

REDES NEURAIIS ARTIFICIAIS: ESTRUTURA, MODELAGEM MATEMÁTICA E EXEMPLO DE APLICAÇÃO**ARTIFICIAL NEURAL NETWORKS: STRUCTURE, MATHEMATICAL MODELING AND APPLICATION EXAMPLES** <https://doi.org/10.63330/aurumpub.005-002>**Joelson Lopes da Paixão**

Mestre em Engenharia Elétrica, especialista em Engenharia de Segurança do Trabalho e em Educação Básica, Tecnológica e EAD
UFSM

E-mail: joelson.paixao@hotmail.com

RESUMO

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, utilizados para resolver problemas complexos por meio de aprendizado adaptativo. Este trabalho apresenta uma análise teórica sobre a estrutura e o funcionamento das RNAs, abordando sua modelagem matemática, principais arquiteturas e métodos de aprendizado. Além disso, são discutidas suas aplicações em otimização, regressão, previsão e classificação de dados, destacando a capacidade desses sistemas em lidar com interações não lineares e padrões complexos. O estudo inclui uma comparação entre diferentes topologias de redes, bem como a influência dos algoritmos de treinamento no desempenho da RNA. Por fim, é apresentado um exemplo prático de aplicação, evidenciando a eficácia desse método na solução de problemas de modelagem matemática.

Palavras-chave: Inteligência Artificial; Otimização; Redes Neurais Artificiais; Aprendizado de Máquina; Modelagem Matemática.

ABSTRACT

Artificial Neural Networks (ANNs) are computational models inspired by the functioning of the human brain, designed to solve complex problems through adaptive learning. This study presents a theoretical analysis of ANN structure and functionality, covering their mathematical modeling, main architectures, and learning methods. Additionally, their applications in optimization, regression, forecasting, and data classification are discussed, highlighting their ability to handle nonlinear interactions and complex patterns. The study includes a comparison between different network topologies and the impact of training algorithms on ANN performance. Finally, a practical application example is presented, demonstrating the effectiveness of this method in solving mathematical modeling problems.

Keywords: Artificial Intelligence; Optimization; Artificial Neural Networks; Machine Learning; Mathematical Modeling.



1 INTRODUÇÃO

A crescente complexidade dos problemas computacionais e a necessidade de tomadas de decisão rápidas e precisas impulsionaram o desenvolvimento de técnicas baseadas em Inteligência Artificial (IA). Entre essas técnicas, as Redes Neurais Artificiais (RNAs) destacam-se como modelos computacionais inspirados no funcionamento do cérebro humano, possuindo a capacidade de processar informações de maneira distribuída e paralela. Seu princípio fundamental baseia-se no aprendizado a partir de exemplos, permitindo a resolução de problemas que envolvem padrões complexos, não linearidades e incertezas (RUMELHART; MCCLELLAND, 1986).

A IA tem suas raízes nos estudos de Alan Turing na década de 1950, quando foi proposto um teste para avaliar a capacidade de máquinas em imitar o comportamento humano (TURING, 1950). Desde então, diversas abordagens foram desenvolvidas para que os sistemas computacionais adquirissem habilidades de aprendizado e inferência. Diferentemente dos algoritmos tradicionais, que requerem programação explícita para cada situação, as RNAs são treinadas para reconhecer padrões e gerar respostas apropriadas com base nos dados de entrada.

O princípio de funcionamento das RNAs consiste na modelagem matemática de neurônios artificiais, organizados em camadas interconectadas, capazes de ajustar seus parâmetros internos por meio de algoritmos de aprendizado. Esses modelos têm sido amplamente aplicados em otimização, regressão, previsão e classificação de dados, demonstrando versatilidade em diversas áreas, como engenharia elétrica, processamento de sinais, bioinformática e finanças (HAYKIN, 2009).

Dessa forma, este trabalho tem como objetivo apresentar uma análise teórica das RNAs, discutindo sua estrutura, modelagem matemática e aplicações práticas. Serão abordadas as principais topologias de redes, os métodos de aprendizado e as funções de ativação utilizadas nesses modelos. Além disso, um exemplo prático será apresentado para ilustrar a eficiência das RNAs na resolução de problemas complexos, destacando sua importância para o avanço da Inteligência Artificial e da otimização computacional.

