

Classificação De Pulsares:

Uma Análise Comparativa Das Redes MLP e RBF

Cassiano Perin De Carvalho¹, Náthalee Calvalcanti De Almeida Lima¹

¹Departamento de Engenharia e Tecnologia – Universidade Federal Rural Do Semi-Árido (UFERSA)
Pau Dos Ferros – RN – Brasil

Cassi18@hotmail.com.br, nathalee.almeida@ufersa.edu.br

Abstract. *Pulsars are objects that originate from supernova, a phenomenon occurring in the final stage of a star, and are extremely dense. The pulsars are subjects of prominence in scientific debates for their extreme characteristics, that make propitious to test some relativistic predictions. Understanding the scientific interest in pulsars is reasonable to propose automated methods for their classification. In this sense, the present work proposes to compare MLP and RBF networks in the task of classifying pulsars. Such results can aid in the design of automated detectors.*

Resumo. *Os pulsares são objetos que se originam de supernova, fenômeno ocorrido no estágio final de uma estrela, e são extremamente densos. Os pulsares são assuntos de destaque em debates científicos pelas suas características extremas, que tornam propícios para testar algumas previsões relativísticas. Compreendendo o interesse científico nos pulsares é razoável propor métodos automatizados para sua classificação. Neste sentido, o presente trabalho propõe comparar as redes MLP e RBF na tarefa de classificação de pulsares. Tais resultados podem ajudar no projeto de detectores automatizados.*

1. Introdução

Quando o combustível de uma estrela chega ao fim, existe a possibilidade da ocorrência de um fenômeno fascinante, que origina um dos objetos mais intrigantes do universo, as estrelas de nêutrons. Isso ocorre apenas quando a massa da estrela é extremamente elevada, entre 8 a 25 massas solares [GOMES, L. V. S.].

As estrelas de nêutrons foram previstas teoricamente em 1932, período em que os nêutrons foram descobertos. Mas sua detecção foi acidental em 1967, quando ondas de rádio periódicas, provindas de estrelas de nêutrons foram recebidas. Por este motivo, o objeto emissor foi denominado pulsar [LOPES, L. L.]. Pulsar trata-se de um tipo de estrela de nêutrons e acreditasse que todas as estrelas de nêutrons inicialmente foram pulsares.

Os pulsares fornecem um ambiente propício para constatação de fenômenos previstos pela teoria da relatividade geral, devido suas características extremas. Portanto são objetos de interesse científico [LOPES, L. L.]. Desta forma, métodos automáticos de classificação dos objetos observados reduziria o tempo necessário para encontrar os pulsares. Nesse sentido, destacam-se as redes neurais artificiais (RNA) amplamente aplicadas na tarefa de classificação.

Dentre as RNAs existentes, no presente trabalho, optou-se pela utilização da perceptron multicamadas (MLP) e da rede de base radial (RBF), uma vez que ambas são

largamente utilizadas na tarefa de classificação, além de amplamente discutidas na literatura.

Desta forma, no presente trabalho é efetuado um comparativo entre MLP e RBF na classificação de Pulsares. Para tanto, foi implementado um script em Matlab onde foram analisados a acurácia, a precisão, a sensibilidade e a especificidade das redes para a tarefa de classificação de Pulsares. Tais resultados caracterizam qual dos métodos é mais apropriado para o problema aqui abordado.

Na próxima seção serão discutidos os pulsares e as redes neurais artificiais em mais detalhes. Na seção 3 serão detalhadas as metodologias empregadas para simulação. Na seção 4 serão apresentados e discutidos os resultados obtidos na simulação. Por fim, segue uma breve conclusão.

2. Referencial Teórico

Nesta seção serão apresentados os principais conceitos relacionados aos pulsares e às redes neurais artificiais, dando ênfase a MLP e RBF. E, por fim, serão discutidos alguns trabalhos relacionados a classificação de pulsares.

2.1. Pulsares

Os pulsares, também denominados de estrelas densas, consistem em objetos extremamente densos, chegando a tal ponto que os núcleos dos átomos se fundem gerando uma matéria altamente condensada. Sua origem é proveniente da explosão de uma supernova, quando a maior parte da massa (da supernova) é enviada para o espaço, o gradiente de pressão torna-se tão elevado, na região que os elétrons e prótons da matéria remanescente unem-se, dando origem a nêutrons e neutrinos [FRANZON, B. C. S.].

Suas características extremas, como: densidade, temperatura, campo magnético. Fazem desses objetos interessantes para constatação de fenômenos previstos pela teoria da relatividade, ou seja, funcionando como um laboratório natural para física contemporânea [FRANZON, B. C. S.].

