

INTELIGÊNCIA ARTIFICIAL E APRENDIZAGEM POR REFORÇO

ARTIFICIAL INTELLIGENCE AND REINFORCEMENT LEARNING

Rosana Helena NUNES

rosananunes03@gmail.com

Faculdade de Tecnologia de Sorocaba, São Paulo, Brasil

Breno de Jesus Toledo

breno.toledo@fatec.sp.gov.br

Faculdade de Tecnologia de Sorocaba, São Paulo, Brasil

Caio César Corrá Bello

caio.bello@fatec.sp.gov.br

Faculdade de Tecnologia de Sorocaba, São Paulo, Brasil

Gabriel Oliveira de Andrade

gabriel.andrade30@fatec.sp.gov.br

Faculdade de Tecnologia de Sorocaba, São Paulo, Brasil

Gabriel Telo Mariano

gabriel.mariano8@fatec.sp.gov.br

Faculdade de Tecnologia de Sorocaba, São Paulo, Brasil

Ricardo Gomes Marques

ricardo.marques5@fatec.sp.gov.br

Faculdade de Tecnologia de Sorocaba, São Paulo, Brasil

Resumo: Este artigo aborda a inteligência artificial (IA) e a aprendizagem por reforço, explorando seus conceitos fundamentais. É apresentado um breve histórico da IA, desde suas origens até os avanços recentes. São discutidos os conceitos básicos da IA, como neurônios artificiais, redes neurais multicamadas e sua aplicação em diferentes modelos, como Perceptron, MLP, CNN, RNN, LSTM, Autoencoder e GAN. Destaca-se a importância do processamento de informações e da capacidade de tomar decisões em situações não previamente projetadas, características fundamentais da IA. Também é explorada a aplicação da aprendizagem por reforço, uma abordagem que busca ensinar um agente a tomar ações em um ambiente para maximizar uma recompensa. Por meio de uma oficina de leitura, os participantes vivenciaram conceitos como o desafio do tabuleiro, ilustrando a importância dos pesos, valores e otimização na resolução de problemas com IA. A oficina despertou

o interesse dos participantes, incentivando-os a buscar mais conhecimento e explorar as aplicações práticas da IA em diferentes contextos. Esse trabalho oferece uma introdução prática e cativante aos conceitos de IA e aprendizagem por reforço, conectando os leitores aos fundamentos dessas áreas e os inspirando a contribuir para soluções inovadoras.

Palavras-chave: Inteligência artificial; Redes neurais; Aprendizagem por reforço; Oficina de leitura.

Abstract: *This paper addresses artificial intelligence (AI) and reinforcement learning, exploring their fundamental concepts. A brief history of AI is presented, from its origins to recent advancements. The basic concepts of AI are discussed, such as artificial neurons, multilayer neural networks, and their application in different models like Perceptron, MLP, CNN, RNN, LSTM, Autoencoder, and GAN. The importance of information processing and the ability to make decisions in unforeseen situations, which are fundamental characteristics of AI, are highlighted. The application of reinforcement learning is also explored, an approach that aims to teach an agent to take actions in an environment to maximize a reward. Through a reading workshop, participants experienced concepts such as the chessboard challenge, illustrating the importance of weights, values, and optimization in problem-solving using AI. The workshop sparked the participants' interest, encouraging them to seek further knowledge and explore the practical applications of AI in different contexts. This paper provides a practical and engaging introduction to the concepts of AI and reinforcement learning, connecting readers to the foundations of these fields and inspiring them to contribute to innovative solutions.*

Keywords: Artificial intelligence; Neural networks; Reinforcement learning; Reading workshop.

INTRODUÇÃO

A inteligência artificial (IA) tem sido um campo de pesquisa e desenvolvimento que tem avançado rapidamente nos últimos anos. Entre as diversas abordagens utilizadas na IA, destaca-se a aprendizagem por reforço, que busca ensinar um agente a tomar ações em um ambiente para maximizar uma recompensa. Neste trabalho, exploraremos os conceitos fundamentais da inteligência artificial e da aprendizagem por reforço.

Durante a oficina de leitura que apresentamos, tivemos a oportunidade de proporcionar uma experiência prática e envolvente aos participantes, permitindo que eles vivenciassem os conceitos discutidos. Um dos destaques dessa oficina foi o desafio do tabuleiro, no qual os participantes foram desafiados a resolver uma equação simples (binária) através da atribuição de pesos e valores adequados. Essa atividade permitiu que eles compreendessem a importância dos pesos, valores e otimização na resolução de problemas utilizando a inteligência artificial.

A oficina despertou o interesse e a curiosidade dos participantes, à medida que eles se envolveram ativamente na resolução do desafio do tabuleiro. Ao enfrentarem o desafio, os participantes foram incentivados a buscar mais conhecimento e explorar as aplicações práticas da IA em diferentes contextos. A experiência proporcionada pela oficina de leitura conectou os participantes aos fundamentos da IA e da aprendizagem por reforço, oferecendo uma base sólida para sua compreensão desses conceitos.

