

Explicando o processo de tomada de decisão de uma máquina em problemas recorrentes

T. V. da Silva Pener, M. A. Fragoso, Marcelo Scavone D. R, L. Augusto da Silva

Faculdade de Computação e Informática – Universidade Presbiteriana Mackenzie
Caixa Postal 01302-907 – São Paulo – SP - Brasil

tiagopeners14@gmail.com, mathamofra@hotmail.com,
marceloscavonedr@gmail.com, leandroaugusto.silva@mackenzie.br

Abstract. *This work aimed to study the evolution of machine learning and its direct contribution to real problems, using the processing capacity of machines in favor of humans in a given applied universe. Therefore, in this work an algorithm capable of playing chess was developed based on the Minimax method to exemplify in a practical way how to optimize the human learning process. The results obtained allowed us to conclude that it is possible to explain the decision making of an algorithm and interpret it to solve recurrent problems in society, not only in the context of chess.*

Keywords: *Chess, Explainable Artificial Intelligence, Minimax, human learning, processing capacity of machines*

Resumo. *Este trabalho teve por objetivo estudar a evolução do aprendizado de máquina e sua contribuição direta para problemas reais, utilizando a capacidade de processamento das máquinas em favor humano em determinado universo aplicado. Portanto, neste trabalho foi desenvolvido um algoritmo capaz de jogar xadrez baseando-se no método Minimax para exemplificar de forma prática como pode-se otimizar o processo de aprendizado humano. Os resultados obtidos permitiram concluir que é possível realizar a explicação da tomada de decisão de um algoritmo e interpretá-lo a fim de resolver problemas recorrentes em toda sociedade, não só no âmbito do xadrez.*

Palavras-chave: *Xadrez, Inteligência Artificial Explicável, Minimax, aprendizado humano, capacidade de processamento das máquinas*

1. Introdução

O entendimento do comportamento e dinâmica em um algoritmo de aprendizado de máquina, para avaliação e resolução de problemas, pode ser um dos próximos passos para o avanço em diversos âmbitos da civilização atual. Existem inúmeras técnicas capazes de chegar a uma conclusão plausível como solução, através de regras lógicas aplicadas a determinado conjunto de informação (BEDNARZ;WELLS, 2021).

É observado também, que novos caminhos estão sendo trilhados para sanar problemas já existentes, estes que demorariam anos para que algum humano encontrasse, em função da sua limitação de processamento para avaliação de cenários. (MCKINSEY, 2018). Um contexto prático em que há a ocorrência desses fenômenos, é

a Inteligência Artificial aplicada ao jogo de Xadrez. Alguns estudos estão apontando o uso desses algoritmos para otimização de tarefas humanas; em seus estudos, Devleena Das e Sonia Chernova realizaram um teste, no qual após diversas simulações de resultados de jogos de xadrez praticados por uma máquina e apresentado a humanos, eles aplicaram as sugestões da máquina em suas partidas pessoais. Após a coleta de resultados, foi inferido que a eficiência do jogador aumentou, uma vez que foi realizada a combinação da saída da máquina, com o conhecimento adicional de um especialista em xadrez. A utilização do algoritmo no processo de aprendizado, e o entendimento de seu processo de tomada de decisão, foram capazes de melhorar estatisticamente o desempenho dos jogadores em comparação com outros participantes do estudo que praticavam o mesmo número de jogos, mas não recebiam as saídas da máquina e não entendiam seu processo de tomada de decisão (DAS;CHERNOVA, 2020). Portanto, entender os processos da lógica utilizada por traz da resolução do problema, tem influência benéfica nas soluções de tarefas realizadas por humanos.

1.1 Contextualização e Relevância do Tema

A Inteligência Artificial e sua evolução no aprendizado de máquina abrem um universo de múltiplas possibilidades de desenvolvimento, em função do seu aumento na capacidade de processamento, combinado com o grande conjunto de dados disponíveis. A quantidade de dados gerados, tanto por humanos quanto por máquinas, supera em muito a capacidade dos humanos de absorver, interpretar e tomar decisões complexas com base na análise deles. O aprendizado de máquina é a base para o futuro da maior parte de tomadas de decisão complexas. Como exemplo, a maioria das pessoas pode descobrir, após rápida análise, como não perder no jogo da velha, mesmo que haja mais de 200 mil movimentos únicos, dos quais 46.080 terminam em empate, porém não conseguem descobrir com máximo de eficiência e rapidez o melhor caminho com base em análises estatísticas. A mesma lógica aplicada ao jogo de xadrez, torna variável a possibilidade de acerto de um humano, uma vez que as possibilidades de combinações de lances são inúmeras.

