

Um estudo de IAs supervisionadas e não supervisionadas em jogos.

Autores: OLIVEIRA, G.A. GRINFFO, M.H.F

Orientador: VIANA, J. A. A.

e-mail: guilherme.oliveira193@fatec.sp.gov.br, matheus.grinffo@fatec.sp.gov.br,

jose.viana@fatec.sp.gov.br,

Resumo: Neste trabalho uma pesquisa foi feita em relação ao uso de Inteligências artificiais supervisionadas e não supervisionadas em jogos eletrônicos, esse estudo abrange as diferenças de cada uma delas, quando elas são usadas em um jogo eletrônico, como elas são usadas e porque elas são usadas, com isso foi demonstrado como ela já é usada atualmente em jogos eletrônicos, porque ela é usada desse modo, e também identificamos possíveis outros métodos de uso dessas tecnologias também, foi falado sobre as diferentes técnicas usadas, tais como machine learning, *deep learning* e redes neurais. Além de Identificarmos o momento que essas tecnologias são usadas também iremos identificamos quando elas não devem ser utilizadas também.

Palavras-chave: Inteligência Artificial; *Machine Learning*; *Deep Learning*; Redes Neurais

Abstract: *In this work a research was done in relation to the use of supervised and unsupervised artificial intelligences in electronic games, this study covers the differences of each of them, when they are used in an electronic game, how they are used and why they are used, with this it was demonstrated how it is already used today in electronic games, Because it is used in this way, and we also identified possible other methods of using these technologies as well, we talked about the different techniques used, such as machine learning, deep learning, and neural networks. In addition to identifying when these technologies are used, we will also identify when they should not be used as well.*

Keywords: *Artificial Inteligenc;Machine Learning;Deep Learning; Neural Networks*

1 Introdução

A inteligência artificial (IA) está cada vez mais presente no nosso cotidiano, e a alguns anos ela também tem tido grande influência e participação em jogos eletrônicos, as vezes ela vem sendo usada de modo errado ou ineficiente mesmo funcionando, esse trabalho tem como objetivo o estudo dos três principais tipos de inteligência artificial em jogos, nesse caso iremos abranger o aprendizado supervisionado, não supervisionado e o aprendizado por reforço.

O aprendizado supervisionado no jogo tem a função de fazer um treinamento da máquina com base em uma base de dados, normalmente em jogos ela pode ser usada para o reconhecimento de um cenário ou até mesmo analisar os comportamentos do jogador para ver quais decisões futuras ele pode tomar.

Já o aprendizado não supervisionado normalmente é usado em jogos para na maioria das vezes criar agentes autônomos, como um *non-playable character* (NPC) que é um

personagem não jogável, muitas vezes os jogos que fazem uso de inteligência artificial não supervisionada fazem os NPCs aprenderem sobre o jogador sozinho ou aprender que deve patrulhar uma área sozinho e se escutar um barulho ir verificar, desse modo em vários tipos de jogos o aprendizado não supervisionado é o mais usado, graças a sua eficiência.

O aprendizado por reforço é um tipo de aprendizado não supervisionado, ele normalmente é usado em jogos casuais e de estratégia, como o xadrez, mas recentemente a indústria de jogos vem aderindo ao uso dele em jogos de terror, *RPG* entre outros.

Esse aprendizado se tornou muito eficiente em jogos de terror e estratégia já que imagine o caso em que um jogador tem que fugir de um monstro se escondendo em alguns lugares, eventualmente o monstro vai aprender o jeito que o jogador se esconde, foge ou luta, o que resultará no monstro mudando suas táticas de caça ou luta.

Estudamos essas inteligências artificiais em jogos para podermos identificar porque elas estão sendo usadas, como estão sendo usadas, qual momento elas devem ser usadas e quais momentos ela não deve ser usada, para assim podermos entender por que o uso delas vem crescendo nos jogos eletrônicos.

Chegamos a essas respostas por meio de um estudo analisando a inteligência artificial implementada como um todo e depois também analisarmos elas em uso em diversos jogos de diversos anos e diversos tipos, para assim conseguir os resultados e conclusão desejada para o trabalho.

2 Justificativa

A principal razão para a criação desse projeto é aprofundar o entendimento sobre o uso de inteligências artificiais supervisionadas, não supervisionadas e de reforço no aprendizado aplicado a jogos. O crescente uso dessas técnicas tem transformado a experiência dos jogadores, as estratégias de design e impulsionado avanços tecnológicos significativos no setor.

Desde a década de 1950, a inteligência artificial vem moldando diversas áreas, incluindo os jogos, que servem como um dos principais campos de experimentação e inovação. Diante disso, um estudo abrangente sobre essas tecnologias e suas implementações no desenvolvimento de jogos não é apenas relevante, mas essencial para compreender o impacto presente e projetar tendências futuras na criação de experiências interativas e imersivas.

3 Objetivo

Visando uma melhor compreensão do uso de IAs supervisionadas e não supervisionadas e aprendizado por reforço em jogos

- Tem como objetivo identificar o uso de IAs supervisionadas, não supervisionadas e de reforço para aprendizado em jogos;
- Identificar quais as principais tecnologias de cada um desse tipo de IA estão sendo usada em jogos;

- Identificar onde e por que cada uma das tecnologias de inteligência artificial presentes nos jogos são usadas.

4 Fundamentação Teórica

Quando falando sobre o uso de inteligência artificial em jogos, é demonstrado muitas coisas, mas antes de tudo é necessário deixar claro sobre o que é um jogo e explicar mais sobre as tecnologias de IA que estamos e definir o que é um jogo, para deixar esclarecido para o leitor cada questão que será discutida e abordada no artigo.

4.1 Mundo vs Inteligência Artificial?

Desde o começo a Inteligência Artificial (IA) teve seu propósito de criação para “imitar” o ser humano e fazer as suas tarefas de um modo mais prático e efetivo, propondo tornar coisas como cálculos complexos que os seres humanos demoravam para fazer em uma coisa rápida de ser feita por uma IA, claro que com o surgimento da IA o mundo foi mudando não só na área profissional como no pessoal, por isso é importante demonstrar a evolução da IA ao longo das décadas e como o mundo a acompanhou.

4.1.1. Década de 50

Mesmo que a IA tenha começado ser estudado alguns anos antes, foi na década de 50 que ela começou a tomar força mesmo que no início da década a “Inteligência Artificial” não existia, as pesquisas sobre como fazer uma máquina imitando o ser humano e se tornando inteligente haviam começado a se tornar mais forte, até mesmo Alan Turing o pai da tecnologia comentou no seu livro intitulado “*Computing Machinery and Intelligence*” lançado em 1950, que a partir do momento que uma pessoa conversando com uma máquina se achasse que estivesse conversando com um ser humano aí finalmente a máquina teria ficado inteligente.

Foi também desenvolvido o teste de Turing que é demonstrado na publicação de Jenni(2023).