Ao compreenderem a importância da IA e da aprendizagem por reforço, os participantes foram inspirados a contribuir para o desenvolvimento de soluções inovadoras. A oficina de leitura serviu como ponto de partida para que eles pudessem explorar mais a fundo esses campos de estudo e buscar maneiras de aplicar seus conhecimentos na resolução de problemas do mundo real.

No decorrer deste trabalho, apresentaremos os conceitos essenciais da inteligência artificial e do aprendizado por reforço, oferecendo uma visão abrangente dessas áreas. Através da experiência compartilhada na oficina de leitura, buscamos fornecer uma introdução prática e cativante aos participantes e a todos os leitores interessados nesses temas.

INTELIGÊNCIA ARTIFICIAL: UM BREVE HISTÓRICO

Durante anos, a programação se restringiu ao modelo sequencial, e, posteriormente, devido à necessidade do mercado, ao modelo padrão de orientação a objeto. Todavia, apesar de uma grande evolução, ambos padrões possuem limitações que impediam o avanço da tecnologia, como não ser capaz de tomar uma decisão ao analisar uma situação que não foi previamente projetada para

aquela lógica, não ser capaz de analisar uma imagem ou até mesmo algo mais simples, ou criar uma conversa de texto em uma linguagem natural.

Em 1956, em uma pesquisa de verão do colégio Dartmouth¹², foi constituída a ideia de que um programa deveria pensar, e com isso, iniciaram-se estudos sobre o cérebro humano e o seu funcionamento, do macro ao micro (neurônios), com sua rede de comunicações, e surgiu assim um novo ponto na história da ciência da computação.

Nos anos seguintes, faculdades como o MIT (Massachusetts Institute of Technology), Stanford e outras começaram a desenvolver pesquisas também na área, apresentando um avanço promissor; em 1965, o MIT criou o primeiro chatbot (ELIZA), capaz de gerar conversas, ainda muito dispersas e sem contexto, mas, considerando a época e a então capacidade de processamento, foi um grande avanço tecnológico.

Processamento sempre foi a chave para a inteligência artificial, pois diferentemente de quando há uma lógica já definida no programa, como acontece em programas sequenciais, a inteligência artificial precisa processar diversas informações de entrada, as possibilidades de saída, buscar de alguma forma no passado suas experiências e, por fim, entregar um resultado de maneira rápida e eficiente.

Assim, os computadores da época não suportavam tantos cálculos, e durante os anos 70 e 80, a área perdeu muitos cientistas, visto que não havia suficiente capacidade de processamento para a realização dos testes ou para provar suas teorias. Apesar disso, pesquisas continuaram sendo desenvolvidas. Em 2009, houve uma revolução na tecnologia, quando a NVIDIA desenvolveu uma placa de vídeo focada em resolver cálculos matriciais, o que tornou possível colocar em prática diversos estudos e retomar as pesquisas em tecnologias de Inteligência artificial, *machine learning* e todas suas ramificações.

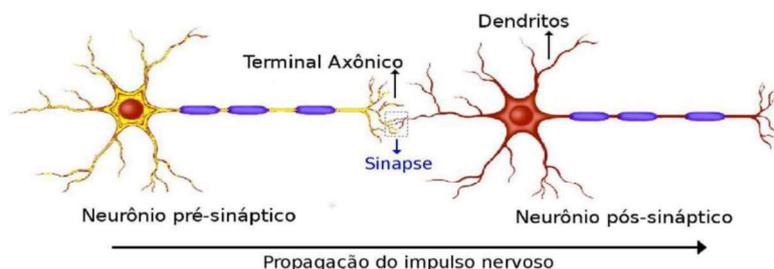
Conceitos

O neurônio artificial foi desenvolvido baseado nos neurônios humanos¹³, mais especificamente com enfoque nas conexões neurais, conhecidas como **Sinapse** (Figura 1): evento no qual há envio de informações do terminal axônico de uma célula nervosa para os dendritos da célula seguinte, por meio de hormônios.

12 Disponível em: <https://opencadd.com.br/como-surgiu-a-inteligencia-artificial/#:~:text=Tudo%20come%C3%A7ou%20em%201956%20com,de%20%E2%80%99Censinar%E2%80%9D%20as%20m%C3%A1quinas>.

13 Disponível em: https://www.gsigma.ufsc.br/~popov/aulas/rna/neuronio_artificial/index.html.

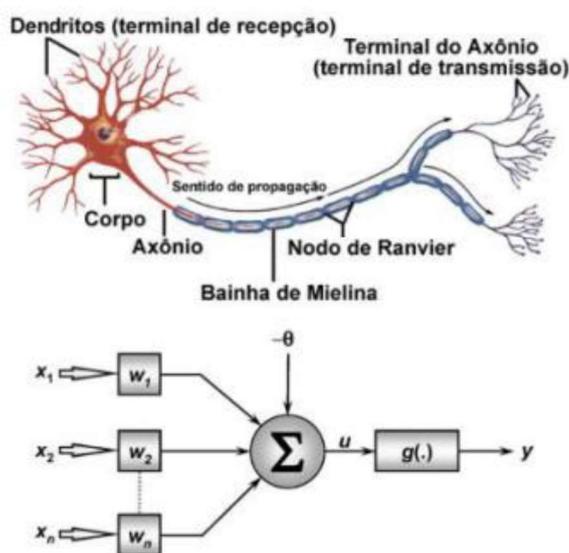
FIGURA 1 - Conexão sináptica



Fonte: <https://educar321.blogspot.com/2022/06/criacao-de-um-habito-no-cerebro.html>