Os computadores são extremamente eficientes no cálculo dessas combinações e permutações para chegar à melhor decisão, de modo que os humanos compreendam e aprendam com a respectiva ação aplicada, agregando no entendimento ordinário por meio do aprendizado de máquina.

1.2. Objeto de Pesquisa

1.2.1 Contextualização do Problema de Pesquisa

O desenvolvimento de novas técnicas através de aprendizado de máquina para resolução de problemas que ocorrem frequentemente está ganhando destaque, uma vez que temos uma possibilidade de teste de cenários para avaliação muito maior do que um humano seria capaz de fazer. (HOLZINGE, 2020)

Entendendo como esses novos padrões são definidos, é possível otimizar processos e tomadas de decisões no âmbito computacional e humano.

Neste contexto, a pergunta respondida nesta pesquisa é:

- Como um algoritmo de aprendizagem de máquina aplicado ao âmbito de xadrez encontra e explica padrões na resolução de problemas recorrentes?

1.2.2 Hipótese

Nos últimos anos tivemos um salto tecnológico nunca visto anteriormente na história. Em seu bojo, tal evolução trouxe consigo o desenvolvimento constante de vários campos da Inteligência Artificial e diferentes formas de resolver problemas utilizando o aprendizado de máquina como ferramenta central (BEDNARZ;WELLS, 2021). Conquanto, a hipótese desenvolvida em torno do problema central de pesquisa levantado no presente trabalho, faz referência a possibilidade de otimizar o aprendizado humano através da absorção e entendimento da resolução para diferentes problemas utilizadas por algoritmos de inteligência artificial. Apoiando-se na tese de (MARQUES, 2020), partiu-se da ideia de que com o desenvolvimento dessas novas técnicas e a explicação de como ela foi desenvolvida através de algoritmos lógicos, existe a possibilidade de replicação e escalabilidade para melhorar processos de aprendizado humano.

1.3 Objetivos do Estudo

O presente trabalho teve por objetivo entender o processo de tomada de decisão de uma máquina e sua recomendação de ação após a análise de um conjunto de dados gerados por partidas de xadrez. Assim, inferiu-se como pode ser feita de forma automatizada a explicação da resolução sugerida pelo algoritmo.

1.3.1 Objetivo Geral

Para que seja possível encontrar e explicar a resolução dos problemas solucionados pelas máquinas, foi necessário entender como uma máquina “pensa” para escolher entre a opção A, B ou C. Precisou-se, portanto, ter bem claro quais são os fluxos e ponderações de uma decisão para entendermos o porquê aquela é a melhor opção em determinado contexto, para podermos, assim, replicar esse entendimento na resolução de problemas análogos para o aprendizado humano.

1.3.2 Objetivos Específicos

Para sustentar a pergunta desta pesquisa, foi necessário fazer a apresentação de alguns pontos que expressam e explicam as decisões das máquinas.

Para isso, foi apresentada a importância do xadrez e como a sua história teve impacto na descoberta de novas técnicas de aprendizagem de máquina, salientando, principalmente, a relevância do jogo na descoberta de novos padrões, como apontado por (ESMENGER, 2011).

Portanto, foi desenvolvido um algoritmo para simular partidas de xadrez através de determinada posição e gerar uma saída de pontuação, junto a uma explicação básica do motivo de determinado lance ser sugerido. Mapeado a sugestão do melhor lance, junto a pontuação do tabuleiro e a explicação do caminho encontrado pelo algoritmo, tem-se uma combinação de elementos que contribui substancialmente para resolução e entendimento de problemas análogos no âmbito do xadrez.

1.4 Justificativa

Um fato acordado nos últimos tempos gira em torno da capacidade de processamento das máquinas serem imensamente superiores à de seres humanos. Entretanto, a gama de

possibilidades de testes através de computadores como ferramenta, aumenta positivamente. Existindo o cenário de maior exploração e teste de soluções razoáveis e otimizáveis para a humanidade, encontrar novas soluções é só questão de tempo (BEDNARZ;WELLS, 2021). Através do entendimento do processo de tomada de decisão de algoritmos e a agregação deste conhecimento processado no aprendizado humano, novas descobertas podem ser reutilizadas em diferentes problemas, replicando uma resolução inovadora e já testada (DAS;CHERNOVA, 2020).

