

Rede Neural Autoexpansível baseada na Teoria da Ressonância Adaptativa para a Identificação de Desordens no Fígado

Matheus Rodrigo Aprigio Candido ¹

Angela Leite Moreno ²

Resumo: O aprendizado de máquina vem se destacando na detecção de várias doenças, tais como, diversos tipos de câncer, doença de Parkinson, entre outras. Entre elas a detecção de doenças no fígado é extremamente importante, pois o fígado desempenha papel crucial no sistema digestório e é a maior glândula do corpo humano, realizando diversas funções vitais para o organismo, entre elas destacam-se a eliminação de substâncias tóxicas e a produção da bile, que é essencial para a digestão de gorduras. Contudo, a maioria dessas doenças são assintomáticas, por isso um diagnóstico precoce é fundamental para a redução do número de óbitos. Com isso surgiram alguns métodos de aprendizado de máquina cujo objetivo é a identificação de pacientes com desordem no fígado, tais como o método de Benchmark utilizado por [1], e os métodos ANN-1, ANN-2, ANN-3, Decision trees (DT), Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Random Forest (RF), XGBoost e Electron Beam Melting (EBM) utilizados por [2].

É nesse contexto que esse trabalho se insere ao apresentar os resultados obtidos pela rede neural baseada na Teoria da Ressonância Adaptativa Autoexpansível Euclidiana [3], abreviadamente (ARTAEE), na classificação de doenças hepáticas. O processo de pesquisa foi realizado implementando as redes no Scilab (software para computação numérica), cujo banco de dados utilizado para os experimentos foi o BUPA (*British United Provident Association*), disponível no repositório *UCI Machine Learning Repository* [4].

Para as simulações o método utilizado foi a validação cruzada (*cross-validation*), ou seja, os dados foram divididos em 10 partes mutuamente excludentes, dos quais nove são utilizados para treinamento e um para teste. Esse procedimento é realizado 10 vezes. Isso foi feito com o objetivo de avaliar a capacidade de generalização de um modelo. As duas principais métricas de validação aplicadas nos resultados obtidos foram acurácia (*ACC*), que avalia a performance geral do modelo e F1-Score, uma média harmônica e bastante utilizada para problemas na área da saúde.

Em relação a classificação, o objetivo foi encontrar a combinação de β e ρ que proporcionassem os resultados mais favoráveis para a classificação de doenças hepáticas no contexto deste estudo. Para isso, o parâmetro β foi variado de 0,05 a 0,70, com um incremento de 0,05, enquanto o parâmetro ρ foi variado de 0,05 a 0,7, com um incremento de 0,001, simultaneamente. Para melhorar a qualidade dos resultados obtidos, utilizou-se algumas formas de pré-processamento. Primeiramente verificou-se os resultados com os dados sem nenhuma forma de pré-processamento (ARTAEE). Em seguida, utilizou-se a normalização dos dados em relação aos valores mínimos e máximos de cada parâmetro

¹Universidade Federal de Alfenas,
matheus.candido@sou.unifal-mg.edu.br

²Universidade Federal de Alfenas - UNIFAL-MG,
angela.moreno@unifal-mg.edu.br

(ARTAEE-1), deste modo, cada um dos parâmetros foi contraído para o intervalo $[0, 1]$. Como alguns dos parâmetros eram relativamente altos, também foi realizado um pré-processamento utilizando a função logarítmica (ARTAEE-2). E, por fim, utilizou-se ambas as ideias: primeiramente aplicando a função logarítmica e, em seguida, normalizando em relação aos valores mínimos e máximos de cada parâmetro ao final da aplicação da função logarítmica (ARTAEE-3). Os resultados são apresentados na Tabela 1.

Tabela 1: Comparativo dos resultados obtidos com os presentes na literatura.

Autores	Método	ACC (%)	Sens. (%)	Esp. (%)	F1-Score
MCDERMOTT	Benchmark	58,00	N.A.	N.A.	N.A.
ABEYRATHNA	ANN-1	61,20	N.A.	N.A.	0,671
	ANN-2	59,40	N.A.	N.A.	0,652
	ANN-3	60,20	N.A.	N.A.	0,656
	DT	59,60	N.A.	N.A.	0,728
	SVM	57,10	N.A.	N.A.	0,622
	KNN	56,60	N.A.	N.A.	0,638
	RF	60,70	N.A.	N.A.	0,729
	XGBoost	63,50	N.A.	N.A.	0,656
	EBM	62,90	N.A.	N.A.	0,710
	Este Trabalho	ARTAEE	71,03	93,00	40,71
Este Trabalho	ARTAEE-1	72,42	81,50	60,00	0,771
Este Trabalho	ARTAEE-2	73,63	100,00	76,76	0,795
Este Trabalho	ARTAEE-3	75,93	87,00	60,76	0,807

N.A.: Não apresenta

Pode-se notar que as mudanças na rede demonstraram ser eficazes, alcançando melhores métricas em relação aos resultados inicialmente obtidos. Esses resultados satisfatórios indicam que esse modelo pode ser utilizado como suporte no processo de tomada de decisão médica, auxiliando no diagnóstico precoce de desordens hepáticas.

O presente trabalho foi realizado com o apoio da FAPEMIG.

Referências

- [1] MCDERMOTT, J.; FORSYTH, R. S. Diagnosing a disorder in a classification benchmark. *Pattern Recognition Letters*, Elsevier, v. 73, p. 41–43, 2016.
- [2] ABEYRATHNA, K. D. et al. A multi-step finite-state automaton for arbitrarily deterministic tsetlin machine learning. *Expert Systems*, Wiley Online Library, v. 40, n. 4, p. e12836, 2023.
- [3] MORENO, A. L. *Redes Neurais ART e ARTMAP com Treinamento Continuado*. Saarbrücken: Novas Edicoes Academicas, 2016. ISBN 978-3330740051.
- [4] DUA, D.; GRAFF, C. *UCI Machine Learning Repository*. 2017. Disponível em: <http://archive.ics.uci.edu/ml>.