Para a biologia, os detritos são terminais de recepção de um neurônio, mas no tema de redes artificiais são denominadas "entradas". É necessário que as entradas de um neurônio artificial sejam números, visto que os computadores trabalham com esse tipo de dado, mais especificamente com o modelo binário, utilizando os números 0 e 1 (HELENO, 2022). Desta maneira, quando uma I.A. trabalha com áudio, vídeo, fotos, reconhecimento facial ou outras tecnologias, suas entradas são sempre convertidas em números para tornar possível o processamento pelos neurônios.

FIGURA 2 - Comparação entre um neurônio real (acima) e um artificial (abaixo)



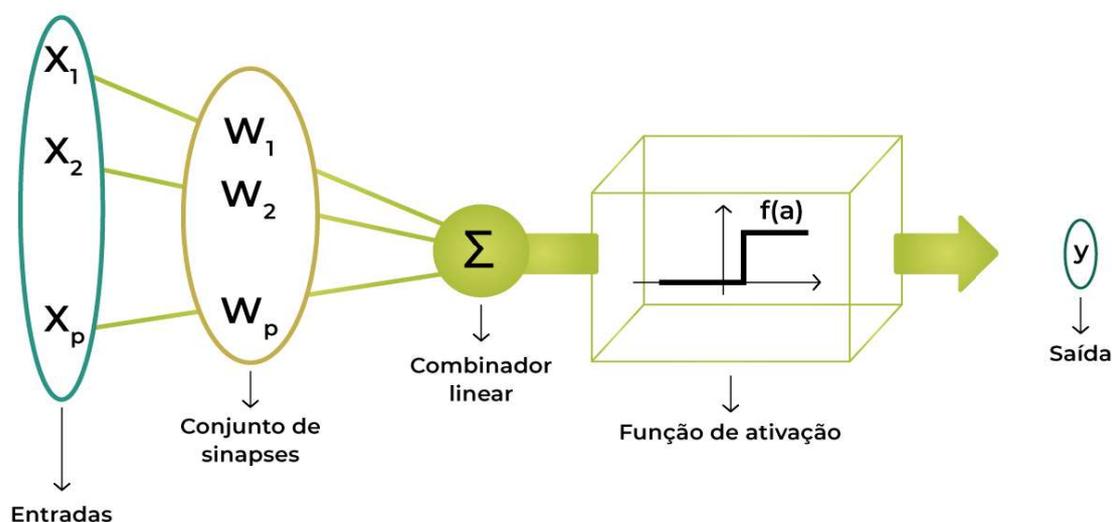
Fonte: KOPILER *et al.*, 2019.

Na figura 2, no modelo artificial (perceptron), as entradas são dadas por x_1 , x_2 e x_n . O corpo das redes neurais artificiais passa por filtros que são chamados de "pesos" e representados pela letra "w", do inglês *weight* (KOPILER *et al.*, 2019). Os pesos são diferentes para cada informação de entrada, sendo definidos aleatoriamente na primeira vez em que se executa um treinamento. É neste

momento que ele “aprende” se uma informação é importante ou não, definindo pesos diferentes para cada entrada, que desempenham melhor quando trabalham com valores entre 0 e 1.

Os pesos são alterados após cada treinamento¹⁴, em qual há uma base de dados com os valores de entrada e um resultado esperado. Dessa maneira, as entradas dos dados são passadas para os neurônios e **multiplicadas** pelos pesos ($X_1 * W_1$), em seguida passam por uma **soma** (Σ), onde seu resultado é aplicado a uma função de ativação ($f(a)$).

FIGURA 3 - Neurônio artificial



Fonte: <https://nutrimosaic.com.br/redes-neurais-artificiais-aplicadas-a-zootecnia/>

O resultado dessa função gera uma saída (y) que é o resultado daquele neurônio, ou Perceptron, como é chamado o modelo neural mais simples.