1.5 Organização do Estudo

Este projeto de Trabalho de Conclusão de Curso (TCC) foi organizado conforme os capítulos descritos a seguir: Além deste capítulo 1, de Introdução, têm-se ainda os capítulos descritos na sequência. No Capítulo 2, encontra-se a fundamentação teórica onde pretendemos abordar dois temas centrais: xadrez e inteligência artificial. Para uma maior compreensão do nosso problema, foi preciso compreender a respeito de alguns temas, sendo esses: funcionamento de uma inteligência artificial, técnicas de interpretação de códigos e modelos, regras e histórias do xadrez e, por fim, a aplicação prática de casos reais de aprendizado de máquina para entendimento das particularidades de problemas distintos e como eles se relacionavam. No Capítulo 3, está presente a metodologia de pesquisa, onde está explícito quais foram as etapas de pesquisa, mostrando como foi elaborado todo o processo de entendimento do problema e desenvolvimento de técnicas para dar uma resposta a hipótese do estudo.

2. Referencial Teórico

2.1 Explicação da IA e do reforço da aprendizagem - Uma revisão sistemática das abordagens e tendências atuais

Inteligência Artificial Explicável (XAI) é uma área crescente de pesquisa e está rapidamente se tornando um dos subtópicos mais pertinentes da Inteligência Artificial (IA).

A pesquisa em Inteligência Artificial Explicável (XAI) tem aumentado como uma resposta à necessidade de maior transparência e confiança na IA. Isso é particularmente importante porque a IA é usada em domínios sensíveis com implicações sociais, éticas e de segurança em grande escala, com sistemas para direção autônoma, simulações meteorológicas, diagnóstico médico, reconhecimento de comportamento, gêmeos digitais, reconhecimento facial, otimização de negócios e segurança são apenas alguns a serem citados. (BEDNARZ;WELLS, 2021)

Com essa sensibilidade aumentada, surgem questões inevitáveis de confiança, preconceito, responsabilidade e processo, ou seja, como a máquina chegou a uma determinada conclusão?

Essas preocupações surgem do fato de que, geralmente, a parte mais popular e potencialmente mais poderosa da IA, aprendizado de máquina, é essencialmente uma caixa preta, por exemplo com entrada de dados em uma rede neural treinada, que então produz uma classificação, decisão ou ação. Os algoritmos chegam ser difíceis de entender ou interpretar até mesmo pelos cientistas de dados, embora a arquitetura e a matemática envolvidas sejam bem definidas, muito pouco se sabe sobre como

interpretar, quanto mais explicar, o estado interno da rede neural. (BEDNARZ;WELLS, 2021)

Esse cenário de caixa preta torna difícil para os usuários finais confiarem no sistema com o qual estão interagindo, quando um sistema de IA produz uma saída inesperada, essa falta de confiança resulta em rejeição por parte do usuário final, esses erros podem ter efeitos colaterais consideráveis, como comportamentos inseguros resultantes em fábricas devido a classificação incorreta, tratamento injusto de membros da sociedade, ações ilegais ou impacto financeiro em empresas que empregam soluções de IA.

A pesquisa XAI no contexto de aprendizado de máquina e (*deep learning*) (*DL*) visa olhar dentro dessa caixa preta e extrair informações ou explicações de porque o algoritmo chegou à conclusão ou ação que fez, além de fornecer ferramentas para auxiliar na confiança e responsabilidade, o XAI auxilia na depuração e polarização no aprendizado de máquina.

As entradas e saídas e o design de rede dos algoritmos de aprendizado de máquina ainda são decididos com a entrada humana e, por conta disso, estão frequentemente sujeitos a erros humanos. Explicações de algoritmos habilitados para XAI podem descobrir possíveis falhas ou problemas, o XAI visa resolver esses problemas, proporcionando ao usuário final mais confiança na máquina.

A aprendizagem por reforço difere da aprendizagem supervisionada (consiste em aprender uma função que mapeia uma entrada para uma saída com base em pares de entrada-saída de exemplo). Na aprendizagem supervisionada os dados de treinamento têm a chave de resposta, de modo que o modelo é treinado com a própria resposta correta, enquanto que na aprendizagem por reforço não há resposta, mas o agente de reforço decide o que fazer para realizar a tarefa dada e, se não houver um conjunto de dados de treinamento, ele aprenderá com sua experiência. (BEDNARZ;WELLS, 2021)

O XAI busca combater as questões de confiança e segurança na IA, um tópico que é particularmente importante. Aplicações como veículos autônomos ou robótica, onde o robô faz observações do ambiente ao seu redor e realiza ações, as quais, o resultado pode ter impacto na segurança são de incrível importância para estudos futuros.

