacientes e podem funcionar como uma segunda opinião aos radiologistas quanto à localização e à natureza dos nódulos mamários (RIBEIRO *et al.*, 2008).

As *Redes Neurais Artificiais* (RNAs) são frequentemente usadas como classificadores em esquemas CAD (RIBEIRO *et al.*, 2008), pois são classificadores que conseguem tratar informações ruidosas e possuem boa capacidade de generalização (aprendizado) (HAYKIN, 2001). Assim, com o objetivo de auxiliar especialistas da área de análise de imagens mamográficas no diagnóstico de massas nodulares, este trabalho propõe um estudo comparativo entre dois classificadores neurais, mais especificamente, as Redes Perceptron Multicamadas (PMC) e Redes de Funções de Base Radial (RBF) (HAYKIN, 2001).

METODOLOGIA

O bom desempenho de uma rede neural artificial, dentre outros fatores, está relacionado com a configuração de sua topologia. A topologia de uma RNA consiste em definir qual o melhor número de camadas, e também, qual o melhor número de neurônios por camada a rede deve possuir. Sendo assim, para encontrar a melhor topologia das redes neurais utilizadas neste trabalho foi adotada a técnica chamada *Validação Cruzada com Parada Antecipada* (VCPA) (do Inglês, *Cross Validation*).

A técnica VCPA consiste em dividir o conjunto de dados¹ do problema em questão em dois subconjuntos: treinamento e teste. Para cada novo ciclo (treinamento–validação–teste), os subconjuntos são recriados de forma aleatória a partir do conjunto de dados inicial. O subconjunto de treinamento ainda é dividido em mais dois subconjuntos, o de estimação e o de validação, que são utilizados durante o processo de treinamento das RNAs e se modificam

¹ O conjunto de dados possui todas as informações de um determinado problema. Este conjunto de dados é utilizado para o aprendizado e teste de uma RNA.

a cada novo ciclo de treinamento. A técnica VCPA busca garantir que as RNAs desenvolvidas generalizam todo o domínio do problema proposto (HAYKIN, 2001).

Os treinamentos e testes realizados nas RNAs foram feitos utilizando o banco de dados *Breast Cancer Wisconsin*, do repositório UCI Machine Learning, da Universidade da Califórnia (FRANK e ASUNCION, 2010). Essa base de dados é bastante conhecida no meio científico e já foi utilizada em diversos trabalhos científicos. As informações desta base de dados foram coletadas a partir de casos clínicos do Dr. Wolberg, da Universidade de Wisconsin. Esta base é composta por 699 amostras. Cada amostra representa as informações de um determinado nódulo mamário, o qual possui 11 atributos (características), sendo que um desses atributos é um identificador da amostra e outro informa a qual classe a amostra pertence, ou seja, se o nódulo é maligno ou benigno. Estes dois atributos são desnecessários para a composição dos dados de treinamento do classificador neural.

RESULTADOS

A métrica utilizada para definir qual a melhor topologia para as redes foi a taxa de acerto. Como o trabalho proposto consiste no desenvolvimento de um sistema de apoio ao diagnóstico de câncer de mama, é imprescindível que o sistema seja o mais confiável possível. Outro fator importante na realização dos testes das redes foi a utilização da técnica VCPA, pois a cada ciclo de teste os subconjuntos de treinamento e teste são recriados de forma aleatória. Desta forma, busca uma topologia de rede não especialista em apenas uma faixa do domínio do problema, e sim, uma topologia que permita à RNA aprender todo o domínio.

Para cada RNA foram realizados testes com diferentes topologias. A base de dados *Breast Cancer Wisconsin* foi dividida em subconjuntos de estimação, validação e teste, onde o subconjunto de estimação possui 586 amostras, o de validação 44 amostras e o de teste 69 amostras, totalizando 699.

Nos testes com a rede PMC, cada topologia foi treinada e testada 500 vezes. Esta quantidade de testes foi definida com o intuito de se obter uma boa amostragem dos resultados para facilitar a detecção de uma possível oscilação no desempenho da rede. Portanto, a partir das 500 execuções de uma determinada configuração, pode-se obter a média de épocas de treinamento, a média de acertos (em porcentagem) e o desvio padrão dos resultados gerados pela rede. Todas as configurações testadas possuem na camada de saída apenas um neurônio. A taxa de aprendizagem utilizada foi de 0,01, no entanto, para os testes 9, 10 e 12 foi usado 0,05, para que não houvesse repetição de configuração das topologias. A Tabela 1 mostra as topologias utilizadas no teste da rede PMC, além dos resultados obtidos para cada uma delas.

Tabela 1. Resultados dos testes com a rede PMC.

Teste	Topologia	Épocas	Taxa de Acerto (%)	Desvio Padrão
1	5-5	199	96,48	5,18
2	5-10	198	97,06	1,94
3	10-10	190	97,01	1,90
4	15-10	194	97,25	1,86
5	5-5-5	195	69,46	29,07
6	5-10-5	213	73,06	28,38
7	10-10-5	208	74,08	28,37
8	15-10-5	161	64,12	25,81
9	5-5	107	96,86	2,02
10	5-10	107	96,88	1,92
11	3-2	186	89,56	20,70
12	3-2	107	96,07	5,76

A topologia da rede PMC que resultou no melhor desempenho foi a do teste 10, pois além de possuir a maior taxa de acerto (96,88%), apresentou também o menor desvio padrão, o que significa que a rede é estável.