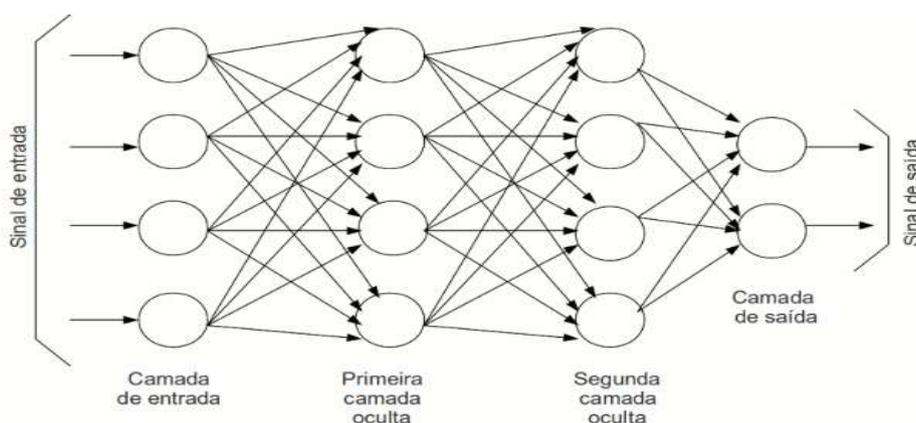
Redes neurais multicamadas

Redes neurais multicamadas são um modelo poderoso de aprendizado profundo que podem ser usados em uma variedade de aplicações. Elas permitem que os dados sejam transformados em representações mais ricas e complexas, o que pode melhorar a precisão do modelo. No entanto, o treinamento de uma rede neural multicamadas pode ser difícil e requer muitos dados e poder de computação.

¹⁴ Disponível em: <https://iaexpert.academy/2022/05/03/teoria-sobre-redes-neurais-artificiais-calculos-passo-a-passo-perceptron/>

As Redes Neurais Multi-camadas (MLPs - *MultiLayer Perceptron*) constituem uma classe de modelos de aprendizado profundo usados em uma variedade de aplicações, como reconhecimento de fala, visão computacional, análise de dados e muitos outros (ROGER, 2017).

FIGURA 4 - Rede neural



Fonte: <https://www.monolitonimbus.com.br/redes-neurais-artificiais/>

Redes neurais multicamadas são modelos de aprendizado profundo compostos de camadas de neurônios que processam informações em uma série de transformações não-lineares. Cada camada recebe os resultados da camada anterior como entrada, e produz uma saída para a próxima camada. A primeira é chamada de camada de entrada, a última, de camada de saída, e as intermediárias, de camadas ocultas.

Cada neurônio de uma camada oculta é conectado a todos os neurônios das camadas anterior e posterior. As conexões entre os neurônios são ponderadas por pesos, que são ajustados durante o treinamento, para otimizar a precisão da rede.

O treinamento de uma rede neural multicamadas envolve o ajuste dos pesos das conexões entre os neurônios, e visa minimizar a diferença entre as saídas da rede e as saídas desejadas. Este processo é geralmente realizado por meio de um **algoritmo de otimização**, como o gradiente descendente.

O gradiente descendente é um método iterativo que ajusta os pesos das conexões para minimizar uma função de perda, que mede a diferença entre a saída da rede e a saída desejada. O algoritmo calcula a derivada da função de perda em relação a cada peso e ajusta o peso proporcionalmente à derivada.

A arquitetura de uma rede neural multicamadas é determinada pelo número de camadas ocultas e pelo número de neurônios em cada camada. Uma rede neural com mais camadas ocultas,

ou com mais neurônios em cada camada, pode aprender funções mais complexas, ao passo que é mais difícil de treinar por demandar mais dados.

Redes neurais multicamadas são usadas em uma ampla variedade de aplicações como reconhecimento de fala, visão computacional, análise de dados e muitos outros. Eles são particularmente úteis em aplicações em quais a entrada é de alta dimensionalidade e não-linear, como processamento de linguagem natural e análise de imagens.

