

MODELOS DE INTELIGÊNCIA ARTIFICIAL APLICADA À IDENTIFICAÇÃO DE FALHAS NO SISTEMA ELÉTRICO DE POTÊNCIA¹

Diovana Fátima Menegat da Rocha², Stefano Frizzo Stefenon³, Ademir Nied⁴.

¹ Vinculado ao projeto “Desenvolvimento da tecnologia de motor elétrico sem manais para aplicações industriais”

² Acadêmica do Curso de Engenharia Elétrica – CCT – Bolsista PROBIC

³ Programa de Pós-Graduação em Engenharia Elétrica – CCT

⁴ Orientador, Departamento de Engenharia Elétrica – CCT – ademir.nied@udesc.br

A Inteligência Artificial (IA) procura reproduzir através de aprendizado de máquina uma ação ou escolha que a inteligência humana tem capacidade de realizar. Desta forma, são utilizados algoritmos para identificar padrões e com base nestes padrões realizar escolhas, seja para identificar uma característica ou para prever um fato ao longo do tempo.

Um conjunto de dados obtidos com uma determinada frequência de tempo, pode ser utilizado para previsão de séries temporais, pois fornecem um meio de ponderação dos dados para o cálculo de valores futuros. A partir da estrutura e funcionamento do neurônio biológico, pesquisadores tentaram simular este sistema em computador. Um neurônio matemático de uma rede neural artificial é um componente que calcula a soma ponderada de várias entradas, aplica uma função e passa o resultado adiante.

A propriedade mais importante das redes neurais é a habilidade de aprender sobre o ambiente, e com isso melhorar seu desempenho. O treinamento é realizado através de um processo iterativo de ajustes aplicado a seus pesos. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

O processamento em cada neurônio se dá pelo que se chama de função de ativação (ver Figura 1). A escolha das funções de ativação de uma rede neural são uma consideração importante uma vez que definem como devem ser seus dados de entrada.




Figura 1. Função de ativação

Uma das maiores dificuldades encontradas no uso das redes neurais é a escolha da melhor arquitetura, uma vez que esse processo é experimental e demanda um grande tempo de execução. Na prática, o processo deve ser aplicado com o intuito de testar vários métodos de aprendizado e as diferentes configurações que uma rede possa ter para a resolução de um problema em específico. Em geral, pode-se identificar três classes de arquiteturas de rede fundamentalmente diferentes: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes [1].

O perceptron é uma forma simples de RNA cuja principal aplicação se dá nos problemas de classificação de padrões. O perceptron de camada única só é capaz de classificar padrões linearmente separáveis. Na prática, o problema a ser trabalhado não admite uma separação linear exata, tornando-se necessário o uso de um perceptron multicamadas.

O ANFIS (Sistema de Inferência Neuro-Fuzzy Adaptativo) herda da rede neural sua capacidade de aprendizagem, classificação, robustez, e da lógica fuzzy a capacidade de adaptação e agrupamento de dados comuns em *clusters*. Um sistema ANFIS é um tipo de RNA baseada na teoria de Takagi-Sugeno, que integra nas redes neurais princípios de lógica Fuzzy. Desta forma, tem potencial para utilizar as vantagens de ambas as técnicas [2].

Já o LSTM (do inglês *Long Short-term Memory* ou Memória Longa de Curto Prazo) é uma rede neural recorrente (RNN) utilizada na aprendizagem profunda (*Deep Learning*). Uma unidade LSTM geralmente é composta de uma célula, uma porta de entrada, uma porta de saída e uma porta de esquecimento. Com base em dados de séries temporais, os LSTMs são adequados para fazer previsões, sendo que foram desenvolvidos para lidar com problemas graduais do treinamento de RNNs.

E, por último, Ensemble *Learning*, também chamado de aprendizado por agrupamento, se baseia na ideia de combinar modelos de predição mais simples (*weak learner*), treiná-los para uma mesma tarefa, e produzir a partir desses um modelo agrupado mais complexo (*strong learner*) que é a soma de suas partes. Os principais métodos de Ensemble *Learning* são *bagging*, *boosting* e *stacking* [3].

Palavras-chave: Previsão de falha. Inteligência Artificial. Redes Neurais.

Referências:

- [1] STEFENON, S. F. et al. Fault Diagnosis of Insulators from Ultrasound Detection Using Neural Networks. **Journal of Intelligent & Fuzzy Systems**, v. 37, n. 5, p. 6655-6664, 2019.
- [2] STEFENON, S. F. et al. Analysis of Training Techniques of ANN for Classification of Insulators in Electrical Power Systems. **IET Generation, Transmission & Distribution**, v. 14, n. 8, p. 1591-1597, 2020.
- [3] RIBEIRO, Matheus Henrique dal Molin; COELHO, Leandro dos Santos. Ensemble approach based on bagging, boosting and stacking for short-term prediction in agribusiness time series, **Applied Soft Computing**. Elsevier, v. 86, n. 105837, jan. 2020.