Proposto pelo matemático inglês Alan Turing em 1950, o Teste de Turing foi criado como um método para determinar a capacidade de uma máquina de exibir comportamento inteligente equivalente ou indistinguível ao de um humano. Turing evitou o debate tradicional sobre a definição de inteligência ao introduzir este teste prático para a inteligência computacional. O teste envolve um avaliador humano que se engaja em uma conversa em linguagem natural com um interlocutor invisível, que pode ser um humano ou uma máquina. Se o avaliador não consegue distinguir de forma confiável a máquina do humano com base na conversa, diz-se que a máquina passou no Teste de Turing. Essa ideia seminal lançou as bases para muitas discussões e desenvolvimentos em IA levando a uma exploração mais ampla da aprendizagem de máquinas, robótica e outras tecnologias de IA.

Foi só em 1956 com a famosa convenção Dartmouth onde os cientistas John McCarthy, Marvin Minsky, Nathaniel Rochester e Claude Shannon reuniram pesquisadores interessados em redes neurais, essa convenção é conhecida como o berço da IA pois foi lá que o termo “Inteligência Artificial”.

A década de 50 foi marcada como o ano de nascimento da IA e o ano que ela se tornou motivo de estudo, curiosidade e ceticismo, o mundo começou a ver a IA como um objeto de estudo teorizando até onde ela poderia chegar no futuro e teorizando que ela poderia se igualar à mente humana em algumas décadas, ela também teve um impacto no mundo do entretenimento onde o conceito de IA foi começando a ser implementado ao estilo de ficção científica, muitos também ficaram céticos achando que uma máquina nunca chegaria tão longe e nem seria capaz de se igualar a inteligência humana.

Porém a partir dessa década o mundo foi começando a conhecer mais sobre a IA estudando e tentando comprovar que ela poderia se igualar à inteligência do ser humano ou até mesmo superar a mesma. (SILVA, 2024).

4.1.2. Década de 60

A década de 60 seguiu o final da de 50 com o entusiasmo pela IA crescendo e ela sendo cada vez mais explorada foi a década que alguns algoritmos foram desenvolvidos para resolver problemas de lógica e simbólicos e linguagem natural um dos exemplos é o *General Problem Solver* (GPS) desenvolvido por Allen Newell e Herbert A. Simon, que se propunha a resolver problemas lógicos. (JENNI, 2023).

Em 1968 foi desenvolvido por Terry Winograd, o programa SHRDLU que podia entender e responder comandos em linguagem natural dentro de um ambiente de blocos virtuais, em resumo ele poderia receber a ordem “pegar” e então ele iria pegar um bloco virtual.

Essa foi a década que a IA em relação em cultural continuou explodindo com a ficção científica continuando tendo um grande papel nisso, nessa década mais e mais filósofos começaram a dar suas opiniões em relação a inteligência artificial demonstrando suas vantagens e desvantagens e como isso poderia afetar o mundo.

Na década de 60 a IA também encontrou um problema, que era a limitação da tecnologia da época, esse foi um dos maiores problemas enfrentados por ela, mesmo assim as pesquisas não pararam e a IA continuou crescendo.

Esta foi uma década que os primeiros robôs começaram a surgir que foram usados para fazer trabalhos perigosos e repetitivos da época, esses robôs foram implementados em fábricas metalúrgicas e automotivas. (SILVA, 2024).

4.1.3. Década de 70

A década de 70 ficou marcada na história da IA, mas não só com coisas boas essa época ficou conhecida como “O inverno da IA” já que os projetos mais ambiciosos falharam e o governo que era um dos maiores apoiadores dos estudos sobre IA parou de investir,

desanimando a indústria, um problema que veio e persistiu foi a limitação tecnológica além do problema de conseguir que a IA tivesse bom senso ou seja pensar em coisas do cotidiano que os humanos já fazem por padrão por puro instinto.(OLIVEIRA; LOPES, 2024).

Mas essa época não foi somente marcada por coisas ruins já que nessa época surgiu programas de IA baseada em conhecimento ou sistemas especializados, esses programas usavam regras e banco de dados especializados, um exemplo é a área de medicina onde a Universidade de Stanford desenvolveu o programa MYCIN que tinha como objetivo a identificação de infecções bacterianas e na recomendação de antibióticos, mesmo tendo um sucesso como uma pesquisa e ser tratado com um ótimo exemplo da evolução da época ele nunca foi implementado na época primeiro pelo receio de ele cometer um erro que coloca-se um paciente em perigo e as limitações da época. (Buchanan; Shortliffe,1984).

É válido dizer que o surgimento dos computadores pessoais trouxe um frescor para a área de IA, já que houve o surgimento de novos programadores e muitos desses interessados em IA.

4.1.4. Década de 80

A década de 80 que começou no ainda chamado de “Inverno da IA” se viu com essa época “gelada” acabando primeiro com os sistemas especializados tendo uma alta em seu uso já que começaram agora a ter um uso comercial além da pesquisa, o que revitalizou a indústria da IA, o surgimento do sistema XCON/R1 que era usado para configurar pedidos de computadores, também a outro sistema de sucesso o DENDRAL um sistema especializado em química para análise de estruturas moleculares.

Foi nessa época que também começaram a surgir os algoritmos de machine learning, com o surgimento disso as redes neurais também vêm à tona agora que era possível criar redes neurais de múltiplas camadas treinadas de uma forma mais eficiente. Além do surgimento dos algoritmos de machine learning, também surgiram os algoritmos genéricos e otimização que usam princípios de evolução biológica para resolver problemas complexos de otimização, esses algoritmos se tornaram uma ferramenta importante para a pesquisa em IA e a otimização. (SILVA, 2024).

Alguns pesquisadores continuaram tendo problemas em seus experimentos, a maioria deles a complexidade dos problemas relacionados à IA, a necessidade de grandes quantidades de dados e a dificuldade de criar sistemas que pudessem generalizar bem a partir de exemplos limitados.

Foi nessa década que a IA começou a ser implementada no meio comercial, como nas áreas de finanças, medicina e engenharia tomando decisões baseadas em conhecimento especializado, além de sistemas de automação para tarefas administrativas e industriais, embora fossem sistemas simples, esse foi um grande passo dado pela indústria.

4.1.5. Década de 90

A década conhecida pela explosão da IA foi a época de 90 houve a explosão dos algoritmos de *machine learning*, algoritmos como *support vector machines* (SVMs), árvores de decisão e redes neurais tornaram-se ferramentas padrão para a criação de modelos preditivos. Esses algoritmos permitiram a análise de grandes volumes de dados e a descoberta de padrões complexos.

Também foi quando redes neurais e *deep learning* pesquisadores começaram a usar redes neurais para reconhecimento de padrões, especialmente em imagens, o que pavimentou os caminhos para o futuro. (SILVA, 2024).

O uso da internet pela população geral foi um dos pilares para a evolução da IA já que além de fornecer uma quantidade de dados gigantescos para o treinamento da IA também ajudou na ligação entre diversos pesquisadores além disso com a criação de ferramentas de pesquisa como o Google em 1998 que usavam algoritmos de IA para ajudar na relevância dos resultados de pesquisa.

