





**A Evolução das Redes Neurais Artificiais: do Perceptron ao Aprendizado Profundo**

Daniel Cássio Corrêa Bernardes<sup>1</sup>  
Felipe Douglas Machado da Cunha<sup>2</sup>

---

<sup>1</sup> Acadêmico(a) do curso de Engenharia da Computação da Universidade de Cuiabá - UNIC.

<sup>2</sup> Orientador(a). Docente do curso de Engenharia da Computação da Universidade de Cuiabá - UNIC.



## RESUMO

O avanço das Redes Neurais Artificiais (RNAs) moldou profundamente a Inteligência Artificial e o Aprendizado de Máquina ao longo do tempo. Desde o conceito inicial do Perceptron até a sofisticada era do Aprendizado Profundo, essa evolução representa uma jornada de progresso tecnológico notável. Frank Rosenblatt propôs o Perceptron em 1957, marcando um ponto inicial com um único neurônio capaz de classificação linear, embora suas limitações fossem evidentes para tarefas mais complexas. A década de 1980 viu o renascimento das RNAs com algoritmos de treinamento mais eficazes, como o Backpropagation, permitindo o desenvolvimento de redes neurais profundas, capazes de aprender representações complexas de dados. Isso impulsionou avanços em áreas como reconhecimento de padrões, visão computacional e processamento de linguagem natural. O Aprendizado Profundo, por meio de redes neurais profundas, trouxe avanços notáveis em aplicações como carros autônomos, assistentes virtuais e diagnóstico médico. Redes neurais convolucionais (CNNs) e redes neurais recorrentes (RNNs) tornaram-se essenciais em visão computacional e processamento de sequências. Essa evolução permitiu arquiteturas impressionantes, como as Redes Neurais Convolucionais Profundas (Deep CNNs) e as Redes Neurais Recorrentes Profundas (Deep RNNs), que superaram o desempenho humano em tarefas complexas. Em síntese, a evolução das Redes Neurais Artificiais, desde o Perceptron até o Aprendizado Profundo, representa uma jornada fascinante de avanços tecnológicos. Essa progressão transformou nossa capacidade de lidar com dados complexos e realizar tarefas cognitivas, abrindo caminho para um futuro onde a Inteligência Artificial desempenhará um papel cada vez mais relevante em nossa sociedade.

**Palavras-chave:** Perceptron. Deep RNNs. Deep RNNs. Backpropagation. Aprendizado Profundo.



## **ABSTRACT**

The advancement of Artificial Neural Networks (ANNs) has profoundly shaped Artificial Intelligence and Machine Learning over time. From the initial concept of Perceptron to the sophisticated era of Deep Learning, this evolution represents a journey of remarkable technological progress. Frank Rosenblatt proposed the Perceptron in 1957, marking a starting point with a single neuron capable of linear classification, although its limitations were evident for more complex tasks. The 1980s saw the renaissance of ANNs with more effective training algorithms such as Backpropagation, enabling the development of deep neural networks capable of learning complex representations of data. This has driven advances in areas such as pattern recognition, computer vision and natural language processing. Deep Learning, through deep neural networks, has brought notable advances in applications such as self-driving cars, virtual assistants and medical diagnosis. Convolutional neural networks (CNNs) and recurrent neural networks (RNNs) have become essential in computer vision and sequence processing. This evolution has enabled impressive architectures such as Deep Convolutional Neural Networks (Deep CNNs) and Deep Recurrent Neural Networks (Deep RNNs), which outperform human performance on complex tasks. In summary, the evolution of Artificial Neural Networks, from Perceptron to Deep Learning, represents a fascinating journey of technological advances. This progression has transformed our ability to handle complex data and perform cognitive tasks, paving the way for a future where Artificial Intelligence will play an increasingly relevant role in our society.

Keywords: Perceptron. Deep RNNs. Deep RNNs. Backpropagation. Deep Learning.