Rede neural e inteligência artificial

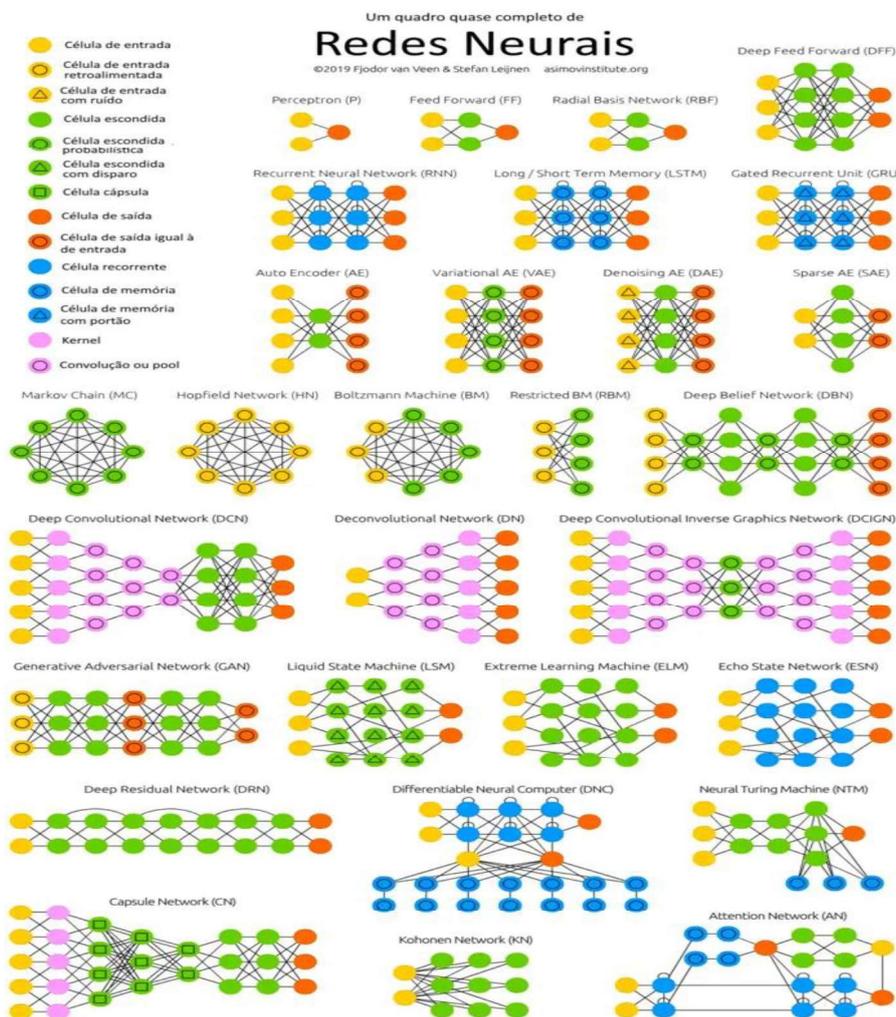
Existem diversos modelos de redes neurais que são aplicados para soluções diferentes. Um exemplo é o Perceptron, uma rede neural com apenas uma camada de neurônios, capaz de realizar classificação binária. Outro modelo é o Multilayer Perceptron (MLP), que possui múltiplas camadas ocultas e pode realizar classificação e regressão. Para tarefas de visão computacional, é comum utilizar a Convolutional Neural Network (CNN), que reconhece padrões em imagens. Já a Recurrent Neural Network (RNN) utiliza feedback, permitindo o processamento de sequências de dados, como textos e áudio. A Long Short-Term Memory (LSTM) é uma RNN com um mecanismo de memória de longo prazo. O Autoencoder reconstrói a entrada original a partir de uma representação compacta e é usado em compressão de dados e detecção de anomalias. A Generative Adversarial Network (GAN) aprende a gerar dados sintéticos semelhantes aos dados de treinamento e é usada em geração de imagens, vídeos e áudio (CECCON, 2017).

Esses são apenas alguns exemplos de modelos de redes neurais existentes. Para o desenvolvimento de aprendizagem por reforço, não há um único modelo considerado o "melhor". A escolha do modelo depende da natureza do problema a ser resolvido. No entanto, algumas arquiteturas comumente usadas em problemas de aprendizagem por reforço incluem as redes neurais profundas convolucionais (CNNs), adequadas para tarefas de visão computacional, as redes neurais recorrentes (RNNs), adequadas para estados sequenciais, e as redes neurais profundas de feedforward (DNNs), usadas em problemas mais gerais.

Além disso, existem modelos mais avançados, como as Redes Neurais de Aprendizado por Reforço Profundo (DRL), que combinam aprendizagem por reforço com redes neurais profundas, e as Redes Neurais de Aprendizado por Reforço Hierárquico (HRL), que permitem a aprendizagem em diferentes níveis de abstração.

Em resumo, a escolha do modelo de rede neural mais adequado para a aprendizagem por reforço depende do tipo específico de problema enfrentado. Cabe aos pesquisadores e desenvolvedores selecionarem a arquitetura mais adequada para a tarefa em questão.

FIGURA 5 - Tipos de redes neurais



Fonte: https://iaexpert.academy/2020/06/08/os-tipos-de-redes-neurais/?doing_wp_cron=1680567869.7873530387878417968750

Aprendizagem por reforço

Uma rede de aprendizagem por reforço é um modelo de aprendizado de máquina que permite a um agente tomar ações em um ambiente para maximizar uma recompensa. O modelo geralmente consiste em três componentes principais: o agente, o ambiente e a função de recompensa.

O agente é a entidade que toma as ações no ambiente com base em suas observações. Ele recebe informações do ambiente na forma de um estado e toma uma ação com base nesse estado. O objetivo do agente é maximizar a recompensa ao longo do tempo.

O ambiente é o mundo em que o agente opera. Ele pode ser um ambiente físico, como um robô, ou um ambiente virtual, como um jogo de computador. O ambiente envia informações ao agente sobre seu estado atual e, em seguida, o agente toma uma ação com base nessa informação.

A função de recompensa é a medida que o agente usa para avaliar suas ações. Ela fornece uma pontuação para cada ação tomada pelo agente. O objetivo do agente é maximizar essa pontuação de recompensa ao longo do tempo.

A rede de aprendizagem por reforço é treinada por meio de um processo iterativo de tentativa e erro. O agente toma ações no ambiente, recebe uma recompensa e atualiza seus pesos para melhorar suas ações futuras. Esse processo é conhecido como "aprendizagem por reforço".

A rede de aprendizagem por reforço é geralmente implementada usando uma rede neural profunda. A rede neural é usada para estimar a probabilidade de uma determinada ação ser a melhor ação a ser tomada, com base no estado atual do agente e em sua experiência anterior. A rede neural é treinada usando uma técnica de otimização chamada "descida de gradiente", que ajusta os pesos da rede para maximizar a recompensa esperada.