Não pode ser deixado de falar os jogos, nos anos 90 os criadores começaram a fazer jogos que fazem uso de IA, um dos eventos mais marcantes da época relacionado a IA foi a derrota de Garry Kasparov campeão mundial de xadrez para o computador da IBM *Deep Blue*, esse evento demonstrou o avanço da IA em jogos estratégicos demonstrando que máquinas poderiam superar humanos em raciocínios lógicos.

Além de jogos de estratégia como o xadrez a década de 90 teve um crescimento de uso de IA em jogos, já que alguns agora haviam implementado IA em seus jogos para dar um desafio crescente maior para seus jogadores.

Os sistemas especialistas que viam desde a época passada continuaram a aumentar seus usos em setores específicos, houve o surgimento de agentes inteligentes que são programas que podiam agir de forma independente em nome dos usuários, um dos exemplos é o *Clippy* da Microsoft que não foi muito bem recebido, mas que marca como um dos primeiros agentes.

Houve um crescimento muito grande na área comercial eletrônico já que empresas como Amazon e eBay que começaram a utilizar a IA para personalizar recomendações e otimizar a logística. A década de 1990 viu o início do comércio eletrônico em grande escala, com a IA desempenhando um papel crucial na análise de comportamento do consumidor e na otimização de operações.

4.1.6. Anos 2000

Os anos 2000 foi marcada como a mudança da IA de uma área de pesquisa da tecnologia para uma coisa do cotidiano mundial, essa época é marcada pela grande evolução nas áreas de *machine learning*, grandes volumes de dados na internet e o começo do uso da IA na maioria das áreas comerciais.

Com a explosão da internet e o crescimento das plataformas digitais uma quantidade de dados gigantes começou a ser gerada diariamente, o que foi ótimo para o *machine learning*

já que os algoritmos de ML precisam de grandes volumes de dados para treinar seus modelos com a melhor precisão.

As grandes empresas começaram a usar o *machine learning* para analisar grandes volumes de dados para extrair as informações mais valiosas, foi aí que houve a popularização dos motores de recomendação que é usado por empresas como a Amazon ou Youtube que se trata de um sistema de recomendação que faz mais sentido pelos gostos e pesquisas recentes do usuário, esse foi um exemplo de como sistemas de IA começaram a ser colocada em plataformas que que milhões de pessoas usam diariamente. (SILVA, 2024).

A década também viu o surgimento de frameworks de aprendizado de máquina, como *Hadoop* e *MapReduce*, que permitiram o processamento de grandes conjuntos de dados de maneira distribuída, facilitando o trabalho com *Big Data*.

Houve também a evolução de redes neurais já que agora elas conseguiam ter um desempenho melhor e bem mais satisfatório em tarefas como reconhecimento de voz e imagens o que era algo novo e levou a uma nova área de pesquisa.

Agora aplicações que faziam uso de visão computacional que consiste no uso da IA para reconhecer coisas que ela pode “ver” comparando com dados que ela já tinha, começaram a fazer mais sucesso já que estavam mais precisas o que fez várias empresas a implementar para diversos usos, desde a sua segurança como em sistemas de reconhecimento facial até a personalização de experiência do usuário.

O processamento de linguagem natural também deu grandes passos durante essa década. Modelos como o *Word2Vec*, desenvolvidos por pesquisadores do Google em 2003, permitiram a criação de representações vetoriais de palavras, o que facilitou o desenvolvimento de *chatbots* e assistentes virtuais.

Recentemente Silva (2024) constatou que foi nessa época que começaram a surgir as assistentes pessoais inteligentes como a siri da Apple, o Google Assistente da Google e a Alexa da Amazon, essas assistentes surgiram como uma novidade já que você podia “conversar” com sua máquina e ela não iria só “responder” como também lhe ajudaria com o que você pediu, além do surgimento das tecnologias de interação por voz que foi impulsionada por técnicas de *deep learning* que ajudou os assistentes virtuais a interpretar comandos por voz com uma maior precisão.

Foi nos anos 2000 que a IA também começou a ser usada para automação de processo com os *Robotic Process Automation* (RPA) que consistem em *bots* para realizar tarefas repetitivas, elas ganharam grande atenção no setor corporativo por causa do seu aumento de eficiência e diminuição de custos. Essa foi uma época que até o setor automotivo começou a fazer o uso da IA adicionando componentes que faziam uso dessa tecnologia em seus veículos dando surgimento aos veículos autônomos, além de ter o fato dos robôs que começaram a ser cada vez mais melhorados e usados nas indústrias.

Silva (2024) diz que.

Os avanços na robótica, impulsionados pela IA, resultaram em robôs mais capazes e adaptáveis, utilizados em manufatura, logística, cirurgia e até em aplicações domésticas. Robôs equipados com IA podem aprender com suas experiências, melhorar seu desempenho ao longo do tempo e realizar tarefas complexas com maior precisão.

Com o grande crescimento da IA na maioria dos setores do cotidiano, muitas discussões éticas começaram a surgir, já que a IA estava “tomando” conta de tudo, as discussões se tratava da regulação da IA além de observações sobre privacidade, segurança e o impacto da automação no mercado de trabalho tornaram-se centrais sobre o futuro da IA. Organizações como a *Partnership on AI*, formada em 2016, começaram a se organizar no final da década para tratar desses desafios. (SILVA, 2024).

O avanço da IA só aumenta a cada dia e cada vez mais estudos sobre ela vem surgindo em diversas áreas buscando demonstrar suas capacidades, sobre o seu futuro e limitações.

4.2 O que é a IA nos tempos modernos

A IA, atualmente, está presente em diversas áreas da nossa vida cotidiana, desde assistentes virtuais como Siri e Alexa até sistemas de recomendação em plataformas de streaming e e-commerce (GUITARRARA, 2024).

4.2.1. Componentes da IA atualmente

Algoritmos: São conjuntos de instruções que permitem a análise de dados e a geração de respostas. Eles podem ser categorizados em:

- **Aprendizado Supervisionado:** Usa dados rotulados para treinar modelos que aprendem a mapear entradas para saídas específicas. Exemplos incluem redes neurais e máquinas de vetores de suporte (SVMs), (WILSON, 2019).
- **Aprendizado Não Supervisionado:** Processa dados sem rótulos para descobrir padrões subjacentes. Algoritmos como *K-Means* e *Clustering* hierárquico se destacam nessa área (DATASCIENCEDOJO, 2022).
- **Aprendizado por Reforço:** Baseia-se na interação de um agente com um ambiente, onde ele aprende a tomar decisões a partir de recompensas ou penalidades, como o *Q-learning* e *Deep Q-Networks* (UNIVERSITY OF YORK et al. 2024).

Dados: São a matéria-prima essencial para treinar os modelos de IA. A qualidade e quantidade de dados impactam diretamente o desempenho dos sistemas de IA sendo cada vez mais dependentes de big data.