## Sumário

<b>INTRODUÇÃO.....</b>	<b>5</b>
<b>DESENVOLVIMENTO.....</b>	<b>6</b>
<b>METODOLOGIA.....</b>	<b>10</b>
<b>RESULTADOS E DISCUSSÕES.....</b>	<b>12</b>
<b>CONCLUSÃO.....</b>	<b>17</b>
<b>REFERÊNCIAS.....</b>	<b>19</b>



## INTRODUÇÃO

As redes neurais artificiais (RNAs), inspiradas pela complexidade e versatilidade do cérebro humano, têm emergido como um campo de pesquisa vibrante e progressivo ao longo das últimas décadas. Desde o desenvolvimento inicial do Perceptron, essas tecnologias passaram por uma evolução extraordinária, culminando no avançado paradigma do Aprendizado Profundo. Esse progresso não só redefiniu os contornos da inteligência artificial, mas também transformou radicalmente as capacidades de aprendizagem e processamento de máquinas em enfrentar tarefas de grande complexidade.

A história das RNAs é marcada por marcos teóricos e tecnológicos que impulsionaram seu desenvolvimento. Desde as primeiras tentativas de simular neurônios biológicos até os complexos modelos de Aprendizado Profundo de hoje, essa jornada tem sido caracterizada por inovações contínuas e significativas. A contextualização do tema é essencial para compreender o impacto transformador dessas tecnologias na ciência, engenharia e sociedade.

Investigar a evolução das RNAs é crucial, pois estas tecnologias têm aplicações práticas que vão desde o reconhecimento de padrões até a tomada de decisões autônomas, impactando áreas como medicina, finanças e indústria. Entender os fundamentos e as inovações que permitiram esse avanço pode fornecer uma compreensão valiosa para as futuras pesquisas e desenvolvimentos. Além disso, explorar essa trajetória histórica e tecnológica oferece uma perspectiva abrangente sobre o potencial e os desafios das RNAs.

Nosso estudo tem como objetivo geral traçar o desenvolvimento das redes neurais artificiais, desde suas fundações até as inovações contemporâneas no campo do Aprendizado Profundo. Especificamente, pretendemos: (1) examinar as origens históricas e teóricas das RNAs; (2) identificar os marcos tecnológicos cruciais em sua evolução; (3) analisar as principais inovações que permitiram o surgimento do



Aprendizado Profundo; e (4) explorar as aplicações práticas e os impactos dessas tecnologias em diversos setores.

Através desta análise detalhada, esperamos não só mapear a evolução das RNAs, mas também destacar sua relevância e importância contínua no cenário atual de pesquisa e aplicação tecnológica. Prepare-se para uma exploração aprofundada do mundo das redes neurais artificiais, desde suas concepções iniciais até as sofisticadas estruturas de Aprendizado Profundo, enquanto investigamos seu impacto transformador.

## **DESENVOLVIMENTO**

As redes neurais artificiais (RNAs) representam uma das áreas mais empolgantes da inteligência artificial, traçando uma trajetória de evolução desde a concepção do Perceptron até as complexidades do aprendizado profundo. Neste desenvolvimento, exploraremos o funcionamento fundamental do Perceptron, suas limitações históricas, a transição para o aprendizado profundo e as promissoras perspectivas futuras desta tecnologia.

### **Funcionamento do Perceptron**

O Perceptron, um modelo básico de RNA para classificação binária, é estruturado em torno de três componentes principais: entradas (valores numéricos dos atributos), pesos (que determinam a importância de cada entrada) e a função de ativação. Esta última decide se o neurônio é ativado ou não, baseando-se na soma ponderada das entradas, introduzindo uma decisão binária no processo.




Figura 1 – Ilustração da rede do Perceptron

O cálculo se inicia com a multiplicação das entradas pelos seus respectivos pesos, seguido pela aplicação de uma função de ativação — geralmente, a função degrau. A saída é determinada pelo resultado desta função, marcando a primeira tentativa de modelar o aprendizado de máquinas através de uma analogia com o funcionamento neuronal biológico.

