

## Redes Neurais Autoexpansíveis baseadas na Teoria da Ressonância Adaptativa aplicadas a problemas da saúde

Angela Leite Moreno <sup>1</sup>

**Resumo:** As redes neurais artificiais são um tipo de modelo computacional inspirado no funcionamento do cérebro humano, que consiste em interconectar um grande número de unidades de processamento simples, chamadas de neurônios artificiais, para realizar tarefas de aprendizado e tomada de decisão. São algoritmos capazes de aprender e generalizar a partir de dados, permitindo que os sistemas automatizados tomem decisões e realizem tarefas complexas sem a necessidade de programação explicitamente.

A Teoria da Ressonância Adaptativa (ART) proposta por Grossberg oferece uma abordagem eficaz para lidar com o dilema da estabilidade-plasticidade, isto é, a capacidade de aprender (plasticidade) sem experimentar o esquecimento catastrófico (estabilidade), ou seja, esquecer-se do conhecimento já aprendido [1].

Os modelos ART são redes competitivas, auto-organizadas, dinâmicas e modulares. Quando uma amostra é apresentada, após a leitura dos dados uma competição ocorre sobre suas categorias na camada de saída, na qual o vencedor leva tudo. Em seguida, é escolhido o neurônio que otimiza a função de ativação, desse modelo entre os nós que mais se aproxima do parâmetro procurado. Durante o processo de classificação, é escolhida uma categoria para representar um dado, em seguida, é realizado o teste de vigilância pelo subsistema orientado para determinar se a categoria vencedora satisfaz um critério de correspondência. Se a confiança em tal hipótese for maior que o limite mínimo (ou seja, o parâmetro de vigilância  $\rho$ ), a rede neural entra em um estado de ressonância e o aprendizado é permitido. Caso contrário, a categoria escolhida *a priori* é inibida, a próxima categoria de classificação mais alta é selecionada e a pesquisa é retomada. Se nenhuma categoria satisfizer as condições de ressonância necessárias, então uma nova é criada para codificar a amostra de entrada apresentada [2].

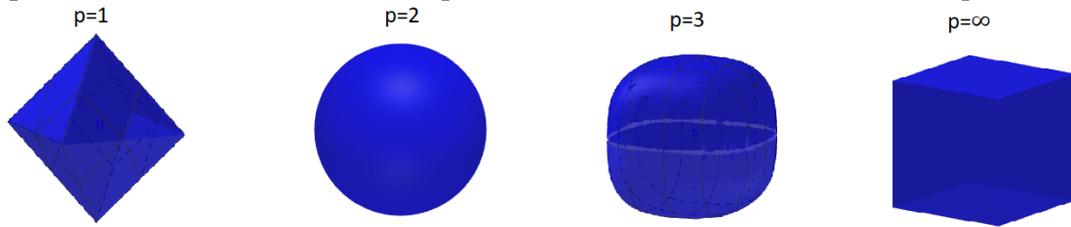
As condições de ressonância dependem do parâmetro de vigilância  $\rho$ , o qual determina o grau de variação admitido no aprendizado de categorias, ou seja, quão refinada será a rede. Portanto, baixo padrão de vigilância implica em maiores generalizações [1].

Uma abordagem para tentar melhorar o desempenho desta rede é a alteração da sua topologia, tendo como consequência a modificação na forma como os dados são classificados. Deste modo, com uma maior gama de topologias que podem ser utilizadas o usuário pode encontrar uma representação mais adequada dos dados. Com isso, há maiores possibilidades da rede aprender padrões e características relevantes para a classificação correta. Uma das formas de modificar a topologia da rede é através da alteração da métrica utilizada nos cálculos dos centros de categorias. A métrica é fundamental para determinar a distância entre o dado e as categorias existentes. Dependendo da métrica escolhida, os dados serão

<sup>1</sup>Universidade Federal de Alfenas - UNIFAL-MG,  
angela.moreno@unifal-mg.edu.br

agrupados de maneiras diferentes, o que pode impactar significativamente a capacidade da rede no processo de classificação ou previsão, podendo melhorar o desempenho. Uma vez que, a variação das topologias das categorias expande as possibilidades de representação dos dados, possibilitando capturar formas mais complexas de agrupamentos.

Figura 1: Diferentes formas de categorias em  $\mathbb{R}^3$  centradas em  $x_0$  conforme  $p$  aumenta.



Dessa forma, a essência deste trabalho é apresentar uma visão dessa arquitetura bem como os resultados obtidos utilizando diferentes métricas como a do mínimo (distância *Fuzzy*), norma Euclidiana e norma  $p$  (Figura 1). Além de mostrar seu impacto em problemas diversos da saúde como, por exemplo, na classificação de doenças como Parkinson, detecção de Câncer de Mama, detecção de Câncer de Pâncreas, Problemas da Coluna Vertebral, previsão de sobrevida em relação à cirurgia cardíacas, entre outras [3].

## Referências

- [1] CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer vision, graphics, and image processing*, Maryland Heights, US, v. 37, n. 1, p. 54–115, 1987. DOI:<[https://doi.org/10.1016/S0734-189X\(87\)80014-2](https://doi.org/10.1016/S0734-189X(87)80014-2)>.
- [2] SILVA, L. E. B. da; ELNABARAWY, I.; WUNSCH, D. C. A survey of adaptive resonance theory neural network models for engineering applications. *Neural Networks*, v. 120, p. 167–203, 2019. ISSN 0893-6080. DOI:<<https://doi.org/10.1016/j.neunet.2019.09.012>>.
- [3] MORENO, A. L. *Redes Neurais ART e ARTMAP com Treinamento Continuado: Uma apresentação detalhada dos principais tipos de redes neurais do tipo ART e ARTMAP*. Saarbrücken: Novas Edicoes Academicas, 2016. ISBN 978-3330740051.