Infraestrutura Computacional: Inclui hardware e software, como GPUs, CPUs e frameworks de *deep learning* (*TensorFlow*, *PyTorch*), necessários para executar os complexos algoritmos de IA.

4.2.2. Paradigmas de IA

- **IA Simbólica:** Baseada em regras lógicas e símbolos programados manualmente. Usada em sistemas especialistas com regras do tipo "se-então".

- IA Conexionista: Inspirada no cérebro humano, utiliza redes neurais artificiais que aprendem diretamente dos dados. Exemplos são CNNs (redes neurais convolucionais) e RNNs (redes neurais recorrentes).
- IA Evolutiva: Utiliza princípios da evolução, como seleção natural, para otimizar soluções e resolver problemas complexos.
- IA Probabilística: Usa modelos estatísticos para lidar com incertezas. Redes bayesianas e modelos ocultos de Markov (HMMs) são exemplos dessa abordagem.

4.2.3 Aplicações de IA

Hoje, a IA está revolucionando diversos setores, como:

- Visão Computacional: Usada em reconhecimento facial, análise de imagens médicas e veículos autônomos.
- Processamento de Linguagem Natural (PLN): Aplicada em *chatbots*, tradução automática, geração de texto e análise de sentimentos em redes sociais.
- Sistemas de Recomendação: Personalizam recomendações de produtos ou conteúdos em plataformas como Netflix e Amazon, baseando-se no comportamento do usuário.
- Jogos: IA é fundamental em NPCs (personagens não jogáveis), geração procedimental de níveis e ajuste dinâmico da dificuldade dos jogos.

4.3 IA em jogos

A utilização da IA em jogos eletrônicos teve seus primórdios em 1952, com o desenvolvimento do jogo *Tic-Tac-Toe* (Jogo da Velha) por Arthur Samuel. Este evento representou um marco significativo na história da IA, visto que Samuel elaborou um algoritmo capaz de aprender as nuances do jogo e aprimorar suas estratégias com base nas partidas disputadas. A capacidade de aprendizado implementada por Samuel inaugurou uma nova era no desenvolvimento de jogos, demonstrando o potencial da IA para criar oponentes desafiadores e adaptativos. (KISHIMOTO, 2004).

Em 1962, o lançamento de *Spacewar!* marcou outro passo importante na integração da IA em jogos. Considerado um dos pioneiros no gênero de combate espacial, *Spacewar!* apresentava inimigos controlados por IA, ainda que com limitações inerentes à tecnologia da época. A IA presente no jogo se restringia a controlar naves espaciais com base em regras pré-definidas de movimentação e ataque, o que, apesar de rudimentar, contribuiu para a imersão dos jogadores ao proporcionar uma experiência de combate espacial dinâmica. (KISHIMOTO, 2004).

A década de 1970 marcou o auge dos jogos de arcade, e *Space Invaders* despontou como um dos pioneiros na utilização de mecanismos de IA. O objetivo do jogo era simples: o jogador controla uma nave com a missão de destruir as naves inimigas que o atacavam. A inovação residia na capacidade da IA de controlar a velocidade dos invasores, aumentando-a

progressivamente à medida que o jogador os eliminava. Essa dinâmica proporciona um aumento gradual na dificuldade, elevando o desafio e o fator viciante do jogo. (FILHO; FILHO, 2022)

Já em 1980, tivemos o lançamento de *Pac-Man*, um jogo em que a inteligência artificial foi levada a outro patamar, sendo usada principalmente para criar inimigos com personalidade, o que fez com que os fantasmas tivessem padrões diferentes de ataque ao jogador. Por exemplo, Blinky (o fantasma vermelho) sempre dava preferência a perseguir o Pac-Man (o personagem principal), enquanto Pinky (o fantasma rosa) tentava antecipar os movimentos do jogador para encurralá-lo. Com isso, os fantasmas apresentavam formas diferentes de perseguir o jogador, criando, assim, jogadas e estratégias únicas para lidar com eles. (KISHIMOTO et al. 2004).

Em 1993, tivemos *Doom*, o pioneiro dos jogos de tiro em primeira pessoa, em que as IAs eram usadas em máquinas de estados finitos, permitindo que os inimigos alternassem entre diferentes estados, como perseguir o protagonista, patrulhar uma área ou atacar assim que o inimigo estivesse no campo de visão. Para os padrões atuais, essas são funções simples, mas para a época, representavam uma revolução. (KISHIMOTO et al. 2004).

Em 1998, tivemos o jogo *Half-Life*, que trouxe uma revolução nos sistemas de física aplicada e no uso de IA. O jogo usava uma IA simples, com base em scripts, mas com uma complexidade anormal para os jogos da época. Os inimigos, em especial os Marines (soldados humanos), possuíam uma notável coordenação tática, podendo atacar pelos flancos, buscar cobertura ou atacar de forma organizada para forçar o jogador a mudar seu estilo de jogo. O jogo também usava a IA para que os NPCs (*non playable characters*) pudessem interagir e reagir com o ambiente de forma mais convincente, proporcionando uma experiência mais imersiva e criando a sensação de um mundo mais vivo e dinâmico. (FILHO; FILHO, 2022).

A evolução da IA em jogos nos anos 2000 foi marcada pela expansão dos mundos abertos e pelo desenvolvimento de IAs de combate mais complexas. Jogos como *Grand Theft Auto: San Andreas* e *The Elder Scrolls III: Morrowind* trouxeram NPCs com comportamentos mais realistas e adaptativos, enquanto *Halo: Combat Evolved* e *F.E.A.R.* apresentaram inimigos com táticas avançadas de combate, como flanquear e se proteger. Nos jogos de estratégia em tempo real, a IA também se tornou mais sofisticada, como em *Civilization IV*, que simulava líderes com personalidades e estratégias distintas. (KISHIMOTO et al. 2004).

Nos anos 2010, o *Machine Learning* começou a ser explorado em jogos, com destaque para a IA *AlphaGo* em *StarCraft II*, que aprendeu a jogar em alto nível. A personalização da experiência também ganhou força com jogos como *Middle-Earth: Shadow of Mordor* e seu sistema *Nemesis*, que permitia que os inimigos "evoluíssem" com base nas interações com o jogador. As narrativas dinâmicas também se beneficiaram da IA, com jogos como *The Walking Dead* adaptando a história às escolhas do jogador. (FILHO; FILHO, 2022).

Já nos anos 2020, a IA generativa passou a ser utilizada para criar conteúdo dinâmico, como em *AI Dungeon*, que gera histórias personalizadas em tempo real. A IA também foi aplicada para criar companheiros virtuais mais inteligentes e realistas, como Ellie em *The Last of Us Part II*. Mundos procedurais vastos e complexos, como em *No Man's Sky*, também se tornaram realidade com o auxílio de algoritmos de IA. Além disso, a IA de

aprendizado contínuo permitiu que NPCs adaptassem suas habilidades ao jogador, proporcionando experiências mais desafiadoras e personalizadas. (FILHO; FILHO, 2022).