Saber por que um robô executou a ação que executou e, saber quais fatores ele considerou de uma forma compreensível para os humanos desempenha um grande passo na construção da confiança de que o robô está de fato tomando decisões inteligentes e seguras, podendo levar à construção de um relacionamento saudável com o robô, o qual torna o trabalho com ele mais eficiente, pois seus comportamentos podem se tornar mais previsíveis. (BEDNARZ;WELLS, 2021)

Diagnosticar o que deu errado quando um robô ou carro autônomo está envolvido em um incidente também se beneficiaria do XAI, onde seria possível consultar a máquina sobre porque ela tomou medidas antes do incidente, o que permitiria evitar mais incidentes.

Um desafio em fornecer XAI para para aprendizado por reforço é que geralmente envolve um grande número de decisões tomadas ao longo de um período de tempo, muitas vezes com o objetivo de fornecer a próxima ação em velocidades de tempo real. Em comparação com as técnicas de ML padrão, em que as decisões podem

acontecer isoladamente ou não relacionadas entre si, as explicações de AR (Aprendizado por Reforço) geralmente precisam abranger um conjunto de ações que estejam relacionadas de alguma forma (exemplo: dar explicações do porquê "Eu fiz as ações X, Y, Z para evitar a pena F").

(BEDNARZ;WELLS, 2021)

Outro desafio é o fato de que os agentes AR são geralmente treinados sem usar dados de treinamento, a aprendizagem é facilitada por um ciclo de feedback (observações) a partir de ações dentro de um ambiente, o que torna difícil gerar explicações legíveis por humanos. Embora os espaços de observação e ação possam ser rotulados de forma sensata, não ter dados de treinamento rotulados por ação humana ligando ações e observações torna difícil a criação de explicações válidas. (BEDNARZ;WELLS, 2021).

2.2 Métodos de Inteligência Artificial explicada, uma breve visão geral

Nos últimos anos, o aprendizado de máquina (ML) tornou-se muito bem-sucedido e influenciou fortemente a inteligência artificial (IA). Modelos sofisticados têm aumentado constantemente em complexidade, o que muitas vezes aconteceu às custas da interpretabilidade humana. Por conta disso, um campo de pesquisa chamado IA explicável (XAI) surgiu com o objetivo de criar ferramentas e modelos que sejam mapeáveis e interpretáveis para os humanos.

Desde aplicações em transformação digital (por exemplo: agricultura, clima, operações florestais, aplicações médicas, ferramentas de automação e robótica, etc.), há agora a necessidade de se envolver de maneira mais intensa em novos cenários, como explicar o aprendizado não supervisionado, e criar explicações que são estruturadas de maneira ideal para os tomadores de decisão humanos. Embora a IA explicável trabalhe com a implementação da transparência de métodos estatísticos de ML de caixa preta, há uma necessidade de ir além da IA explicável, por exemplo, medir a qualidade das explicações e encontrar soluções para a construção de interfaces Humano-IA eficientes para essas novas interações entre inteligência artificial e inteligência humana.

Para certas tarefas, o aprendizado de máquina interativo com o humano no circuito pode ser vantajoso porque um especialista em domínio humano as vezes pode complementar a IA com conhecimento, tal humano no circuito poderia contribuir para uma inteligência artificial com experiência e consciência de contexto, se concretizado, poderia ser usado para criar modelos estruturais de tomada de decisão humana.

O sucesso do aprendizado de máquina estatístico a partir de big data, especialmente de *deep learning* (DL), tornou a inteligência artificial muito popular. Na última década, o DL revigorou a pesquisa de aprendizado de máquina, mostrando seu poder de aprender com grandes quantidades de dados para resolver tarefas complexas, tornando a IA popular, muitas vezes até além do desempenho do nível humano. No entanto, os modelos de DL são compostos de milhões de parâmetros e, sua alta complexidade torna esses modelos de “caixa preta” desafiadores para a compreensão humana.

Como essas abordagens de “caixa preta” são cada vez mais aplicadas a domínios de alto impacto e alto risco, como IA médica ou direção autônoma, o impacto de suas falhas também aumenta (por exemplo: diagnósticos médicos incorretos, colisões de

veículos etc.). Devido a isso, há uma demanda crescente de ferramentas diversificadas de métodos que ajudem pesquisadores e profissionais de IA a projetar e entender modelos complexos.