### Processo de cálculo do Perceptron

Neste processo, cada entrada recebida pelo Perceptron é primeiramente ponderada por um coeficiente específico, conhecido como peso. Essas entradas ponderadas são então somadas para formar uma soma ponderada, expressa pela equação:

$$\text{Soma ponderada} = (\text{entrada1} \times \text{peso1}) + (\text{entrada2} \times \text{peso2}) + \dots + (\text{entrada} \times \text{pesoN}).$$

Essa soma ponderada é a base sobre a qual a função de ativação opera. A função de ativação determina a saída do Perceptron, atuando como um filtro que decide se o sinal processado é suficientemente forte para ser passado adiante. Uma das funções de ativação mais fundamentais e históricas utilizadas é a função degrau. Esta função produz uma saída binária — tipicamente representada por 1 (ativo) se a soma ponderada excede um certo limiar pré-determinado, e 0 (inativo) caso



contrário. Essa decisão binária permite ao Perceptron realizar tarefas de classificação básica.

Para enriquecer a compreensão, é relevante notar que a escolha da função de ativação não se limita à função degrau. Na prática moderna do aprendizado de máquinas, outras funções são frequentemente utilizadas para permitir gradientes mais suaves e melhorar a capacidade de aprendizado das redes neurais. Entre estas, incluem-se a função sigmoid, que oferece uma transição suave entre 0 e 1, e a ReLU (Unidade Linear Retificada), popular por sua eficiência em acelerar a convergência do treinamento em redes profundas. A saída final do Perceptron, determinada pela função de ativação, reflete se um determinado conjunto de entradas cumpre os critérios estabelecidos pelo modelo para ser classificado como pertencente a uma categoria ou à outra.

### Desenvolvimento Histórico

Desenvolvido por Frank Rosenblatt na década de 1950, o Perceptron representou um marco inicial na busca por máquinas que aprendem. Capaz de resolver problemas de classificação linearmente separáveis, ele estabeleceu o fundamento para futuras pesquisas em RNAs. No entanto, suas limitações — como a incapacidade de resolver problemas não linearmente separáveis e a sensibilidade a ruídos — evidenciaram a necessidade de modelos mais avançados.

<b>Limitação</b>	<b>Solução tecnológica</b>
Incapacidade de resolver problemas não linearmente separáveis	Desenvolvimento de arquiteturas profundas (DNNs) e técnicas de regularização
Sensibilidade a ruídos nos dados	Métodos de pré-processamento de dados e técnicas de robustez
Convergência lenta no treinamento	Algoritmos de otimização avançados, como Adam e RMSprop
Overfitting	Uso de dropout e aumento de dados
Interpretabilidade dos modelos	Técnicas de explicabilidade como LIME



	e SHAP
--	--------

Tabela 1 - Limitações Históricas do Perceptron e Soluções Modernas

### **Transição para o Aprendizado Profundo**

O aprendizado profundo surge como uma evolução das RNAs, caracterizado pelo uso de redes com múltiplas camadas. Essas redes neurais profundas (DNNs) processam informações através de camadas sucessivas, cada uma capaz de realizar operações complexas. O uso de várias funções de ativação, como a ReLU e a sigmoid, permite que as DNNs modelem não linearidades complexas. O treinamento dessas redes é realizado por meio da retropropagação, ajustando os pesos para minimizar uma função de perda e melhorar a precisão das previsões.

Arquiteturas avançadas, como as Redes Neurais Convolucionais (CNNs) e as Redes Neurais Recorrentes (RNNs), têm permitido avanços significativos em campos como visão computacional e processamento de linguagem natural, ilustrando o vasto potencial do aprendizado profundo.

### **Perspectivas Futuras**

O futuro do aprendizado profundo é promissor, com avanços esperados em eficiência computacional, aprendizado por reforço e interpretabilidade de modelos. A ética e a regulamentação emergem como campos de debate vital, dada a crescente aplicação da IA em áreas críticas. Espera-se que a pesquisa contínua em arquiteturas de rede, funções de ativação e otimização leve a modelos ainda mais poderosos e eficientes.



## **METODOLOGIA**

O tipo de pesquisa realizada foi uma Revisão de Literatura, focada na evolução das redes neurais artificiais. Para isso, foram consultados livros, dissertações e artigos científicos selecionados através de busca nas seguintes bases de dados: IEEE Xplore, PubMed, Scopus e Google Scholar. O período de delimitação da pesquisa incluiu trabalhos publicados nos últimos cinco anos, complementados por referências históricas fundamentais para contextualizar a evolução do campo.