4.4 O que é Inteligência Artificial Supervisionada?

O aprendizado supervisionado é uma abordagem de treinamento de modelos de IA aonde o sistema é alimentado com pares de entrada-saída rotulados. Cada exemplo no conjunto de dados de treinamento é composto por uma entrada e a saída desejada. O objetivo é que o modelo aprenda a mapear as entradas para as saídas corretas, generalizando bem para novos dados não vistos durante o treinamento.

O autor Alex Wilson (2019) diz que

O aprendizado supervisionado é uma forma de aprendizado de máquina que visa modelar a relação entre os dados de entrada e os rótulos de saída. Os modelos são treinados usando exemplos rotulados, em que cada entrada é emparelhada com sua saída correta correspondente. Esses exemplos rotulados permitem que o algoritmo aprenda padrões e faça previsões em dados não vistos.

4.4.1 Componentes do Aprendizado Supervisionado

Dados Rotulados: Conjuntos de dados onde cada instância é associada a uma etiqueta ou valor de saída conhecido. Por exemplo, um conjunto de dados para reconhecimento de imagem pode incluir imagens de animais (entradas) e os nomes dos animais correspondentes (saídas).

Função de Custo: Mede a discrepância entre as previsões do modelo e as saídas reais. O objetivo do treinamento é minimizar essa função de custo, ajustando os parâmetros do modelo.

Algoritmos de Treinamento: Métodos usados para ajustar os parâmetros do modelo. Exemplos incluem regressão linear, árvores de decisão, máquinas de vetor de suporte (SVMs) e redes neurais artificiais.

4.4.2 Exemplos de Aplicações

Classificação: Determinar a categoria à qual uma nova observação pertence, com base em um conjunto de dados de treinamento contendo observações cujas categorias são conhecidas. Exemplos incluem classificação de e-mails como spam ou não spam, e reconhecimento de dígitos manuscritos.

Regressão: Prever um valor contínuo com base em entradas, como prever preços de imóveis ou temperaturas futuras.

4.4.3 Definição Técnica de IA Não Supervisionada

O aprendizado não supervisionado envolve treinar modelos com dados que não têm rótulos ou saídas conhecidas. O objetivo é identificar padrões ou estruturas ocultas nos dados sem orientação explícita sobre o que procurar.

4.4.4 Componentes do Aprendizado Não Supervisionado

Dados Não Rotulados: Conjuntos de dados onde as instâncias não possuem uma etiqueta ou valor de saída associado. O modelo deve encontrar relações intrínsecas nos dados por conta própria.

Algoritmos de Agrupamento e Associação: Métodos que procuram identificar agrupamentos naturais nos dados ou associações entre características dos dados. Exemplos incluem *K-Means*, agrupamento hierárquico, e redes neurais auto-organizáveis (SOM), (DATASCIENCEDOJO, 2022).

4.4.5 Exemplos de Aplicações

Agrupamento (*Clustering*): Dividir um conjunto de dados em grupos de elementos similares. Um exemplo comum é a segmentação de mercado, onde os clientes são agrupados com base em comportamentos de compra.

Redução de Dimensionalidade: Reduzir o número de variáveis em um conjunto de dados, mantendo a maior quantidade possível de informações importantes. Técnicas incluem Análise de Componentes Principais (PCA) e Análise de Componentes Independentes (ICA).

4.4.6 Definição de Aprendizado por Reforço

O aprendizado por reforço (*Reinforcement Learning* - RL) é um paradigma da aprendizagem de máquina focado em como agentes inteligentes devem tomar ações em um ambiente dinâmico para maximizar uma recompensa cumulativa. Diferente do aprendizado supervisionado, que requer dados rotulados, o RL baseia-se na interação contínua com o ambiente, onde o agente aprende através de tentativa e erro, recebendo feedback na forma de recompensas ou punições. (MUREL; KAVLAKOGLU, 2024).

Pode ser entendido pelo autor Alex Wilson (2019) que “o aprendizado por reforço é uma abordagem de aprendizado de máquina em que um agente aprende por tentativa e erro, realizando ações em um ambiente. Este método de aprendizagem gira em torno do conceito de maximizar recompensas e minimizar penalidades.”

4.4.7 Componentes do Aprendizado por Reforço

Agente: A entidade que toma ações no ambiente para maximizar recompensas.

Ambiente: O contexto ou mundo no qual o agente opera, descrito por estados.

Estado (S): A representação atual do ambiente ou situação em que o agente se encontra.

Ação (A): Conjunto de todas as operações possíveis que o agente pode executar a partir de um estado.

Recompensa (R): O feedback recebido pelo agente após realizar uma ação, indicando o sucesso ou fracasso da ação.

Política (π): Estratégia que o agente segue para decidir suas ações com base nos estados atuais.

Função de Valor (V): Avaliação da "qualidade" de um estado em termos de recompensas esperadas futuras.

Função de Q-Valor (Q): Avaliação da qualidade de uma ação específica em um estado específico.

4.4.8 Métodos de Aprendizado por Reforço

Q-Learning: Um método *off-policy* que busca aprender a função de valor Q, que representa a qualidade de uma ação em um estado, independentemente da política seguida.

SARSA (*State-Action-Reward-State-Action*): Um método *on-policy* que aprende a função de valor Q enquanto segue a política atual, ajustando-se com base nas ações realmente tomadas pelo agente.

Algoritmos de Diferença Temporal (TD): Combinam aspectos de programação dinâmica e métodos de Monte Carlo, atualizando a política do agente com base na diferença entre as recompensas esperadas e reais.

4.4.9 Exemplos de aplicações de Aprendizado por Reforço

Robótica: Agentes de RL são utilizados para controlar robôs em tarefas complexas, como navegação autônoma e manipulação de objetos.

Jogos Eletrônicos: O RL é amplamente aplicado para criar agentes que aprendem a jogar jogos como xadrez, *AlphaGo* e videogames clássicos. Um exemplo notável é o *AlphaGo*, que utiliza RL para tomar decisões de jogo em tempo real.

Processamento de Linguagem Natural (NLP): Agentes de RL são usados para melhorar *chatbots* e assistentes virtuais, permitindo que eles interajam de forma mais natural e eficaz com os usuários.

5 Trabalhos Similares

5.1 Aprendizado por reforço utilizando Q-Learning e redes neurais artificiais em jogos eletrônicos.

Neste trabalho o autor Ícaro da Costa (2018) estuda o aprendizado por reforço com *Q-Learning*.

Ele observa e descreve os métodos que são usados nesse tipo de aprendizado, junto com as fórmulas matemáticas, ele também descreve como funciona agentes, e propõe a criação de um próprio agente dele usando tecnologias *open source* para não só desenvolver seu agente, mas também fazer com que ele reconheça as imagens dos jogos que são usadas como base.

Ele faz uso de tecnologias da OpenIA primeiro para fazer a criação do seu agente e depois para reconhecer a imagem oficial do jogo, e depois para modificar as dimensões e formato da imagem original para que o agente possa enxergar e conseguir jogar o jogo.