2 REDES NEURAIS ARTIFICIAIS

As RNAs são modelos computacionais inspirados no funcionamento do sistema nervoso humano. Elas consistem em um conjunto interconectado de neurônios artificiais que processam informações por meio de um aprendizado adaptativo. Devido à sua capacidade de capturar padrões complexos e não lineares, as RNAs vêm sendo amplamente utilizadas em diversas aplicações, como modelagem matemática, previsão, classificação e otimização (HAYKIN, 2009).

Cada RNA é composta por unidades de processamento simples, chamadas neurônios artificiais, organizadas em uma arquitetura específica que determina o fluxo da informação dentro da rede. Essas unidades aplicam funções matemáticas sobre os dados de entrada, ajustando seus parâmetros internos por


meio de algoritmos de aprendizado. Dessa forma, as RNAs são capazes de generalizar padrões e realizar inferências mesmo em ambientes de alta complexidade (RUMELHART; MCCLELLAND, 1986).

2.1 ESTRUTURA DAS REDES NEURAIS ARTIFICIAIS

O funcionamento das RNAs é baseado em três elementos fundamentais:

1. **Camadas de neurônios:** as RNAs são compostas por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A quantidade de camadas ocultas e de neurônios impacta diretamente a capacidade da rede de representar funções complexas.
2. **Pesos sinápticos:** cada conexão entre neurônios possui um peso, que regula a intensidade da transmissão de informação entre as unidades. Durante o treinamento, esses pesos são ajustados para minimizar erros e melhorar a performance da rede.
3. **Função de ativação:** determina a resposta do neurônio com base nos valores recebidos. As principais funções de ativação incluem linear, degrau, sigmoidal e ReLU (Rectified Linear Unit), cada uma com características específicas para diferentes aplicações (HAYKIN, 2009).

A Figura 1 apresenta a estrutura de um neurônio biológico real, cuja modelagem serviu de base para a concepção das RNAs.



Fonte: Borges et al. (2015).


A modelagem matemática de um neurônio artificial é baseada na equação (1):

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (1)$$

onde:

- x_i são os sinais de entrada,
- w_i são os pesos sinápticos,
- b é o termo bias,
- f é a função de ativação,
- y representa a saída do neurônio.

A Figura 2 ilustra um modelo simplificado de neurônio artificial, destacando os principais componentes.



Fonte: (SOARES; SILVA, 2011).


2.2 ARQUITETURAS DAS REDES NEURAIS ARTIFICIAIS

As RNAs podem ser classificadas conforme sua arquitetura de conectividade e propagação da informação. As duas principais categorias são:

1. **Redes de Propagação Direta (Feedforward Neural Networks – FNNs):** a informação flui em uma única direção, da camada de entrada para a camada de saída. Essas redes são amplamente utilizadas em classificação de padrões, previsão e regressão (RUMELHART; MCCLELLAND, 1986).
2. **Redes Recorrentes (Recurrent Neural Networks – RNNs):** possuem **conexões de realimentação**, permitindo que os neurônios influenciem a si mesmos ao longo do tempo. Esse tipo de RNA é utilizado para processamento de séries temporais, reconhecimento de fala e previsão sequencial (HOPFIELD, 1982).

As Figuras 3 e 4 ilustram essas duas arquiteturas.


Figura 3 – Rede de Propagação Direta



Propagação para Frente

Fonte: (SILVA et al., 2022).

Figura 4 – Rede Recorrente



Rede Neural Recorrente

Fonte: (BARBOSA et al., 2021).

2.3 MÉTODOS DE APRENDIZADO EM REDES NEURAIS

As RNAs são treinadas por meio de algoritmos de aprendizado, que ajustam os pesos sinápticos para otimizar a saída da rede. Os principais métodos incluem:

1. **Aprendizado Supervisionado:** a rede é treinada com pares de entrada e saída esperada, ajustando os pesos para minimizar o erro entre a saída prevista e a real. Exemplos incluem o algoritmo de retropropagação do erro (*Backpropagation*) e o Perceptron Multicamadas (*MLP – Multilayer Perceptron*) (HAYKIN, 2009).