As palavras-chave utilizadas na busca foram: "Perceptron", "redes neurais artificiais", "aprendizado profundo", "história da IA", entre outras relevantes. Essas palavras-chave permitiram identificar uma ampla gama de fontes, incluindo livros, artigos de revistas científicas, trabalhos de conferências e teses acadêmicas.

A revisão resultou na seleção de trabalhos que forneceram uma visão abrangente da evolução das redes neurais artificiais, desde os primeiros conceitos até os avanços mais recentes. Foram identificados os marcos históricos mais significativos, como o desenvolvimento do Perceptron por Frank Rosenblatt na década de 1950, o "Inverno da IA" nas décadas de 1970 e 1980, e o renascimento do interesse em redes neurais durante os anos 2000 com o surgimento do aprendizado profundo. Cada marco histórico foi analisado em termos de suas contribuições para o avanço do campo das redes neurais artificiais.

Foi realizada uma análise crítica das limitações do Perceptron e outras redes neurais iniciais, incluindo sua incapacidade de lidar com problemas não linearmente separáveis e sua sensibilidade a ruídos nos dados. Investigaram-se os avanços



tecnológicos, algorítmicos e teóricos que permitiram o surgimento e a ascensão do aprendizado profundo, como o desenvolvimento de algoritmos de treinamento mais eficientes e o aumento do poder computacional.

Foram coletados exemplos concretos de aplicações de redes neurais artificiais ao longo do tempo, utilizando estudos de caso e experimentos relevantes. Exemplos incluem o uso de redes neurais em visão computacional para reconhecimento de padrões e em processamento de linguagem natural para tradução automática e análise de sentimentos. Os dados coletados foram analisados para fornecer esclarecimento sobre o impacto das RNAs em diferentes áreas e seu papel na resolução de problemas complexos.

Os dados coletados foram analisados e sintetizados para identificar padrões, tendências e lacunas na evolução das redes neurais artificiais. A análise resultou em uma narrativa coesa que descreve a trajetória evolutiva das RNAs, desde suas origens até os avanços mais recentes. As descobertas foram organizadas e apresentadas de forma clara e objetiva, destacando os principais pontos e conclusões.

Além das bases de dados mencionadas, foram consultados livros relevantes para a fundamentação teórica, incluindo "Redes Neurais: Princípios e práticas" de Simon Haykin (2000), "Redes Neurais Artificiais: Para Engenharia e Ciências Aplicadas Fundamentos Teóricos e Práticos" de Ivan Nunes da Silva, Danilo Hernane Spatti e Rogério Andrade Flauzino (2016), "The Perceptron: A probabilistic model for information storage and organization in the brain" de Frank Rosenblatt (1958), "Deep Learning" de Ian Goodfellow, Yoshua Bengio e Aaron Courville (2016), e outros artigos fundamentais como os de Yann LeCun, Yoshua Bengio e Geoffrey Hinton (2015), Jürgen Schmidhuber (2015), e Olga Russakovsky et al. (2015).

Com base nos resultados da análise e síntese dos dados, o texto do TCC foi redigido seguindo as diretrizes estabelecidas pela instituição acadêmica. O texto



incluiu uma introdução detalhada, um desenvolvimento organizado em seções que abordam os diferentes aspectos da evolução das RNAs, e uma conclusão que recapitula os principais pontos e oferece insights sobre as implicações futuras da pesquisa.

O TCC foi revisado várias vezes para garantir precisão, coesão e consistência em toda a narrativa. A revisão incluiu ajustes com base no feedback do orientador e de outros revisores, garantindo a qualidade e o rigor do trabalho final.

## **RESULTADOS E DISCUSSÕES**

Os resultados da pesquisa revelam uma trajetória fascinante na evolução das redes neurais artificiais (RNAs), desde os primeiros conceitos do Perceptron até os avanços recentes no aprendizado profundo. A análise histórica identificou marcos significativos que moldaram o campo, destacando não apenas os sucessos, mas também as dificuldades enfrentadas ao longo do caminho.