As redes de aprendizagem por reforço são usadas em muitas aplicações, incluindo robótica, jogos de computador e processamento de linguagem natural. Elas são particularmente úteis em situações em que o ambiente é complexo e difícil de modelar matematicamente.

Agente: O agente é o sistema que aprende a tomar decisões no ambiente. Ele pode ser um robô, um software ou qualquer outro tipo de sistema que possa interagir com o ambiente.

Ambiente: O ambiente é o mundo em que o agente atua e toma decisões. Pode ser o mundo real ou um ambiente simulado.

Função de recompensa: A função de recompensa é a maneira como o ambiente avalia as ações do agente. É uma função que atribui uma recompensa numérica ao agente após cada ação. O objetivo do agente é maximizar a recompensa acumulada ao longo do tempo.

Política: A política é a estratégia que o agente usa para decidir qual ação tomar em cada estado do ambiente. Ela pode ser determinística ou estocástica, dependendo da aleatoriedade das ações tomadas. O objetivo do agente é encontrar a melhor política possível para maximizar a recompensa.

Cálculo: O cálculo é o processo que o agente usa para atualizar sua política com base nas recompensas recebidas. Existem vários algoritmos de aprendizagem por reforço que usam diferentes métodos de cálculo para atualizar a política do agente.

O processo de aprendizagem por reforço começa com o agente realizando uma ação no ambiente. Em seguida, o ambiente fornece uma recompensa ao agente com base na ação realizada.

O agente usa essa recompensa para atualizar sua política e, em seguida, realiza outra ação. Esse processo continua até que o agente encontre uma política que maximize a recompensa acumulada ao longo do tempo.

É importante notar que a aprendizagem por reforço é uma técnica de aprendizagem por tentativa e erro. O agente aprende por meio da experiência, tentando diferentes ações e observando as recompensas recebidas. À medida que o agente ganha mais experiência, ele pode encontrar políticas mais eficientes e maximizar a recompensa acumulada ao longo do tempo.

RESULTADOS DA OFICINA DE LEITURA

A oficina de leitura, realizada no dia 15/05/2023, às 21h (figura 6), teve duração de cerca de 1 hora. Esse evento consistiu, primeiramente, na apresentação do conteúdo por meio de uma apresentação de PowerPoint. Para complementar a explicação, foi utilizado um vídeo explicativo sobre o funcionamento basal de um neurônio Perceptron.

O PowerPoint, apresentado com o auxílio de um tablet, consistia em uma breve introdução sobre a inteligência artificial, um pouco sobre sua história, o seu surgimento e suas motivações. Posteriormente, foi apresentado o conceito de uma rede neural e sua relação com o neurônio perceptron. Em seguida, explicou-se o funcionamento do aprendizado de um neurônio, o passo a passo dos cálculos envolvidos, bem como a explicação do desafio, o qual consistiu na montagem de um quebra-cabeça com peças destacáveis e um tabuleiro (figura 7). Para saber qual a peça correta, os 4 participantes precisaram compreender os conceitos, somente então foi possível calcular os valores e escolher as peças corretas para completar a atividade, escolhendo corretamente os valores de um neurônio simples (perceptron), com uma função de ativação baseada em *step function*.

Um tabuleiro (figura 6), foi impresso em papel A3, contendo desenhos de neurônios artificiais, uma tabela verdade com os valores esperados de entrada (X_i) e saída (Y_i) e as fórmulas necessárias para a realização dos cálculos.

Por fim, os 4 alunos que participaram da oficina responderam a um formulário do Google (google forms), que continha 5 perguntas para conferir se houve efetiva transmissão do conteúdo, bem como um pedido para que avaliassem o desempenho do grupo referente à avaliação. As perguntas e respostas eram:

1. Qual é o objetivo principal da inteligência artificial?

- a) Replicar a inteligência humana.
- b) Desenvolver máquinas que possam tomar decisões por si mesmas.
- c) Automatizar tarefas repetitivas.
- d) Criar sistemas que possam aprender e se adaptar.

Resposta correta: d) Criar sistemas que possam aprender e se adaptar.

	Participante 1	Participante 2	Participante 3	Participante 4	Acertos
Respostas	d	d	d	a	75%

2. O que é um neurônio perceptron?

- Uma unidade básica de processamento em um sistema de inteligência artificial.
- Um tipo de algoritmo de aprendizado de máquina.
- Um dispositivo físico que simula o funcionamento do cérebro humano.
- Um tipo de rede neural artificial.

Resposta correta: a) Uma unidade básica de processamento em um sistema de inteligência artificial.

	Participante 1	Participante 2	Participante 3	Participante 4	Acertos
Respostas	a	a	a	a	100%

3. Qual é a função de ativação mais comumente usada em um neurônio perceptron?

- Função tangente hiperbólica (tanh).
- Função sigmoide.
- Função degrau.
- Função linear.

Resposta correta: b) Função sigmoide.