2.2. Redes Neurais Artificiais, MLP e RBF

As redes neurais artificiais (RNAs) são modelos matemáticos baseados nos princípios de funcionamento do cérebro, cuja principal intenção é simular a capacidade de processamento cerebral [HAYKIN, S.]. Tendo como principais características, a capacidade de aprendizado, a habilidade de generalização, a tolerância a falhas e o armazenamento distribuído [SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.].

O modelo de um neurônio artificial é dado como segue,

$$u = \sum_{i=0}^N w_i x_i \quad (1)$$

$$y = g(u) \quad (2)$$

onde u é o potencial de ativação, w_i é o i -ésimo peso sináptico (quando $i = 0$, w_i é o limiar de ativação - bias), x_i é a i -ésima entrada (quando $i = 0$, x_i é -1), $g(\cdot)$ é a função de ativação e y é a saída do neurônio artificial [SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.].

Mais especificamente, a MLP é um tipo de rede neural artificial com arquitetura feedforward de múltiplas camadas, ou seja, a MLP é composta por neurônios nas camadas intermediárias e de saída, inexistindo realimentação por neurônios de camadas superiores [HAYKIN, S.].

As redes de base radial (RBF) são assim chamadas porque possuem uma única camada de neurônios escondida, cuja função de ativação é gaussiana, como segue:

$$g_j(x) = e^{-\frac{\sum_{i=1}^N (x_i - w_{ij})^2}{2\sigma_j^2}} \quad (3)$$

onde w_{ij} é a média da i -ésima entrada no j -ésimo neurônio, x_i é a i -ésima entrada e σ_j é o desvio padrão do j -ésimo neurônio [SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.].

Também é caracterizada pela arquitetura feedforward de múltiplas camadas, mas os neurônios da camada apresentam comportamento diferente da MLP, sendo a região de separação, gerada pela RBF, campos receptivos hiperesférico [SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.].

2.3. Trabalhos Relacionados

Em [KLAMBAUER, G. et al.] são comparadas as principais técnicas de aprendizado profundo para três problemas de classificação encontrados na base de dados da UCI, foram utilizados os seguintes conjuntos de dados: conjunto de dados UCI 121 para aprendizado de máquina; descoberta de medicamentos; e classificação de pulsares. Constatando que as SNNs (*self-normalizing neural network*) obtiveram resultados excelentes para três problemas avaliados, destacando como melhor método para os problemas da descoberta de medicamento e detecção de pulsares, devido permitir topologias mais profundas.

Em [SOUZA, P. V. C.; GUIMARÃES, A. J.] é ressaltado a importância da classificação correta de pulsares por meios automatizados, uma vez que o atual processo de detecção pode ser demorado, prejudicando assim os avanços da física. Desta forma, propõem classificação por meio de redes neurais nebulosas e comparam com outros métodos automatizados, quais são, MLP, c4.5, *navies bayes*, GH-VFTD e SVN (*support vector machine*). Embora a acurácia de treinamento de 98,02 % das redes neurais nebulosas, modesta em comparação com outros métodos, sendo da RNA de 99,41 %, elas obtiveram maior acurácia de teste de 97,95 %, seguida pela GH-VFTD de 97,54 %. Implicando que as redes nebulosas fornecem em excelente método para classificação de pulsares.

3. Metodologia

O trabalho consiste em comparar as redes neurais artificiais, MLP e RBF, na tarefa de classificar pulsares. Para tanto, foram utilizados 17898 casos, sendo esses dividido em 60% para treinamento da rede e 40% para testar as redes. Os dados foram obtidos da UCI, na base de dados chamada HRTU2.

Os dados estão organizados em 8 entradas, quais são, média, desvio padrão, excesso de curtose e assimetria: do perfil integrado e da curva DM-SNR. E em uma saída, que distingue pulsar (1) de um não pulsar (-1).

No trabalho, foi utilizada uma MLP com 16 neurônios em sua única camada escondida, a função de ativação foi a tangente hiperbólica na camada escondida e função linear na camada de saída. Um esquema representativo é apresentado abaixo:




Figura 1: Esquema da MLP

Para o treinamento da MLP, foi utilizado índice de aprendizado de 0,16 e 1000 repetições, sendo o algoritmo de treinamento Levenberg-Marquardt.

Já a RBF, utilizada na comparação contém 25 neurônios na camada radial e desvio padrão de 0,4, onde todas as entradas forma normalizadas. Na Figura 2, é apresentado diagrama esquemático da topologia da rede RBF utilizada no presente trabalho.




Figura 2: Esquema da RBF

As redes foram simuladas no Matlab, para MLP foi utilizada função newff como apresentado em [MATSUNAGA, V. Y.], para RBF foi utilizada função newrb.

