

Agrupamento de figuras utilizando a Rede ART Fuzzy

David Vinicius da Silva¹

IFSP/Câmpus Hortolândia

Carlos Roberto dos Santos Junior²

IFSP/Câmpus Hortolândia

Thays Abreu (Orientadora)³

IFSP/Câmpus Hortolândia

As redes neurais artificiais (RNA) baseadas na teoria da ressonância adaptativa, redes neurais da família ART [3], possuem a habilidade de aprender com novas entradas sem destruir os aprendizados já assimilados por meio de outras amostras. Isso confere as redes dessa família as características de flexibilidade e adaptabilidade. A ART Fuzzy é uma rede não-supervisionada e sua arquitetura, basicamente, é formada por três camadas: entrada, reconhecimento e comparação [4].

A camada de entrada é responsável pelo pré-processamento dos dados antes do treinamento [4]. Já a camada de reconhecimento e comparação trabalham conjuntamente verificando o quão parecido é um padrão de entrada com um padrão já reconhecido pela RNA [4]. Um ponto importante dessa arquitetura é o parâmetro de vigilância, representado pela letra grega ρ (rô). Esse parâmetro é representado com um valor entre zero e um, sendo o responsável por estabelecer a taxa mínima de similaridade entre os valores de entrada e os valores aprendidos pela rede. Um valor alto de ρ significa decisões mais criteriosas, criando classes específicas para o reconhecimento dos padrões. Um valor baixo de ρ permite uma maior generalização das entradas, consequentemente resultando em menos classes [4].

Com isso, assume-se como hipótese que a RNA ART Fuzzy pode possuir alguma vantagem no agrupamento de figuras. Dessa forma, este resumo se propõe a verificar o desempenho de uma RNA ART Fuzzy [2] na agrupamento de figuras, especificamente, com o objetivo de avaliar o desempenho da ART Fuzzy em agrupar figuras em classes diferentes para entradas distintas.

Foram criadas cerca de 20 imagens para cada figura geométrica plana nas dimensões: 10x10, 50x50 e 100x100. Totalizou-se cerca de 60 imagens para cada tipo de figura, sendo que cada imagem possuía variações no tamanho da forma. As figuras geométricas utilizadas neste experimento foram o retângulo e a elipse. Exemplo das imagens pode ser encontrados na Figura 1.




Figura 1: (a) Exemplo de figura de retângulo de 100X100. (b) Exemplo de figura de elipse de 100x100.

Antes do treinamento da RNA, ocorreu um pré-processamento sobre as imagens. Primeiro, as imagens foram convertidas para escala de cinza, dessa maneira, os valores contidos nelas se

¹david.vinicius@aluno.ifsp.edu.br

²carlos.rsantos@ifsp.edu.br

³thays7abreu@gmail.com

transformaram de uma matriz de três dimensões para uma matriz de apenas uma dimensão para enfim ser convertida como um vetor para entrada da rede. Foi definido arbitrariamente três valores para o parâmetro de vigilância: 0,75; 0,85 e 0,95. O experimento foi realizado uma vez para cada tamanho e valor de parâmetro de vigilância, resultando ao todos em 9 resultados. Foram utilizados a acurácia, precisão, *recall* e *F1 score* como forma de verificação dos resultados, os critérios empregados para a verificação são descritos na Tabela 1.

Tabela 1: Parâmetros para os critérios de avaliação.

Verdadeiro Positivo (VP)	Imagens de elipse agrupadas como elipse
Falso Positivo (FP)	Imagens de retângulo agrupadas como elipse.
Falso Negativo (FN)	Imagens de elipse agrupadas como retângulo.
Verdadeiro Negativo (VN)	Imagens de retângulo agrupadas como retângulo.

Os resultados adquiridos são apresentados na Tabela 2.

Tabela 2: Resultado.

Dimensão das imagens	parâmetro de vigilância	Acurácia	Precisão	Recall	F1
10x10	0,75	65,00%	75,00%	45,00%	56,25%
10x10	0,85	40,00%	41,66%	50,00%	45,45%
10x10	0,95	67,50%	62,96%	85,00%	72,34%
50x50	0,75	72,50%	84,62%	55,00%	66,66%
50x50	0,85	95,00%	95,00%	95,00%	95,00%
50x50	0,95	90,00%	86,36%	95,00%	90,47%
100x100	0,75	32,50%	26,66%	20,00%	22,85%
100x100	0,85	60,00%	64,28%	45,00%	52,94%
100x100	0,95	82,50%	80,95%	85,00%	82,92%

Observando os resultados da Tabela 1, nota-se que aparentemente com um maior número de dados, nos casos de imagens de 50x50 e 100x100, e com um parâmetro de vigilância mais criterioso a ART Fuzzy parece conseguir agrupar melhor os dados do que em casos com menos informações, imagens de tamanho 10x10. Outro ponto a se relevar é que para os casos em que a ART Fuzzy era determinada como mais criteriosa - com o parâmetro de vigilância tendo o valor 0,95 - o valor de *recall* foi superior ao valor de precisão. O que sugere que a rede conseguiu evitar melhor as situações de imagens de elipse agrupadas como retângulo.

Referências

- [1] Abreu, Thays; Amorin, Aline J.; Santos-Junior, Carlos R.; Lotufo, Anna D.P. and Minussi, Carlos R. Multinodal load forecasting for distribution systems using a fuzzy-artmap neural network. *Applied Soft Computing*, 71: 307-316, 2018.
- [2] Carpenter, G. A.; Grossberg, S. and Rosen D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Network*, 4(1): 759-771, 1991.
- [3] Grossberg, S. Adaptive pattern classification and universal recoding, I: parallel development and coding of neural feature detectors. *Biological Cybernetics*, 23(3): 121-134, 1976.
- [4] Lopes, M. Maria Lúcia. "Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica", Tese de Doutorado, Universidade Estadual Paulista - UNESP, 2005.