O autor faz o estudo com base em 4 jogos, *Ms Pacman*, *Enduro*, *Pong* e *Breakout*, ele criou o seu agente e depois fez jogar cada um dos jogos assim gerando um resultado e identificando se o agente dele conseguiu ou não aprender a melhor forma de jogar cada jogo, no estudo o agente demonstrou ter aprendido somente no *Ms Pacman*.

Nas palavras de Ícaro da Costa (2018).

O agente obteve maior êxito no jogo *Ms. Pacman*. Neste jogo, como o agente é frequentemente recompensado a cada ação tomada e a mecânica do jogo prioriza a estratégia frente à precisão da movimentação, o aprendizado foi mais efetivo.

Já para os outros jogos que precisam de jogadas mais complexas para fazer pontos e gerar recompensas o aprendizado não foi eficiente, porque o agente não conseguia fazer as jogadas necessárias para obter uma recompensa logo não aprendendo nada.

O trabalho do autor Ícaro da Costa foi bem desenvolvido, porém pela escolha de jogos que ele fez o agente dele não pode ser tão bem aproveitado como deveria, mesmo assim vale dizer que a construção do agente foi muito bem-feita, mesmo que não bem usado ele demonstrou que com o jogo certo sua curva de aprendizado foi muito boa.

Na nossa opinião, se o autor continuar trabalhando seus agentes do modo certo e com os jogos certos o agente poderá ter um grande sucesso no seu futuro.

Vale dizer que esse é um trabalho muito interessante a ser seguido não só como base de estudo, mas também como futura descoberta e desenvolvimento.

5.2 Um Sistema para o Aprendizado Automático de Jogos Eletrônicos baseado em Redes Neurais e *Q-Learning* usando Interface Natural.

No estudo conduzido pelos autores Rafael Lopes e Victor Guerese (2017), foi investigado o aprendizado por reforço em jogos eletrônicos, empregando o algoritmo *Q-Learning* em conjunto com redes neurais. O objetivo principal foi desenvolver um algoritmo apto a aprender a jogar diversos tipos de jogos eletrônicos, visando alcançar a maior pontuação possível.

Utilizando emuladores de Atari e Playstation 2, foram testados cinco jogos distintos: *Toy Problem*, *Pong*, *Breakout*, *Enduro* e *Galaga*. Os pesquisadores coletaram informações a partir de frames dos jogos, monitorando a pontuação e recompensando a inteligência artificial (IA) a cada aumento de pontuação em relação à anterior. Para isso, realizaram um treinamento com 500 partidas, permitindo que a rede neural aprendesse os padrões de jogo para, então, tentar antecipar possíveis cenários em 10 partidas selecionadas aleatoriamente.

Posteriormente, os pesquisadores compararam o desempenho das 10 partidas selecionadas aleatoriamente com o das 10 partidas realizadas durante o treinamento.

Para Lopes e Guerese (2017)

Os resultados obtidos foram satisfatórios em três dos cinco jogos analisados. Observou-se que os jogos que demandam movimentos mais precisos foram os que apresentaram os piores resultados para o agente, devido à sua dificuldade em compreender os limites de movimento do jogo e em discernir como o jogo avalia um acerto.

Ao compará-lo com outros algoritmos presentes na literatura, foi possível notar que o agente obteve resultados comparáveis e satisfatórios em relação a esses algoritmos, os quais se baseiam em dados extraídos da memória dos jogos. Também se evidenciou que a utilização de redes neurais para antecipar os resultados do algoritmo *Q-Learning* tornou o experimento viável, uma vez que possibilitou uma análise atemporal das decisões tomadas.

Por fim, é perceptível que o treinamento foi eficaz, embora tenha acarretado um alto custo computacional devido ao método de análise de telas empregado pelos pesquisadores.

O trabalho dos autores Rafael Lopes e Victor Guerese foi bem desenvolvido, introduzindo métodos de análise de dados que se diferenciam dos comumente utilizados na literatura. Vale destacar que o agente criado demonstrou excelentes resultados na maioria dos testes realizados. No entanto, enfrentou algumas dificuldades em determinados jogos, atribuídas a dois principais fatores: a limitação do agente em dominar os controles e a jogabilidade ultrapassada dos jogos testados.

Considerando o escopo do estudo, é possível extrair ideias sobre a importância do aprendizado por reforço no desenvolvimento de máquinas capazes de se adaptar à jogabilidade dos jogadores de jogos contemporâneos. Isso se deve à grande capacidade dos algoritmos de prever situações com base nas informações coletadas, alinhadas à forma como o jogador humano interage com o jogo. Essas descobertas podem servir como base para futuros testes e para pesquisas adicionais que possam complementar a pesquisa que nós realizamos.

5.3 Métodos de Inteligência Artificial aplicados em jogos baseados em turnos.

Nesse estudo o autor Gabriel Pacheco (2018) propõe o uso de dois algoritmos diferentes para o uso de aprendizado por reforço o primeiro algoritmo e o *Heuristically Accelerated Q-Learning* (HAQL) e o outro e o Algoritmo Evolutivo (AE), eles usam os dois algoritmos com 5 agentes diferentes, o jogo que eles usam como estudo se chama: *MiniDungeons* esse jogo é um jogo em 2D que tem como objetivo explorar uma *dungeon* encontrar tesouros, matar inimigos e ir para o próximo andar, vale dizer que o jogo foi feito

com o intuito de ser usado para teste de agentes de aprendizado e claro para diversão também, sua pesquisa o autor fez cada um dos agentes ter um objetivo diferente...

O primeiro tinha o objetivo de explorar o jogo de todos os modos sem focar em nenhum objetivo específico, esse agente foi chamado de *Baseline*, o segundo agente tinha o objetivo de passar pelas fases do jogo priorizando a menor quantidade de mortes possíveis esse agente recebeu o nome de *Survivalist*.

Seguindo isso vinha o agente responsável por priorizar a menor tomada de ações possíveis para passar à fase, esse agente foi chamado de *Runner*, também um agente responsável por priorizar a morte de monstros, esse agente tem o nome bem sugestivo de *Monster Killer*.

No agente final temos primeiro o agente responsável por coletar os tesouros em cada fase do jogo, esse agente foi chamado de *Treasure Collector*.

No seu estudo o autor observou como cada algoritmo iria interagir com cada agente e depois comparou os resultados obtidos, chegando à conclusão que em casos focando só o objetivo do agente o primeiro algoritmo chamado de HAQL tinha um sucesso maior porque ficava só na função dele e nada mais, mas em um contexto geral o AE se mostra mais efetivo porque ele além de focar no objetivo principal tentar tomar sempre as melhores rotas para evitar danos negativos. (Pacheco, 2018)

Foi possível observar nesse trabalho a grande diferença entre os algoritmos falados e demonstrados e como eles tem suas vantagens e desvantagens. em casos diferentes, foi possível principalmente notar que no caso de precisão de um agente para algo bem específico o algoritmo HAQL usado realmente superior, porém no caso de um agente que tem um objetivo e deve focar nos menores danos possíveis o AE se mostrou a melhor escolha.