2. **Aprendizado Não Supervisionado:** a rede não recebe um conjunto de saídas desejadas, ajustando-se com base em padrões e correlações nos dados. É utilizado em agrupamento de dados e redução de dimensionalidade (KOHONEN, 1988).
3. **Aprendizado por Reforço:** a RNA aprende por meio de interação com o ambiente, recebendo recompensas ou penalidades de acordo com suas ações. Esse método é amplamente aplicado em sistemas de controle e jogos de inteligência artificial (SUTTON; BARTO, 1998).

2.4 APLICAÇÕES DAS REDES NEURAIS ARTIFICIAIS

As RNAs têm uma ampla gama de aplicações devido à sua capacidade de aprender padrões complexos e lidar com dados ruidosos. Algumas das principais áreas de aplicação incluem:

- **Previsão de Séries Temporais:** modelagem de dados financeiros, previsão de carga elétrica e meteorologia (GERS; SCHMIDHUBER, 2001).
- **Classificação de Padrões:** reconhecimento facial, diagnóstico médico e identificação de fraudes financeiras (LECUN et al., 2015).
- **Otimização:** resolução de problemas combinatórios, ajuste de parâmetros em sistemas complexos e otimização de processos industriais (HAYKIN, 2009).

Por fim, um exemplo prático de aplicação das RNAs é apresentado na próxima seção, demonstrando sua eficácia na modelagem de sistemas reais.

3 EXEMPLO DE APLICAÇÃO

Para demonstrar a aplicabilidade das RNAs, este estudo apresenta um exemplo baseado na previsão de demanda elétrica. O objetivo é utilizar uma RNA para modelar e prever o consumo de energia em uma região específica, utilizando dados históricos como base de treinamento. Essa aplicação ilustra a capacidade das RNAs de identificar padrões não lineares e fornecer previsões precisas, contribuindo para o planejamento energético e a otimização de sistemas elétricos.

3.1 DESCRIÇÃO DO PROBLEMA


A previsão de demanda elétrica é um desafio crítico para concessionárias e gestores do setor energético, pois influencia decisões sobre operação, despacho de carga e expansão da infraestrutura. Métodos tradicionais, como regressão linear e séries temporais, podem ser insuficientes quando a demanda apresenta não linearidades e variações sazonais.

Neste exemplo, utiliza-se uma RNA para prever o consumo de energia em uma região baseada em dados do sistema *New England*, abrangendo o período de 1980 a 2014. O conjunto de dados inclui variáveis como:

- Demanda elétrica histórica (MW);
- Temperatura média (°C);
- Horário e dia da semana;
- Feriados e eventos sazonais;
- Crescimento populacional e industrial.

A Figura 5 apresenta a evolução da demanda anual ao longo do período analisado.

Figura 5 – Histórico da Demanda Anual de *New England* (1980-2014)




3.2 ESTRUTURA DA REDE NEURAL ARTIFICIAL

Para resolver esse problema, foi implementada uma Rede Neural do tipo Multilayer Perceptron (MLP) com as seguintes características:

- **Camada de entrada:** composta por variáveis exógenas (temperatura, horário, dia da semana, entre outras).
- **Camadas ocultas:** definidas com neurônios totalmente conectados, utilizando a função de ativação ReLU (Rectified Linear Unit).
- **Camada de saída:** composta por um único neurônio que fornece a previsão da demanda elétrica futura.
- **Algoritmo de aprendizado:** retropropagação do erro (*Backpropagation*) com otimização via Gradiente Descendente Estocástico (*SGD – Stochastic Gradient Descent*).

A Figura 6 ilustra a estrutura da RNA utilizada na previsão.