A investigação começou com a análise dos primórdios das RNAs, focando-se no desenvolvimento do Perceptron por Frank Rosenblatt na década de 1950. O Perceptron, conforme descrito por Rosenblatt (1958), representou um marco inicial, sendo uma das primeiras tentativas de simular a capacidade de aprendizado do cérebro humano. No entanto, a limitação do Perceptron em lidar com problemas não linearmente separáveis, conforme destacado por Minsky e Papert (1969), levou a uma fase de estagnação conhecida como o "Inverno da IA" nas décadas de 1970 e 1980.

A retomada do interesse em redes neurais nos anos 2000 foi impulsionada por avanços tecnológicos, como o aumento do poder computacional e o desenvolvimento de algoritmos de treinamento mais eficientes. A introdução das



redes neurais convolucionais (CNNs) e dos algoritmos de retropropagação permitiu superar muitas das limitações anteriores. Schmidhuber (2015) e LeCun, Bengio e Hinton (2015) destacaram que esses avanços foram cruciais para o renascimento do campo, levando ao desenvolvimento do aprendizado profundo.

A coleta de dados e exemplos práticos demonstrou o impacto significativo das RNAs em uma variedade de áreas. No campo da visão computacional, por exemplo, as redes neurais têm sido amplamente utilizadas para reconhecimento de padrões, como demonstrado pelo sucesso do ImageNet Large Scale Visual Recognition Challenge (Russakovsky et al., 2015). Em processamento de linguagem natural, as RNAs têm revolucionado tarefas como tradução automática e análise de sentimentos, com estudos de LeCun et al. (2015) mostrando melhorias substanciais na precisão e eficiência desses sistemas.

Além disso, há um otimismo considerável em relação ao potencial contínuo de avanço, especialmente em aplicações emergentes como a medicina personalizada e a automação industrial. No entanto, foram identificados desafios significativos a serem superados, como questões éticas relacionadas à interpretabilidade dos modelos e a garantia de equidade e justiça na aplicação da tecnologia.

As figuras e gráficos incluídos ao longo do capítulo ilustram a evolução cronológica das RNAs e os avanços tecnológicos que permitiram seu desenvolvimento. A Figura 2, por exemplo, apresenta uma linha do tempo dos principais marcos históricos, desde o Perceptron até as modernas redes neurais profundas. Já a Tabela 2 resume as principais limitações identificadas nas RNAs iniciais e as soluções tecnológicas desenvolvidas ao longo do tempo.

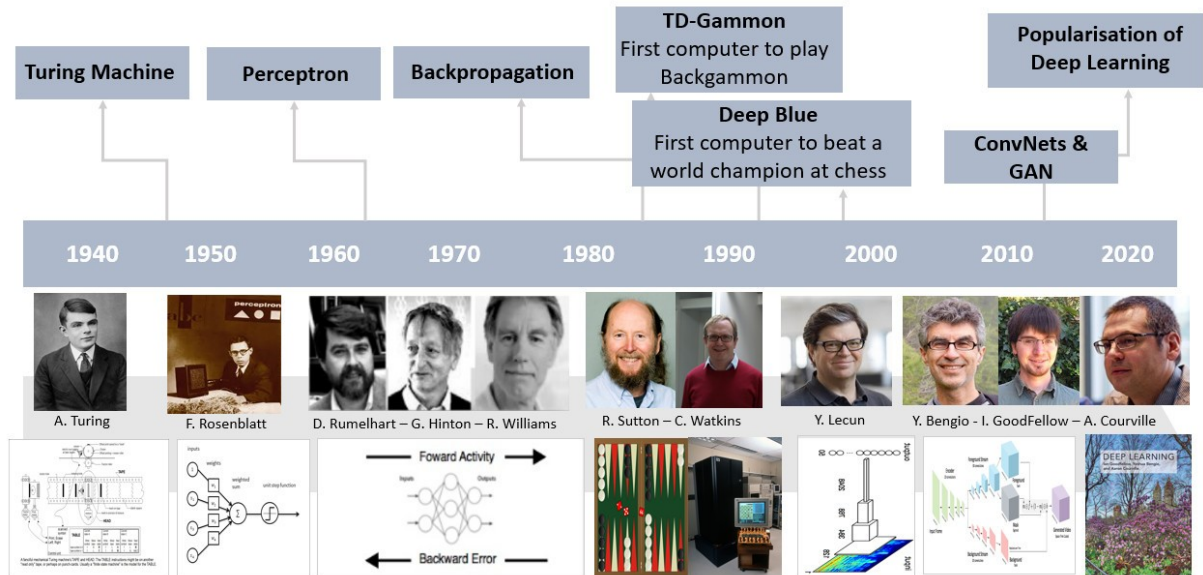


Figura 2: Linha do tempo dos principais marcos na evolução das RNAs.