Em todos os testes com a rede RBF, a rede possuía somente um neurônio na camada de saída e a taxa de erro (critério de parada) foi definida em 0,00001. Os testes foram feitos com 18 configurações (topologias) distintas. Cada configuração foi treinada e testada 2500 vezes. A diferença na quantidade de treinamentos e testes realizados com a RBF em relação à PMC se dá pelo fato de que a RBF consome menos tempo de treinamento do que a PMC, por possuir uma quantidade de neurônios menor do que a PMC. A Tabela 2 apresenta as topologias utilizadas no teste da rede RBF, além dos resultados obtidos com cada configuração.

Tabela 2. Resultados dos testes com a rede RBF.

Teste	Camada Intermediária	Taxa de Aprendizagem	Momentum	Épocas	Taxa de Acerto (%)	Desvio Padrão
1	2	0,01	0,9	50	88,04	4,44
2	2	0,05	0,9	28	89,53	4,22
3	2	0,1	0,9	27	90,08	4,39
4	3	0,01	0,9	50	82,21	5,78
5	3	0,05	0,9	28	83,03	6,23
6	3	0,1	0,9	25	83,37	6,68
7	1	0,01	0,9	105	77,71	5,68
8	1	0,05	0,9	39	79,81	4,60
9	1	0,1	0,9	21	79,72	4,76
10	2	0,01	0,8	78	86,98	4,77
11	2	0,01	0,7	90	84,05	8,26
12	2	0,01	0,6	57	73,16	11,07
13	3	0,01	0,8	74	82	5,91
14	3	0,01	0,7	82	79,49	7,81
15	3	0,01	0,6	64	73,78	9,72
16	1	0,01	0,8	20	65,51	5,51
17	1	0,01	0,7	20	65,66	5,45
18	1	0,01	0,6	20	65,54	5,54

Das redes testadas, a melhor foi a do teste 3. Os seguintes fatos foram considerados para escolher esta rede como a melhor. Esta rede obteve a maior taxa de acerto, possui um baixo desvio padrão, o que significa que a rede possui um comportamento estável e conseguiu treinar em poucas épocas de treinamento, apenas 27 épocas.

Durante a análise dos resultados se percebeu que duas amostras dos testes nunca eram classificadas corretamente. A explicação pode ser pelo fato de que essas amostras estão em uma região do espaço que faz fronteira entre as duas classes (maligno e benigno), portanto, é de difícil classificação.

CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo um estudo comparativo entre dois classificadores baseados em redes neurais artificiais, mais precisamente, as Redes Perceptron Multicamadas e as Redes de Funções de Base Radial, aplicados ao problema de diagnóstico de câncer de mama. Os resultados obtidos não foram comparados com outros trabalhos, pois não se encontrou na literatura trabalhos que usassem a base de dados *Breast Cancer Wisconsin*.

A utilização das RNAs em esquemas CAD como classificadores de nódulos mamários se mostrou bastante satisfatória com as redes testadas, com taxa de acerto acima de 90%, tanto para a rede PMC, quanto para as RBF. Sendo assim, estes esquemas CAD podem servir com

uma segunda opinião para os especialistas no diagnóstico de câncer de mama. A vantagem da utilização da rede RBF é a sua velocidade no treinamento, a qual utiliza poucas épocas de treinamento. Por outro lado, a taxa de acerto da rede RBF não superou a da rede PMC, que apresentou uma taxa de 96,86% em sua melhor topologia.

Além da velocidade no aprendizado, a técnica de Validação Cruzada foi útil para validar a rede, ou seja, por utilizar amostras aleatórias da base de dados a cada treinamento, a rede correu menor risco de se tornar especialista, generalizando melhor e encontrando as melhores topologias para as redes neurais.

REFERÊNCIAS

FRANK, A.; ASUNCION, A. 2010. UCI Machine Learning Repository, <http://archive.ics.uci.edu/ml>, Irvine, CA: University of California, School of Information and Computer Science.

GLINGANI, F. A.; AMBRÓSIO, P. E. 2004. Sistema de análise computadorizada para auxílio à detecção de lesões de mama baseado em redes neurais artificiais, *In: Anais do IX Congresso Brasileiro de informática em Saúde*, Ribeirão Preto.

HAYKIN, S. 2001. *Redes Neurais Artificiais: Princípios e Práticas*. Porto Alegre, Bookman, 900p.

PATROCINIO, A. C. 2004. Classificador automático de achados mamográficos em imagens digitais de mamas densas utilizando técnicas híbridas. Universidade de São Paulo, Tese.

RIBEIRO, P. B. 2006. Classificação por Análise de Contornos de Nódulos Mamários Utilizando Redes Neurais Artificiais. Universidade de São Paulo, Tese.

RIBEIRO, P. B.; SCHIABEL, H.; PATROCINIO, A. C.; ROMERO, R. A. F. 2008. Análise da Variação de Textura em Imagens Mamográficas para Classificação de Massas Suspeitas. *In: III Workshop de Visão Computacional*, Bauru.

TAHMOUSH, D. 2007. Image differencing approaches to medical image classification. *In: 36th IEEE Applied Imagery Pattern Recognition Workshop*, Washington, p.22-27.