	Participante 1	Participante 2	Participante 3	Participante 4	Acertos
Respostas	b	b	b	b	100%

4. O que é aprendizado supervisionado?

- Um tipo de aprendizado de máquina onde os dados de entrada são fornecidos com suas respectivas saídas corretas.
- Um tipo de aprendizado de máquina onde os algoritmos aprendem a partir de um feedback contínuo.
- Um tipo de aprendizado de máquina onde os algoritmos aprendem através da tentativa e erro.
- Um tipo de aprendizado de máquina onde os algoritmos aprendem com base em recompensas e punições.

Resposta correta: a) Um tipo de aprendizado de máquina onde os dados de entrada são fornecidos com suas respectivas saídas corretas.

	Participante 1	Participante 2	Participante 3	Participante 4	Acertos
Respostas	b	b	a	a	50%

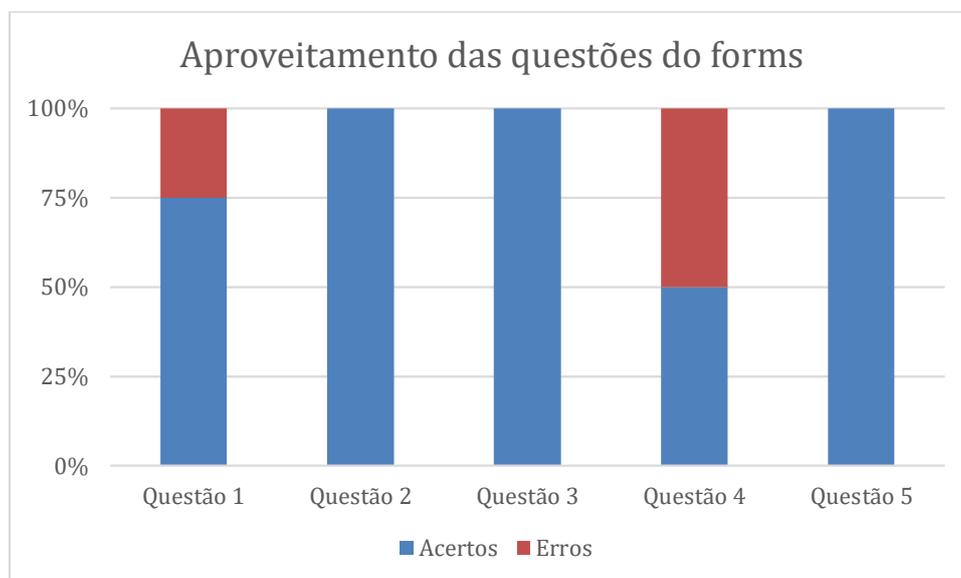
5. O que é overfitting em aprendizado de máquina?

- Um estado em que o modelo se ajusta excessivamente aos dados de treinamento e não generaliza bem para novos dados.
- Um estado em que o modelo subestima a complexidade dos dados de treinamento.
- Um estado em que o modelo não consegue ajustar-se aos dados de treinamento.
- Um estado em que o modelo se ajusta perfeitamente aos dados de treinamento.

Resposta correta: a) Um estado em que o modelo se ajusta excessivamente aos dados de treinamento e não generaliza bem para novos dados.

	Participante 1	Participante 2	Participante 3	Participante 4	Acertos
Respostas	a	a	a	a	100%

Os resultados totais foram:



Fonte: autoria própria, 2023.

Avaliação dos participantes

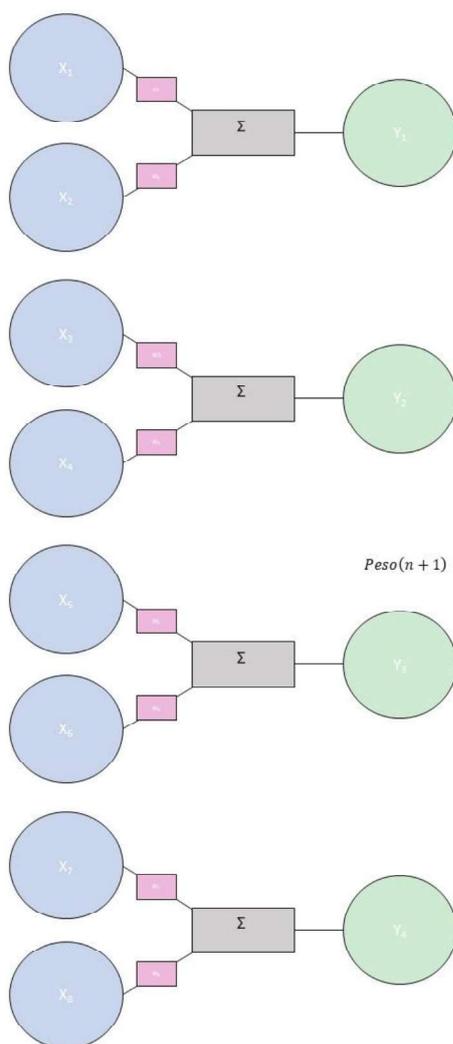
Como citado anteriormente, o formulário pedia uma avaliação dos participantes sobre a atuação do grupo referente à apresentação feita. As avaliações foram positivas, como segue:

TABELA 1 – Avaliações

Muito interessante o tema. Pesquisa muito bem feita, grau de aprofundamento adequado para a atividade. Parabéns!
Parabéns ao grupo, muito bem explicado e ótima dinâmica
Esclareceu completamente os conceitos básicos de como uma inteligência artificial funcional. Excelente explicação e atenção por parte do grupo que estava apresentando
“Explicação muito boa, trabalho muito didático. 10/10

Fonte: autoria própria, 2023.