Com base no aumento da aplicação da IA em praticamente todos os domínios (por exemplo: agricultura, clima, saúde, sustentabilidade, etc.), há também a necessidade de abordar novos cenários no futuro, por exemplo, explicando o aprendizado não supervisionado. Embora a IA explicável esteja essencialmente preocupada com a implementação de transparência de métodos estatísticos de ML de caixa preta, haverá uma grande necessidade no futuro de ir além da IA explicável, por exemplo, estender a IA explicável para incluir causalidade e medir a qualidade das explicações.

Para certas tarefas, um humano no circuito pode ser benéfico, porque esse especialista humano pode as vezes aumentar a IA com conhecimento, ou seja, contribuir para uma IA com experiência humana. Nós humanos podemos integrar novos insights conquistados por nossas experiências e temos a habilidade de generalizar a partir de exemplos, isso poderia ser usado para construir modelos de tomada de decisão humana, e os recursos podem ser rastreados para treinar a IA.

Em domínios de aplicação tão sensíveis e críticos para a segurança, haverá uma necessidade crescente de soluções de IA confiáveis no futuro. A IA confiável deve ser equilibrada com valores humanos, princípios éticos e requisitos legais, para garantir privacidade, segurança e proteção.

Há alguns métodos de IA Explicável que estão sendo estudados nos últimos anos, dentre eles podemos citar: XGNN (Explainable Graph Neural Networks) e TCAV (Testing with Concept Activation Vectors). O XGNN é um método que opera no nível do modelo, o que significa que ele não se esforça para fornecer explicações individuais no nível do exemplo, o aprendizado por reforço conduz uma busca para encontrar um gráfico adequado começando por um nó escolhido aleatoriamente ou um gráfico pré-definido. Este método de explicação é inventado especialmente para a tarefa de classificações gráficas, os gráficos retornados são os que foram mais representativos para a decisão do GNN (Graph Neural Networks) e geralmente possuem alguma propriedade particular. A explicação fornecida é considerada mais eficaz para grandes conjuntos de dados, onde humanos não têm tempo para verificar a explicação de cada exemplo individualmente. (HOLZINGER; GOEBEL; FONG; MOON; MULLER; SAMEK, 2020).

O método TCAV (Testing with Concept Activation Vectors), é uma abordagem de rede neural baseada em conceito que visa quantificar a intensidade com que um conceito, como por exemplo cor, influencia a classificação. O TCAV é baseado na ideia de vetores de ativação de conceito (CAV), que descrevem como as ativações neurais influenciam a presença ou ausência de um conceito específico do usuário. Para calcular tal CAV, dois conjuntos de dados devem primeiro ser coletados e combinados: um conjunto de dados contendo imagens que representam o conceito e, um conjunto de dados composto por imagens nas quais esse conceito não está presente. Em seguida, um modelo de regressão é treinado no conjunto de dados combinado para classificar se o conceito está presente em uma imagem, as ativações da camada da rede neural servem como recursos para o modelo de classificação e, os coeficientes do modelo de regressão

são então os CAVs. (HOLZINGER; GOEBEL; FONG; MOON; MULLER; SAMEK, 2020).

Por exemplo, para investigar o quanto o conceito “listrado” contribui para a classificação de uma imagem como “zebra” por uma rede neural, devendo ser montado um dataset representando o conceito “listrado” e um dataset aleatório em que o conceito “listrado” não está presente. A partir dos CAVs, pode-se calcular a sensibilidade conceitual, a qual indica, portanto, quão forte a presença de um conceito contribui para a classificação.

2.3 O Uso dos Racionais Para Otimização das Tarefas Humanas

O desempenho obtido por aprendizado de máquina e IA tem surpreendido muito pela sua geração de resultados precisos. Em função disso, ergueu-se o seguinte questionamento: é possível que resultados oriundos de Inteligência Artificial possam ser ‘racionalizados’, ou seja, convertidos em estruturas compreensíveis a humanos, com intuito de otimizar suas atividades ordinárias? Uma das respostas para essa pergunta está dentro dos sistemas XAI (nicho de estudos sobre IA Explicável), mais especificamente, com o emprego do Algoritmo Gerador de Racionais (RGA). (DAS;CHERNOVA, 2020)

Primeiramente, é necessário compreender que Racionais são definidos como explicações de linguagem natural que não exponha literalmente o funcionamento interno de um sistema inteligente, mas, em vez disso, forneça uma linguagem natural contextualmente apropriada.

O estudo da geração do RGA será feito a partir de partidas de xadrez. Em suma, a abordagem assumida demonstra que lógicas geradas automaticamente a partir de um modelo de tarefa interna de IA podem ser usadas não apenas para explicar o que o sistema está fazendo, mas também para instruir os usuários de uma maneira que aprimore suas próprias tarefas e desempenho na ausência de justificativas usuais.