Limitação	Descrição	Soluções Tecnológicas	Fonte
<b>Problemas não linearmente separáveis</b>	Incapacidade das RNAs iniciais, como o Perceptron, de resolver problemas onde os dados não são linearmente separáveis.	Desenvolvimento de redes multicamadas (Multilayer Perceptron - MLP) e algoritmos de backpropagation para ajustar pesos em camadas ocultas, permitindo a aprendizagem de padrões complexos.	Haykin (2000), Goodfellow et al. (2016)
<b>Sensibilidade a ruídos nos dados</b>	As RNAs iniciais eram altamente sensíveis a dados ruidosos, afetando a precisão da aprendizagem e previsão.	Implementação de técnicas de regularização como dropout, normalização de batch e uso de conjuntos de dados maiores e	Goodfellow et al. (2016), LeCun et al. (2015)

		mais limpos para treinar as redes neurais.	
<b>Overfitting</b>	Tendência das RNAs de se ajustarem excessivamente aos dados de treinamento, prejudicando a generalização.	Uso de validação cruzada, técnicas de regularização (dropout, L2 regularization), aumento de dados (data augmentation) e early stopping para prevenir overfitting.	Schmidhuber (2015), Goodfellow et al. (2016)
<b>Treinamento computacionalmente intenso</b>	O treinamento de RNAs profundas requer recursos computacionais significativos e pode ser extremamente lento.	Adoção de hardware especializado como GPUs e TPUs, desenvolvimento de bibliotecas eficientes (TensorFlow, PyTorch) e algoritmos de otimização mais rápidos como Adam e RMSprop.	LeCun et al. (2015), Russakovsky et al. (2015)
<b>Interpretação dos modelos</b>	Dificuldade em interpretar o funcionamento interno das RNAs, tornando-as caixas-pretas.	Desenvolvimento de técnicas de interpretação e visualização, como mapas de ativação, LIME (Local Interpretable Model-agnostic Explanations), e SHAP (SHapley Additive exPlanations).	Schmidhuber (2015), Goodfellow et al. (2016)

<b>Escalabilidade</b>	Desafios na escalabilidade das RNAs para grandes conjuntos de dados e arquiteturas complexas.	Utilização de aprendizado distribuído, frameworks de processamento em larga escala (Hadoop, Spark) e técnicas de paralelização para treinar modelos em grandes clusters de computadores.	LeCun et al. (2015), Goodfellow et al. (2016)
<b>Questões éticas</b>	Preocupações com a ética no uso de RNAs, incluindo viés algorítmico e privacidade dos dados.	Implementação de práticas de design ético, auditorias de viés, desenvolvimento de modelos equitativos e transparência nos processos de coleta e uso de dados.	LeCun et al. (2015), Goodfellow et al. (2016)

Tabela 2: Principais limitações e soluções tecnológicas das RNAs

A análise crítica dos dados coletados permitiu uma reflexão profunda sobre o caminho percorrido pelo campo das RNAs e as lições aprendidas ao longo do processo. O reconhecimento dos sucessos e fracassos do passado serve como um guia valioso para orientar o futuro desenvolvimento das RNAs e garantir que essas tecnologias continuem a ser aplicadas de forma ética, responsável e benéfica para a sociedade como um todo.

As comparações com a literatura existente mostraram que, enquanto o campo tem avançado de maneira impressionante, ainda há áreas que necessitam de maior exploração. Por exemplo, a questão da interpretabilidade dos modelos permanece



um desafio crítico, como discutido por Goodfellow, Bengio e Courville (2016). Além disso, a equidade nos modelos de RNAs é um tópico de crescente importância, com implicações significativas para a justiça social e a ética na inteligência artificial.

