

Rede neural ART auto-expansível na detecção da doença de Parkinson

Reginaldo J. Silva¹

FEIS/UNESP, Ilha Solteira, SP

Angela L. Moreno²

DEMAT/UNIFAL-MG, Alfenas, MG

A Doença de Parkinson (DP) é uma doença evolutiva, neurodegenerativa e crônica descrita pela primeira vez por James Parkinson em 1817 e é um dos distúrbios neurológicos mais comuns, ficando atrás apenas da doença de Alzheimer, afetando cerca de 100 a 200 pessoas a cada 100.000 [1]. A detecção no início da doença possibilita o tratamento nos estágios iniciais, retardando a evolução da doença. No entanto, não existe um exame específico para realizar o diagnóstico. Como a doença afeta a fala [2], alguns trabalhos na literatura utilizam dados obtidos a partir da fala e métodos de aprendizado de máquina para classificar a doença. O estudo pioneiro usando essa abordagem foi publicado em 2009 e está disponível em [3]. Com base nisso, este trabalho apresenta os resultados obtidos pela rede neural ART Euclidiana Auto-Expansível (ARTEAE), baseada na Teoria da Ressonância Adaptativa (*Adaptive Resonance Theory - ART*), para a classificação da doença de Parkinson comparando-os com os da literatura.

Os dados utilizados foram obtidos por [4] e podem ser encontrados no *UCI - Machine Learning Repository*. Os dados consistem em medidas acústicas extraídas de gravações de voz de 40 pessoas, sendo 20 com DP e 20 saudáveis. O conjunto é composto por 1040 dados contendo 26 amostras de voz de cada paciente ($26 \cdot 40 = 1040$), possui 29 atributos, sendo 26 medidas acústicas, um atributo de identificação do paciente (que não é utilizado no treinamento da rede), um valor dado por um especialista a partir da Escala Unificada de Avaliação para Doença de Parkinson (*Unified Parkinson's Disease Rating Scale - UPDRS*) na qual cada indivíduo é avaliado por um médico especializado em diagnóstico de DP e recebe uma posição nesta escala, além de um indicador de categoria.

Para avaliar a capacidade de generalização do modelo, foi utilizado o método de validação cruzada *10-fold*, no qual os dados são divididos em dez subconjuntos, o treinamento é realizado com nove desses subconjuntos e um para testes, esse processo é repetido até que todos os subconjuntos de dados sejam utilizados para a análise. Os resultados apresentados são relativos à média das 10 classificações. As métricas de avaliação utilizadas para validar os resultados foram acurácia (ACC), sensibilidade (Sens), especificidade (Sp) e o coeficiente de correlação de Matthews (MCC).

A estrutura do modelo proposto pode ser vista na Figura 1. Optou-se por realizar o pré-processamento com a transformação logarítmica com o intuito de suavizar a variação causada pelos valores extremos, a rede ARTEAE utilizada foi desenvolvida por [5], por se tratar de uma rede ART possui uma alta capacidade de generalização e adaptação, no entanto, ao contrário das redes ART tradicionais, essa nova rede não possui estrutura fixa, iniciando com um único *cluster* e se expandindo de acordo com a necessidade de comportar novos *clusters*. Além disso, como cada paciente do banco de dados possui 26 tipos diferentes de gravações, a técnica de votação foi utilizada para definir a classe final do paciente levando em consideração o rótulo mais frequente para o paciente [2].

¹regisilva_mb@hotmail.com

²angela.moreno@unifal-mg.edu.br




Figura 1: Modelo Proposto.

Os parâmetros β e ρ da rede foram ajustados a partir de uma busca exaustiva com o objetivo de alcançar os melhores resultados, vale ressaltar que a taxa de treinamento β controla a velocidade de adaptação e o parâmetro de vigilância ρ controla a ressonância da rede, responsável pela criação de categorias. Após a busca, os melhores parâmetros encontrados foram $\beta = 0,2$ e $\rho = 0,203$. O modelo atingiu uma $ACC = 90,00\%$ e $MCC = 0,8040$; o comparativo dos resultados pode ser visto na Tabela 1. Destaca-se que [2] não utiliza o banco de dados completo, pois o mesmo aplica um método para seleção de atributos e o 40 -fold para validação. O A-MCFS utilizado por [2] remove todas as gravações de voz que não possuem recursos com uma correlação significativa.

Tabela 1: Comparativo dos resultados.

Autores	Classificador	Seleção de atributos	ACC	Sens	Esp	MCC
[2]	ANN (fine-tuned) [2]	A-MCFS	86,47%	88,91%	84,02%	0,7321
[2]	ANN 10 [2]	–	67,25%	69,33%	65,17%	0,3467
Este estudo	ARTEAE [5]	–	90,00%	85,00%	95,00%	0,8040

A rede atingiu um resultado satisfatório, a acurácia alcançada foi superior aos da literatura confirmando a eficácia do modelo proposto. Em trabalhos futuros pretende-se focar em buscar os melhores resultados focando na sensibilidade, tendo em vista o problema envolvido, como também utilizar outras redes, além de técnicas para seleção de atributos.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo auxílio financeiro.

Referências

- [1] M. Kasten, A. Chade e C. M. Tanner. “Epidemiology of Parkinson’s disease”. Em: **Handbook of clinical neurology** 83 (2007), pp. 129–151. DOI: 10.1016/S0072-9752(07)83006-5.
- [2] L. Berus et al. “Classifying Parkinson’s Disease Based on Acoustic Measures Using Artificial Neural Networks”. Em: **Sensors** 19.1 (dez. de 2018), p. 16. DOI: 10.3390/s19010016.
- [3] M. A. Little et al. “Suitability of dysphonia measurements for telemonitoring of Parkinson’s disease”. Em: **Nature Precedings** (set. de 2009). DOI: 10.1038/npre.2008.2298.1.
- [4] B. E. Sakar et al. “Collection and analysis of a Parkinson speech dataset with multiple types of sound recordings”. Em: **IEEE Journal of Biomedical and Health Informatics** 17.4 (2013), pp. 828–834.
- [5] A. L. Moreno. **Redes Neurais ART e ARTMAP com Treinamento Continuado: Uma apresentação detalhada dos principais tipos de redes neurais do tipo ART e ARTMAP**. Ed. por Novas Edições Acadêmicas. Saarbrücken: Novas Edições Acadêmicas, 2016. ISBN: 978-3330740051.