Um dos *inputs* do RGA é uma função de utilidade, que é como uma soma ponderada de todas as variáveis usadas para decidir uma saída. Dentro do RGA, a função de utilidade é decomposta para identificar os fatores significativos que contribuem para a seleção de novas ações. Outro *ponto* é o *domain knowledge*, que se trata da base de conhecimento sobre a atividade analisada pela IA. (DAS;CHERNOVA, 2020)

O algoritmo RGA, nesse estudo de caso, é aplicado em um cenário restrito de uma partida de xadrez, justamente um cenário de final de jogo em que a tomada de decisão é crucial para um resultado, e há uma quantidade relativamente pequena de movimentos.

Após as simulações e apresentações dos resultados aos participantes, estes aplicaram as sugestões da IA em partidas de xadrez pessoais. Os resultados mostraram que os fundamentos do RGA são mais eficientes quando as informações retornadas pelo algoritmo são combinadas com conhecimento adicional de um especialista no respectivo domínio, no caso xadrez. O algoritmo foi capaz de melhorar estatisticamente o desempenho do usuário no xadrez em comparação com os participantes do estudo que

praticavam o mesmo número de jogos, mas não recebiam justificativas por parte de especialistas. Apenas demonstrar aos participantes a ação ideal sem uma justificativa do raciocínio não produziu os mesmos resultados, indicando a importância de lógicas interpretáveis na elucidação da tarefa. (DAS;CHERNOVA, 2020)

2.4 Notas dos entendimentos da fronteira de Inteligência Artificial em centenas de casos de uso

Como já mencionado nos referenciais iniciais, a Inteligência Artificial está sendo amplamente utilizada em diferentes áreas do conhecimento. Para entender tal evolução, a consultoria McKinsey mapeou como diferentes técnicas de aprendizagem de máquinas foram usadas para resolver mais de 400 problemas em diferentes empresas. (MCKINSEY, 2018).

Para deixar claro como os casos foram resolvidos e como de fato pode-se tirar valor da inteligência artificial, o papel de discussão foi dividido em quatro tópicos principais.

O primeiro tópico tem por objetivo deixar claro quais tipos de técnica, principalmente de *deep learning*, são capazes de resolver quais tipos de problemas e como podemos usá-las para tirar valor de suas aplicações. Assim, foram analisados o uso de três técnicas primordiais para o desenvolvimento de redes neurais: Feed Forward Network (FFN), Recurrent Neural Networks (RNNs) e Convolutional Neural Networks (CNNs).

Em seguida, McKinsey apresentou mais de 400 casos de uso em mais de 19 tipos de indústria como: agricultura, sistema bancário, sistema de saúde, turismo entre outros. Dessa forma, conseguimos entender como as diferentes técnicas de aprendizado profundo podem ser usadas de maneiras similares e mesmo assim resolver problemas distintos. Aqui, foi criado também um mapa de calor para que pudéssemos saber quais tipos de técnicas estão mais sendo usadas nos setores. (MCKINSEY, 2018).

Depois de apresentado os casos de uso, foi mostrado o verdadeiro potencial da Inteligência Artificial e o quanto isso vêm trazendo de impacto econômico positivo para as empresas que decidem desfrutar de seu uso. Podemos observar que as maiores oportunidades de aplicação (onde poderemos tentar replicar algumas das técnicas estudadas no nosso estudo de caso do xadrez) são: marketing, vendas e sistemas bancários etc. (MCKINSEY, 2018).

Portanto, por mais que a Inteligência Artificial esteja superdesenvolvida, ela ainda tem algumas limitações e, por isso, precisará superar alguns desafios. Alguns desses principais desafios são: conseguir fazer a classificação de dados desconhecidos; obter conjuntos de dados que consigam representar uma compreensão geral do problema; conseguir apresentar a explicação do processo de tomada de decisão; conseguir replicar técnicas já aprendidas em novos modelos. (MCKINSEY, 2018).