Na análise comparativa serão avaliados: a acurácia, que caracteriza a taxa de acertos da RNA, eq. 4

$$\text{Acurácia} = \frac{V_p + V_n}{V_p + V_n + F_p + F_n} \quad (4)$$

sendo V_p o número de verdadeiros positivos, V_n o número de falsos verdadeiro, F_p o número de falsos positivos e F_n número de falsos negativos; a precisão, que consiste na razão entre os acertos positivos e total avaliado como positivos, eq. 5

$$\text{Precisão} = \frac{V_p}{V_p + F_p} \quad (5)$$

ou seja, alta precisão indica que poucas dentro do conjunto das amostras classificadas como positivo poucas foram classificadas erroneamente; a sensibilidade, que consiste na razão entre os acertos positivos e total de positivos, eq. 6

$$\text{Sensibilidade} = \frac{V_p}{V_p + F_n} \quad (6)$$

Ou seja, alta sensibilidade indica que dentro do conjunto das amostras verdadeira poucas foram classificadas erroneamente; a especificidade, que consiste na razão entre os acertos negativos e total de negativos, eq. 7

$$\text{Especificidade} = \frac{V_n}{V_n + F_p} \quad (7)$$

Ou seja, alta especificidade indica que dentro do conjunto das falsas poucas foram classificadas erroneamente.

4. Resultados e Discussões

A tabela abaixo apresenta os resultados obtidos pelos dois métodos de classificação:

Tabela 1: Comparativo entre os resultados da MLP e da RBF

	MLP	RBF
Acurácia (%)	98,0	98,0
Precisão (%)	92,3	94,6
Sensibilidade (%)	85,4	82,6

Especificidade (%)	99,3	99,5
--------------------	------	------

Pela tabela 1, é possível concluir que a MLP obteve desempenho superior a RBF, com respeito a sensibilidade, 85,4% contra 82,6%. Ambas obtiveram mesma acurácia, de 98%. Nos demais quesitos, a RBF foi superior.

Vale ressaltar que, para o problema em questão, a característica mais importante da rede é a sensibilidade, sendo interessante que a rede seja conservadora, já que objetos classificados como pulsar poderiam passar por outra análise mais refinada. Desta forma, o emprego da MLP é mais interessante para aplicações de classificação de pulsares.

5. Conclusão

No presente trabalho, foi visto que os pulsares despertam o interesse da comunidade acadêmica, devido possuir características extremas que produz condições para testar diversos fenômenos previstos pela teoria da relatividade. Sendo assim, analisamos algumas topologias de redes neurais na classificação de pulsares, podem agilizar o processo descoberta destas estrelas de nêutrons.

Concluimos que a MLP apresentou os melhores resultados, sendo sua sensibilidade de 85,4 %, sendo este o parâmetro mais importante para validação da rede, no problema aqui tratado. Por outro lado, a RBF apresentou valores mais elevado para especificidade (99,5 %) e precisão (94,6 %).

6. Referências

GOMES, L. V. S.; *Proto-estrelas de nêutron com ressonância delta usando o modelo de Zimanyi-moszkowski*. 2010. Dissertação (mestrado em física) – Programa de pós-graduação em física, Universidade Federal de Roraima, Roraima.

LOPES, L. L.; *Estrelas de Nêutrons: do gás de nêutrons livres à inclusão de híperons e campo magnético*. 2012. Dissertação (mestrado em física), Universidade Federal de Santa Catarina, Florianópolis.

HAYKIN, S.; *Redes Neurais: Princípios e Práticas*. 2ª ed. Porto Alegre: Bookman, 2001.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.; *Redes Neurais Artificiais para engenharia e ciências aplicadas: fundamentos teóricos e aspectos práticos*. 2ª ed. Artliber, 2015.

FRANZON, B. C. S.; *Glúns em estrelas de nêutrons*. 2012. Dissertação (mestrado em física) – Instituto de Física, Universidade de São Paulo, São Paulo.

KLAMBAUER, G. et al. *Self-normalizing neural networks*. Advances in Neural Information Processing Systems. 2017.

SOUZA, P. V. C.; GUIMARÕES, A. J.; *Detecção de pulsares utilizando redes neurais nebulosas baseadas em uninormas*. Disponível em: https://www.researchgate.net/profile/Paulo_Campos_Souza/publication/327474412_Deteccao_de_pulsares_utilizando_redes_neurais_nebulosas_baseadas_em_uninormas/links/5b914e104585153a53fea745/Deteccao-de-pulsares-utilizando-redes-neurais-nebulosas-baseadas-em-uninormas.pdf, acesso em janeiro 2018.

MATSUNAGA, V. Y.; *Curso de redes neurais utilizando o Matlab*. Belém do Pará, 2012.