FIGURA 6 – Tabuleiro utilizado na aplicação da oficina



$$Soma = \sum_{i=1}^n X_i + W_i$$

$$Soma \geq 1? Y_i = 1 : Y_i = 0$$

X ₁	X ₂	Classe
0	0	0
1	0	0
0	1	0
1	1	1

$$Peso(n + 1) = peso(n) + (Taxa de Aprendizagem * entrada * erro)$$

Grupo 4: Inteligência Artificial e aprendizagem por reforço

Fonte: autoria própria, 2023

CONSIDERAÇÕES FINAIS

A inteligência artificial e a aprendizagem por reforço são áreas da ciência da computação, que têm experimentado um rápido crescimento e desenvolvimento, nos últimos anos. Através da implementação de redes neurais e algoritmos de aprendizagem por reforço, tornou-se possível criar agentes virtuais capazes de aprender e tomar decisões autônomas em ambientes complexos.

A evolução da inteligência artificial e da aprendizagem por reforço tem sido impulsionada pelo avanço tecnológico, especialmente no processamento de dados e na capacidade de armazenamento. Além disso, os algoritmos de aprendizagem por reforço têm se beneficiado de melhorias significativas, permitindo a otimização do desempenho dos agentes virtuais.

As redes neurais desempenham um papel fundamental nesse processo, fornecendo estruturas flexíveis e poderosas para modelar e processar informações. Através de camadas de neurônios interconectados, as redes neurais são capazes de aprender padrões complexos e realizar tarefas de classificação, reconhecimento e tomada de decisão.

No entanto, é importante ressaltar que ainda existem desafios a serem superados. A complexidade dos ambientes, a necessidade de grandes conjuntos de dados para treinamento e a interpretabilidade dos modelos são algumas das questões que requerem atenção contínua.

Apesar dos desafios, a inteligência artificial e a aprendizagem por reforço têm um enorme potencial em várias áreas, como robótica, jogos, medicina, finanças e muito mais. À medida que a tecnologia continua a evoluir, espera-se que essas áreas sejam cada vez mais exploradas e aplicadas em problemas do mundo real.

Em suma, a combinação da inteligência artificial e da aprendizagem por reforço está transformando a maneira como os agentes virtuais interagem e aprendem com o ambiente. Com a contínua pesquisa e avanço tecnológico, podemos esperar avanços significativos nessa área, com aplicações cada vez mais diversas e impactantes em diferentes setores da sociedade.

A oficina de leitura apresentada neste trabalho proporcionou uma experiência prática e envolvente sobre os conceitos da inteligência artificial e da aprendizagem por reforço. Através do desafio do tabuleiro, os participantes puderam vivenciar a importância dos pesos, valores e otimização na resolução de problemas. A oficina despertou o interesse e a curiosidade dos participantes, incentivando-os a buscar mais conhecimento e explorar as aplicações práticas da IA. Essa experiência conectou os participantes aos fundamentos da IA e da aprendizagem por reforço, inspirando-os a contribuir para o desenvolvimento de soluções inovadoras.

REFERÊNCIAS

CECCON, Denny. *Os tipos de redes neurais*. Disponível em: <https://iaexpert.academy/2020/06/08/os-tipos-de-redes-neurais/?doing_wp_cron=1680567869.7873530387878417968750>. Acesso em: 3 maio. 2023.

CONEGLIAN, Sabrina. *Redes neurais e zootecnia: benefícios da inteligência artificial na agropecuária*. 2022. Disponível em: <https://nutrimosaic.com.br/redes-neurais-artificiais-aplicadas-a-zootecnia/>. Acesso em: 26 abr. 2023.

GÉRON, Aurélien. *Hands-On Machine Learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems*. Sebastopol: O'reilly Media, Inc., 2017. 760 p.

KOPILER, Alberto Arkader *et al.* *Redes Neurais Artificiais e suas aplicações no setor elétrico*. *Revista de Engenharias da Faculdade Salesiana*, [s. l.], n. 9, p. 27-33, jan. 2019. Disponível em: https://www.fsma.edu.br/RESA/Edicao9/FSMA_RES_2019_1_04.pdf. Acesso em: 28 abr. 2023.

ROGER, Vinicius. *Redes Neurais Artificiais*. 2017. Disponível em: <https://www.monolitonimbus.com.br/redes-neurais-artificiais/>. Acesso em: 26 abr. 2023.

HELENO, Sérgio. *Neurônios e sinapses*. 2022. Disponível em: <https://educar321.blogspot.com/2022/06/criacao-de-um-habito-no-cerebro.html>. Acesso em: 29 abr. 2023.