Após ler e estudar o arquivo, pudemos observar que a pesquisa desenvolvida pelo autor se mostrou extremamente interessante e altamente relevante para o tema. Sem dúvida, ela não apenas pôde, como efetivamente agregou valor à pesquisa que foi desenvolvida neste artigo, elevando seus critérios e contribuindo significativamente para as respostas que buscávamos obter.

O trabalho mostrou-se cheio de atributos úteis para nosso artigo, como o fato de descrever muito bem as tecnologias que estudamos, além de abordar alguns algoritmos que foram interessantes para o desenvolvimento do estudo.

6 Metodologia

A metodologia utilizada para o desenvolvimento do artigo consistiu em uma pesquisa exploratória baseada em fontes confiáveis, selecionadas criteriosamente para garantir a qualidade das informações obtidas. Com base nesses dados, foram realizadas análises para atingir os objetivos definidos previamente. Além disso, foi conduzido um estudo de caso para ilustrar a aplicação prática de cada uma das tecnologias abordadas em jogos, destacando os desafios enfrentados em sua implementação

7 Desenvolvimento

Hoje em dia, a Inteligência Artificial (IA) está presente em quase todos os jogos, tornando as experiências de jogo mais dinâmicas, desafiadoras e imersivas. Existem três tipos principais de IA usadas nos jogos: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço. Cada um tem suas particularidades e oferece formas únicas de aprimorar a experiência dos jogadores.

7.1 IA Supervisionada na Prática

No aprendizado supervisionado, a IA é treinada com dados já organizados para reconhecer padrões e fazer previsões. Imagine um jogo de cartas como *Hearthstone*: a IA analisa as combinações de cartas e consegue antecipar as estratégias mais eficientes, como se "pensasse" como um jogador experiente. Outro exemplo é o sistema de *matchmaking* em *League of Legends*, que usa aprendizado supervisionado para prever o nível de habilidade dos jogadores e formar equipes equilibradas, garantindo partidas mais justas e competitivas (GOODFELLOW et al. 2016).

Esse tipo de IA também é utilizado em jogos de realidade aumentada como Pokémon GO, onde a tecnologia permite que a IA reconheça objetos reais e alinhe elementos virtuais, criando uma interação fluida entre o mundo real e o virtual (RUSSELL; NORVIG, 2010). Além disso, no multiplayer, a IA supervisionada identifica comportamentos tóxicos e fraudes com base em dados históricos, ajudando a manter um ambiente de jogo mais saudável (GOODFELLOW et al. 2016).

Em RPGs, a IA supervisionada ajuda na recomendação de itens. Por exemplo, com base no estilo de jogo do jogador ou na classe do personagem, a IA pode sugerir itens relevantes, o que torna o jogo mais intuitivo e prático (RUSSELL; NORVIG, 2010).

7.2 IA Não Supervisionada na Prática

No aprendizado não supervisionado, a IA analisa dados sem orientação específica, encontrando padrões e agrupando informações de forma autônoma. Em jogos massivos como *World of Warcraft* e *Destiny 2*, a IA entende melhor o perfil de cada jogador, identificando se ele gosta mais de explorar, competir ou colaborar. Com isso, o jogo pode adaptar os desafios e recompensas ao estilo de cada jogador, aumentando o engajamento (GOODFELLOW et al. 2016).

Um uso muito conhecido do aprendizado não supervisionado é a geração procedural, que cria níveis, mapas e paisagens automaticamente. Jogos como *Minecraft* e *No Man's Sky* utilizam essa tecnologia para gerar mundos únicos a cada partida, sem a necessidade de criação manual. Em *League of Legends*, a IA também analisa métricas dos jogadores, como tempo em cada função e *KDA* (mortes, abates e assistências), para criar partidas balanceadas e conteúdos personalizados (RUSSELL; NORVIG, 2010).

Outra aplicação interessante é em jogos de mundo aberto como *Spore*, onde a IA gera sons e músicas que se adaptam ao ambiente e às ações do jogador, criando uma atmosfera mais envolvente e natural (SUTTON; BARTO, 2018).

7.3 IA por Reforço na Prática

O aprendizado por reforço é um tipo de IA que aprende por tentativa e erro, ajustando-se para alcançar o melhor resultado possível. Esse método é fundamental em jogos como *Dota 2* e *StarCraft II*, onde agentes de IA, como o *OpenAI Five*, enfrentam jogadores humanos e desenvolvem estratégias cada vez mais complexas, jogando milhares de partidas simuladas. Esse tipo de IA é capaz de se adaptar em tempo real, o que torna cada partida única e desafiadora (SUTTON; BARTO, 2018).

De acordo com a OpenAI (2018), o *OpenAI Five* joga 180 anos de jogos contra si mesmo todos os dias, aprendendo por meio do auto jogo (BROCKMAN et al. 2019).

Em jogos de esportes, como *FIFA*, o aprendizado por reforço permite que a IA se adapte ao estilo de jogo do usuário. Por exemplo, se o jogador gosta de passes rápidos, a IA pode ajustar sua defesa em tempo real para tornar a experiência mais desafiadora e personalizada. Em jogos de corrida, NPCs também aprendem com o comportamento dos jogadores, criando estratégias para competir de forma mais acirrada (SUTTON; BARTO, 2018).

Outro exemplo notável está em *Alien: Isolation*, onde a IA do alien aprende com base nas ações do jogador. Ao longo do jogo, o alien se torna mais habilidoso em detectar e perseguir o jogador, o que aumenta o suspense e o desafio (RUSSELL; NORVIG, 2010). Em RPGs e jogos de mundo aberto, NPCs podem ajustar suas atitudes em resposta às escolhas do jogador, como oferecer descontos ou até aumentar os preços dependendo das ações do personagem (GOODFELLOW et al. 2016).

7.4 Desafios

Cada uma dessas tecnologias tem suas vantagens e desvantagens e seus diferentes usos como já foi mostrado acima, cada uma delas também possuindo suas dificuldades, o modelo de IA supervisionada trabalha com dados rotulados, o que depende uma grande quantidade de informações para comparação de certo o errado, o que torna esse modelo o menos dinâmico e veloz, tornando isso um dos seus maiores desafios para uso em jogos.

O modelo de inteligência artificial não supervisionada trabalha com dados não rotulados tornando a mais dinâmica e mais rápida, o problema é que quando se precisa identificar certas coisas, o fato de não haver dados para comparação se torna um impedimento para seu uso eficaz, já que como não a supervisão, não há como saber se aquilo é certo ou errado.

Já o modelo de aprendizado por reforço é o ideal para dar mais vida a jogos e adicionar mais dinâmica, como esse modelo com um agente que está aprendendo a todo momento com novas experiências, recompensas e punições. O problema é que isso leva

tempo, um tempo que em alguns jogos pode ser muito precioso, além da dificuldade no desenvolvimento desse agente, decidindo como ele vai ser recompensado ou punido.