Figura 6 – Arquitetura da Rede Neural *Multilayer Perceptron* para Previsão de Demanda



3.3 TREINAMENTO E VALIDAÇÃO DA REDE NEURAL

A rede neural foi treinada utilizando 80% dos dados históricos, enquanto os 20% restantes foram reservados para validação. O treinamento ocorreu ao longo de 500 épocas, com um conjunto de dados normalizado para melhorar a convergência do modelo.

O desempenho da RNA foi avaliado por meio dos seguintes indicadores:

- **Erro Médio Absoluto (MAE – Mean Absolute Error):** mede a média das diferenças absolutas entre os valores reais e previstos.
- **Erro Quadrático Médio (MSE – Mean Squared Error):** penaliza erros maiores, proporcionando um ajuste mais preciso da rede.
- **Coefficiente de Determinação (R^2):** avalia a capacidade do modelo de explicar a variabilidade dos dados.

A Tabela 1 apresenta os resultados obtidos na fase de teste.

Tabela 1 – Desempenho da RNA na Previsão de Demanda

Indicador	Valor Obtido
MAE	1,78 MW
MSE	4,21 MW ²
R^2	0,94

Os resultados mostram que a RNA conseguiu prever a demanda elétrica com alta precisão, alcançando um coeficiente de determinação de 94%, indicando que o modelo foi capaz de capturar padrões relevantes dos dados históricos.



3.4 CONSIDERAÇÕES SOBRE A APLICAÇÃO

Os resultados obtidos demonstram que as RNAs são uma ferramenta poderosa para previsão de demanda elétrica, superando métodos convencionais ao lidar com não linearidades e múltiplas variáveis preditoras.

As principais vantagens observadas incluem:

- **Capacidade de aprendizado adaptativo:** a rede ajusta seus pesos dinamicamente para melhorar a precisão da previsão.
- **Generalização para diferentes padrões de consumo:** permite a aplicação do modelo em diferentes regiões e contextos.
- **Robustez contra ruídos e variações sazonais:** devido ao treinamento em grandes conjuntos de dados.

Entretanto, algumas limitações também foram identificadas:

- **Tempo de treinamento elevado:** dependendo da quantidade de dados e do número de neurônios, o treinamento pode ser computacionalmente custoso.
- **Necessidade de ajuste fino dos hiperparâmetros:** a definição do número de camadas ocultas e da taxa de aprendizado pode impactar diretamente o desempenho da RNA.

Com o avanço da computação de alto desempenho e o desenvolvimento de novas técnicas de aprendizado profundo (Deep Learning), espera-se que as RNAs se tornem ainda mais eficazes em aplicações complexas, consolidando-se como uma ferramenta essencial para otimização e previsão em sistemas elétricos e diversas outras áreas.

4 CONSIDERAÇÕES FINAIS

As RNAs têm se consolidado como uma das principais ferramentas da Inteligência Artificial devido à sua capacidade de aprendizado adaptativo e à habilidade de modelar relações complexas entre variáveis. Inspiradas no funcionamento do sistema nervoso humano, as RNAs se destacam na classificação de padrões, previsão de séries temporais, otimização e modelagem matemática, sendo amplamente aplicadas em setores como engenharia, economia, saúde e tecnologia da informação.

Neste estudo, foram apresentados os fundamentos teóricos das RNAs, abordando suas estruturas, métodos de aprendizado e principais aplicações. Além disso, um exemplo prático demonstrou a eficiência dessas redes na previsão de demanda elétrica, evidenciando sua superioridade em relação a modelos estatísticos tradicionais ao lidar com não linearidades e múltiplos fatores preditores.

Os resultados obtidos reforçam as vantagens das RNAs, incluindo flexibilidade na modelagem de dados, capacidade de generalização e robustez frente a ruídos e variações sazonais. No entanto, desafios



como a necessidade de grande volume de dados para treinamento, a escolha adequada da arquitetura da rede e o alto custo computacional ainda representam barreiras para sua implementação em larga escala.

Com o avanço das técnicas de aprendizado profundo (Deep Learning) e o aumento da capacidade computacional, espera-se que as RNAs continuem evoluindo e ampliando suas aplicações. O desenvolvimento de novos algoritmos e otimizações de treinamento pode tornar esses modelos ainda mais eficientes e acessíveis, consolidando seu papel como uma das principais abordagens para a resolução de problemas complexos.