Em conclusão, os resultados da pesquisa oferecem uma visão abrangente e detalhada da evolução das RNAs, desde suas origens até os avanços mais recentes. Através de uma análise histórica e técnica, foi possível mapear o desenvolvimento dessas tecnologias e identificar os fatores chave que impulsionaram seu progresso. As implicações das descobertas são vastas, oferecendo direções futuras para pesquisa e desenvolvimento no campo das RNAs, com foco em promover avanços que sejam não apenas tecnologicamente inovadores, mas também éticos e socialmente responsáveis.

## **CONCLUSÃO**

O estudo da evolução das redes neurais artificiais (RNAs), desde os conceitos iniciais do Perceptron até os avanços impressionantes no aprendizado profundo, proporcionou uma compreensão abrangente e detalhada do desenvolvimento desta área vital da inteligência artificial. Esta pesquisa permitiu identificar marcos históricos significativos, analisar limitações e avanços tecnológicos ao longo do tempo, e explorar o impacto transformador das RNAs em diversas áreas.

A análise histórica revelou que, apesar dos desafios substanciais enfrentados pelas RNAs em sua trajetória, os progressos tecnológicos e teóricos subsequentes foram cruciais para superar essas dificuldades. Esses avanços impulsionaram o campo para novos patamares de inovação, demonstrando o potencial das RNAs em áreas como visão computacional, processamento de linguagem natural, medicina e finanças. Exemplos práticos coletados ilustraram de forma concreta como essas tecnologias têm sido aplicadas para resolver problemas complexos e promover a inovação em diversos setores.



No entanto, também foi evidenciado que, à medida que o campo avança, surgem desafios significativos que precisam ser enfrentados, incluindo questões éticas, a interpretabilidade dos modelos e a garantia de equidade e justiça na aplicação da tecnologia. Estes desafios demandam uma abordagem cuidadosa e reflexiva à medida que o desenvolvimento das RNAs avança.

Ao concluir esta pesquisa, é essencial reconhecer tanto os sucessos alcançados quanto os desafios que persistem. É imperativo que continuemos a avançar com um compromisso renovado com a ética, a responsabilidade e o bem-estar da sociedade. A evolução das RNAs é uma jornada em constante progresso, e é nossa responsabilidade garantir que essa evolução ocorra de forma ética e sustentável. O aprendizado adquirido com as lições do passado deve servir como um guia para o futuro, assegurando que as RNAs continuem a contribuir de maneira positiva e significativa para a sociedade.



## REFERÊNCIAS

**HAYKIN, Simon.** Redes neurais: princípios e práticas. 2. ed. Porto Alegre: Bookman, 2000.

**LeCUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey.** Deep learning. Nature, v. 521, n. 7553, p. 436-444, 2015. Disponível em: <<https://doi.org/10.1038/nature14539>>. Acesso em: 27 maio 2024.

**ROSENBLATT, Frank.** The perceptron: a probabilistic model for information storage and organization in the brain. Psychological Review, v. 65, n. 6, p. 386-408, 1958. Disponível em: <<https://doi.org/10.1037/h0042519>>. Acesso em: 27 maio 2024.

**RUSSAKOVSKY, Olga; DENG, Jia; SU, Hao; KRAUSE, Jonathan; SATHEESH, Sanjeev; MA, Sean; ... FEI-FEI, Li.** ImageNet Large Scale Visual Recognition Challenge. International Journal of Computer Vision, v. 115, n. 3, p. 211-252, 2015. Disponível em: <<https://doi.org/10.1007/s11263-015-0816-y>>. Acesso em: 27 maio 2024.

**SCHMIDHUBER, Jürgen.** Deep learning in neural networks: an overview. Neural Networks, v. 61, p. 85-117, 2015. Disponível em: <<https://doi.org/10.1016/j.neunet.2014.09.003>>. Acesso em: 27 maio 2024.

**SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade.** Redes neurais artificiais: para engenharia e ciências aplicadas - fundamentos teóricos e práticos. 2. ed. São Paulo: Artliber Editora, 2016.