2.5 Inteligência Artificial: aplicação do algoritmo *Minimax* em um jogo de xadrez

Para melhor compreender o algoritmo Minimax, será percorrido em duas etapas sendo a primeira o entendimento teórico e estático do jogo de xadrez e por conseguinte a

compreensão de como o aplicativo Minimax é empregado para definição de melhores jogadas a partir da avaliação de determinada posição no tabuleiro. Em primeira instância, aborda-se alguns conceitos básicos do xadrez, sendo este entre dois adversários que tem como o rei do oponente sob ataque a ponto de não possuir nenhum movimento, dando assim o xeque mate. Estima-se que 605 milhões de pessoas em todo mundo jogam xadrez, de forma profissional e por diversão. Não é certa a origem do xadrez, mas estima-se a forma atual do jogo se iniciou no século XV no sudoeste da Europa, sofrendo algumas alterações até chegar ao modo que conhecemos hoje (ALBUQUERQUE, 2016).

Conforme a tecnologia evoluiu, o xadrez em diversos momentos esteve ao seu lado. É estimado que profissionais dessa área iniciam as primeiras construções de máquinas que possuem a capacidade de jogar xadrez desde 1890 e que os primeiros programas de xadrez foram os pioneiros no desenvolvimento relacionado a Inteligência Artificial, em meados de 1950. (ALBUQUERQUE, 2016).

Entendendo o relacionamento entre o xadrez e a computação, o algoritmo denominado Minimax visa entender qual a “melhor jogada” da posição do tabuleiro. Ele funciona de forma recursiva de busca, entendendo diferentes consequências de movimentos a fim de encontrar a melhor. O princípio básico é aumentar as possibilidades de vitória a partir de determinado movimento jogado no tabuleiro. (ALBUQUERQUE, 2016).

Em segunda instância, faz-se necessário a compreensão de como o algoritmo funciona. O mesmo percorre cinco passos, iniciando sua função a partir do segundo. No primeiro passo temos toda a árvore de jogadas até os estados terminais. No segundo passo é aplicada uma função de avaliação da posição de forma estática em cada um dos nós folhas, a fim de definir se a posição é ou não boa, retornando um valor de saída. Na terceira etapa o algoritmo compara o valor dos estados finais de cada um dos ramos e então determina qual nó subirá um nível da árvore de busca. Na penúltima fase temos o repasse de valores das folhas em direção ao topo, um nível por vez de forma recursiva. Após isso temos a fase final, onde o valor da avaliação atinge a raiz da árvore, sugerindo o melhor movimento da posição a ser realizado. (ALBUQUERQUE, 2016).

Quando trabalhamos com muitos diferentes estados para avaliação, a eficácia do algoritmo Minimax diminui já que é necessário percorrer todos os nós das árvores de jogadas para então definir a escolha final. Assim, junto ao Minimax é recomendado o uso de um algoritmo de poda Alfa Beta, que objetiva ganhar tempo durante a busca dentro da árvore. Nesse algoritmo é feita uma otimização, permitindo que não seja necessária a avaliação de algumas soluções que são descartadas em primeiro momento, podando assim a árvore de jogadas que deve ser percorrida. (ALBUQUERQUE, 2016).

2.6 Como avaliar de forma simplificada as peças no jogo de Xadrez

No jogo de Xadrez, cada peça tem sua função tática e estratégica. Para cada uma, podemos classificar um valor numérico, variando de acordo com a posição no tabuleiro.

De forma prática, é consensual que as avaliações das peças são proporcionalmente fixadas em: Peão = 100, Cavalo = 320, Bispo = 330, Torre = 500, Dama = 900 e Rei = 1000000. (CHESS PROGRAMMING, 2022).

Por padrão, espera-se que os peões avancem para conquistar espaço no tabuleiro. Para peões nas colunas A, B, C, F, G, H: É importante não se mover para garantir a proteção do rei, já que é encorajado o rei a ficar na borda e em segurança. (CHESS PROGRAMMING, 2022).

Para peões nas colunas D, E, caso estejam na casa 2 e 3: É importante mover essas peças pois eles bloqueiam peças-chaves, como bispos e rainhas de se deslocarem de suas posições iniciais. Caso estejam em outras casas: É necessário fazer essa movimentação para que o peão em questão esteja mais ao centro do tabuleiro. (CHESS PROGRAMMING, 2022).

No geral, espera-se que os cavalos conquistem o centro. Também evitar as colunas A, B, F e G, visto que cavalos se movem devagar e estando no centro, movimentos de ataque e defesa são facilitados. (CHESS PROGRAMMING, 2022).

É importante que os bispos estejam longe das bordas e dos cantos. Além disso, são instigados que fiquem principalmente nas colunas C, D, E, F e nas casas 3, 4, 5, 6 pois estando nessas posições centrais do tabuleiro, facilita o seu deslocamento para posições de ataque e defesa. Além de estarem em B3, C4, B5 e D3, visto que nessa posição tendem ter uma vantagem de atacar o rei e dama adversário, e defender essas suas mesmas peças. (CHESS PROGRAMMING, 2022).