8 Resultados e Discussões

Depois de toda pesquisa foi possível observar que a IA vem sendo usada em jogos a anos e a cada ano ela vem evoluindo mais, de modo que o sucesso de muitos jogos é devido ao grande sucesso que muitos jogos tiveram só de implementar essas tecnologias.

De modo que essa é uma área que só demonstra crescimento exponencial, o que pode levar o uso dessas tecnologias a se tornar algo atual entre todas as desenvolvedoras e não só as maiores empresas, criando assim uma área no mercado de jogos.

Essas tecnologias também são usadas de diversas formas em diversos jogos, alguns jogos usam uma tecnologia para sanar uma necessidade dele, mesmo que ele poderia estar usando outra para aquilo, já que mesmo que a dele funcione ele poderia estar usando uma outra que torne isso eficiente.

Também é notável como cada uma delas são usadas da melhor forma possível de seu jeito, de modo que mesmo tecnologias relativamente parecidas não são usadas para fazer a mesma coisa, já que mesmo que essas tecnologias sejam parecidas, colocar elas para fazerem o mesmo processo seria ineficiente.

9 Conclusões

Com o objetivo de identificar como as tecnologias de IA supervisionada, não supervisionada e aprendizado por reforço vem sendo usada em jogos, podemos entender como cada uma delas funciona e como é implementada nos jogos e porque é implementada.

Também foi possível identificar as dificuldades e restrições de cada uma delas, afinal mesmo elas sendo usadas para seus princípios, ainda há dificuldades e restrições que impedem que as vezes ela alcance seu melhor uso.

Além de ser possível identificar como cada uma dessas tecnologias funcionam aumentando a compreensão de cada uma delas, mostrando suas capacidades e suas limitações, o que aumentou um entendimento sobre essas tecnologias.

Elas demonstraram ser uma área de estudo interessante que vem crescendo desde a década de 50 quando surgiu o termo inteligência artificial tendo grande influência pela cultura pop e contemporânea, com o tempo ela cresceu na indústria de jogos, começando com coisas simples e depois se expandindo até o que temos agora, também foi possível identificar que a indústria só demonstra um crescimento ainda maior nesta área, mostrando que o futuro da IA em jogos tem um potencial bom e infinito.

Agradecimentos

Gostaríamos de agradecer primeiramente ao falecido professor José Alexandre Ducatti, por ter dado o incentivo necessário e apoiado essa ideia no começo. Também gostaríamos de agradecer o professor José Aguiar Viana por ter nós ajudado e orientado nessa caminhada, além de agradecer os membros da banca Adriano Luís Simonato e Matheus Amaro Santos.

Referências

BROCKMAN, Greg et al. **OpenAI Five**. OpenAI Blog, 2019. Disponível em: <https://openai.com/research/openai-five>. Acesso em: 6 nov. 2024.

BUCHANAN, B. G.; SHORTLIFFE, E. H. Rule-based expert systems: **The MYCIN experiments of the Stanford heuristic programming project**. Reading: Addison-Wesley, 1984.

DATASCIENCEDOJO. **Machine learning 101: The types of ML explained**. Disponível em: <https://datasciencedojo.com/blog/machine-learning-101/>. Acesso em: 8 nov. 2024.

FILHO, Alexandre Roberto Gobete; FILHO, João de Lucca. **Interface tecnológica: algoritmos de IA em jogos**. FATEC, 2022. Disponível em: <https://revista.fatectq.edu.br/interfacetecnologica/article/view/1546/814>. Acesso em: 7 out. 2024.

GUITARRARA, Paloma. "**Inteligência artificial**"; Brasil Escola. Disponível em: <https://brasilecola.uol.com.br/informatica/inteligencia-artificial.htm>. Acesso em 23 de junho de 2024.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Cambridge: MIT Press, 2016.

JENNI AI. **Decodificando a IA: Uma linha do tempo de seu desenvolvimento e implicações futuras**. 2023. Disponível em: <https://jenni.ai/>. Acesso em: 7 out. 2024.

KISHIMOTO, André. **Inteligência artificial em jogos eletrônicos**. 2004. Disponível em: <https://edisciplinas.usp.br/>. Acesso em: 7 out. 2024.

LOPES, Rafael A. S.; BRAGA, Victor Guerresi de Mello. **Um Sistema para o Aprendizado Automático de Jogos Eletônicos baseado em Redes Neurais e Q-Learning usando Interface Natural**. 2017. 45 v. TCC (Graduação) – Curso de Ciência da Computação, Universidade de Brasília, Brasília, 2017.

MOTA, Ícaro da Costa. **Aprendizagem por reforço utilizando Q-Learning e redes neurais artificiais em jogos eletrônicos**. 2018. 50 f. TCC (Graduação) – Curso de Engenharia de Controle e Automação, Universidade de Brasília, Brasília, 2018.

MUREL, Jacob; KAVLAKOGLU, Eda. **What is reinforcement learning?** IBM, 2024. Disponível em: <https://www.ibm.com/cloud/learn/reinforcement-learning>. Acesso em: 23 jun. 2024.

OLIVEIRA, Gabriel Pacheco de. **Métodos de Inteligência Artificial aplicados em jogos baseados em turnos**. 2018. 1 v. TCC (Graduação) – Curso de Ciência da Computação, Universidade Federal de Uberlândia, Uberlândia, 2018.

OLIVEIRA, Marcos de Souza; LOPES, Murilo Cruz. **Inteligência artificial: passado, aplicações atuais e futuro**. 2024. Inatel. Disponível em: <https://inatel.br/noticias/inteligencia-artificial-passado-aplicacoes-atuais-e-futuro>. Acesso em: 16 nov. 2024

RUSSELL, Stuart; NORVIG, Peter. **Artificial Intelligence: A Modern Approach**. 3. ed. Upper Saddle River: Prentice Hall, 2010.

SILVA, Andressa. **A EVOLUÇÃO DA INTELIGÊNCIA ARTIFICIAL E SEUS IMPACTOS AO LONGO DOS ANOS**. São Paulo, 07 jul. 2024. Disponível em: <https://revistaft.com.br/a-evolucao-da-inteligencia-artificial-e-seus-impactos-ao-longo-dos-anos/>. Acesso em: 16 nov. 2024

SUTTON, Richard S.; BARTO, Andrew G. **Reinforcement Learning: An Introduction**. 2. ed. Cambridge: MIT Press, 2018.

UNIVERSITY OF YORK. **What is reinforcement learning?** University of York, 2024. Disponível em: <https://online.york.ac.uk/reinforcement-learning/>. Acesso em: 23 jun. 2024.

WILSON, Alex. **Supervised Learning vs Unsupervised Learning vs Reinforcement Learning**. Try Machine Learning, 2019. Disponível em: Supervised Learning vs Unsupervised Learning vs Reinforcement Learning - Try Machine Learning Acesso em: 8 nov. 2024.