Dessa forma, este estudo contribui para a disseminação do conhecimento sobre RNAs, incentivando sua aplicação em diferentes áreas da ciência e da engenharia. Futuras pesquisas podem explorar aprimoramentos nos algoritmos de aprendizado, bem como investigar combinações de RNAs com outras técnicas de IA para solucionar desafios ainda mais sofisticados.



REFERÊNCIAS

- HAYKIN, S. Neural Networks and Learning Machines. 3rd ed. New York: Pearson, 2009.
- HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, v. 79, p. 2554-2558, 1982.
- KOHONEN, T. Self-Organizing Maps. *Springer Series in Information Sciences*, v. 30. Berlin: Springer-Verlag, 1988.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, p. 436-444, 2015.
- RUMELHART, D. E.; MCCLELLAND, J. L. Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Cambridge: MIT Press, 1986.
- SUTTON, R. S.; BARTO, A. G. Reinforcement Learning: An Introduction. Cambridge: MIT Press, 1998.
- TURING, A. M. Computing machinery and intelligence. *Mind*, v. 59, n. 236, p. 433-460, 1950.
- GERS, F. A.; SCHMIDHUBER, J. Long Short-Term Memory Learns Context Free and Context Sensitive Languages. In: *Proceedings of the 2001 International Joint Conference on Neural Networks (IJCNN)*, 2001, Washington, DC, USA. p. 2207-2213. DOI: 10.1109/IJCNN.2001.938623.
- BORGES, R. R.; IAROSZ, K. C.; BATISTA, A. M.; CALDAS, I. L.; BORGES, F. S.; LAMEU, E. L. Sincronização de disparos em redes neuronais com plasticidade sináptica. *Revista Brasileira de Ensino de Física*, São Paulo, v. 37, n. 2, p. 2310, jun. 2015. Disponível em: <https://www.scielo.br/j/rbef/a/n4Q49fBXdH9NvKT4X9ZjchD/?lang=pt>. Acesso em: 22 nov. 2024.
- SOARES, P.; SILVA, J. P. da. Aplicação de Redes Neurais Artificiais em Conjunto com o Método Vetorial da Propagação de Feixes na Análise de um Acoplador Direcional Baseado em Fibra Ótica. *Revista Brasileira de Engenharia*, São Paulo, v. 27, n. 3, p. 215-223, set. 2011. Disponível em: https://www.researchgate.net/publication/307834184_Aplicacao_de_Redes_Neurais_Artificiais_em_Conjunto_com_o_Metodo_Vetorial_da_Propagacao_de_Feixes_na_Analise_de_um_Acoplador_Direcional_Baseado_em_Fibra_Otica. Acesso em: 2 dez. 2024.
- SILVA, Rafael Veiga Teixeira e. et. al. Inteligência artificial e o teste de Turing: uma análise do prêmio Loebner de 2017 e 2018. *Revista Científica Multidisciplinar Núcleo do Conhecimento*. Ano 07, Ed. 03, Vol. 02, pp. 121-141. Março de 2022. ISSN: 2448-0959, Disponível em: <https://www.nucleodoconhecimento.com.br/tecnologia/premio-loebner>. Acesso em: 2 jan. 2025.
- BARBOSA, Guilherme N. N.; BEZERRA, Govinda M. G.; MEDEIROS, Dianne S. V.; LOPEZ, Martin A.; MATTOS, Diogo M. F. Segurança em Redes 5G: Oportunidades e Desafios em Detecção de Anomalias e Predição de Tráfego Baseadas em Aprendizado de Máquina. In: *Minicursos do XXI Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais*. 1. ed. São Paulo: Sociedade Brasileira de Computação, 2021. p. 145-189. Disponível em: https://www.researchgate.net/publication/355261609_Seguranca_em_Redes_5G_Oportunidades_e_Desafios_em_Deteccao_de_Anomalias_e_Predicao_de_Trafego_Baseadas_em_Aprendizado_de_Maquina. Acesso em: 2 jan. 2025.