As torres precisam em colunas centrais do tabuleiro, evitando as bordas, para facilitar a conquista do território do inimigo e proteger o rei com maior facilidade. Caso estejam na casa 2, ganham ainda mais força pois fazem uma linha de defesa para dama e rei. Se estiverem em D8 ou E8, ganham força por estarem em uma posição central no campo oposto, facilitado o ataque a peças-chaves do adversário. (CHESS PROGRAMMING, 2022).

Por padrão, a posição ideal para a dama é no centro, pois, conseguem controlar mais posições e voltar facilmente para o seu lado do tabuleiro para facilitar a proteção do rei. Caso estejam em B3 ou C2, a dama é encorajada a estar nessa posição para facilitar sua saída inicial e voltar facilmente para a linha de defesa do tabuleiro. Para o rei, ficar nos cantos do tabuleiro, onde pode ser defendido por outras peças com maior facilidade. (CHESS PROGRAMMING, 2022).

2.7 Inteligência artificial explicável para análise de partidas de futebol

O presente referencial apresenta métodos para investigar a influência de técnicas de aprendizado de máquina no futebol e o quanto suas previsões são capazes de moldar novas táticas e olhar para recursos que raramente são tidos como importantes para treinadores, preparadores e jogadores.

Por mais que haja diversos estudos que concluam que as máquinas não sejam uma maneira eficaz de medir os eventos que ocorrerão durante uma partida de futebol, não há estudos suficientes que comprovem o porquê de as máquinas não serem precisas na previsão de determinados resultados. Isso se dá principalmente por conta da forma como algoritmos mais complexos são implementados, “cuja eficácia é atingida às custas da perda de interpretabilidade”. (MARQUES, 2019)

Com essa falta de interpretabilidade, é avaliado e comparado uma série de modelos preditivos a fim de identificar os fatores mais significativos por trás de uma vitória, empate ou derrota de uma equipe através da tomada de decisão de algoritmos

populares. Para embasar todas as necessidades do estudo, há uma contextualização de como funciona uma partida de futebol e suas principais regras, além de uma discussão, a respeito da aplicação de árvores de decisão, classificadores lineares e técnicas ensemble e sua relação com o conceito de “inteligência artificial explicável”. (MARQUES, 2019).

Dentro do âmbito do futebol, a análise de desempenho das partidas está em crescimento e sendo alvo direto de pesquisas por parte dos clubes de futebol de pessoas que apostam em resultados de partidas. De acordo com o estudo “Investigação centrada na análise do jogo: Da modelação estática à modelação dinâmica”, as análises aplicáveis para determinar os acontecimentos de um jogo de futebol se dividem em trabalhos encontrados em três categorias: análise descritiva, análise comparativa e análise preditiva. Aqui nesse ponto, é importante ressaltar como o tipo de análise que se escolhe para refletir uma partida pode influenciar diretamente a forma como se implementam os algoritmos para avaliar as partidas, e como suas avaliações podem ser interpretadas e explicadas já que cada análise se baseia em um conjunto de especificidade e objetivos diferentes. (MARQUES, 2019).

Para apresentar os resultados de sua pesquisa, uma análise preditiva foi feita através da implementação de modelos aptos a avaliar resultado de três campeonatos (Copa do Mundo, Campeonato de Futebol Feminino dos Estados Unidos e Campeonato de Futebol Feminino da Inglaterra) através de dez métricas capazes de avaliar a qualidade das previsões feitas, as quais foram visualmente expostas, a fim de apresentar, através mecanismos mais interpretáveis, os fatores mais importantes para o resultado de uma partida de futebol.

Através dos resultados, foi possível observar que novas variáveis que geralmente não são vistas com tanta relevância pela maior parte de análises preditivas de futebol, tiveram grandes destaques, tal como total de passes e tempo de recuperação de bola. Essas novas descobertas nos mostram como os algoritmos são capazes de nos mostrar características que os humanos não são capazes de perceber a olho nu. Isso nos abre o alerta de fazer análises mais profundas para essas novas variáveis com o auxílio dos resultados da tomada de decisão da máquina e de também conseguir explicar de maneira humana o porquê dessas novas variáveis terem tanto impacto no resultado dos jogos, para que a organização do time possa usar essas descobertas a seu favor. (MARQUES, 2019).

3. Metodologia

No que tange à metodologia empregada neste TCC, o trabalho teve início com a revisão de assuntos necessários para a compreensão e evolução do tema de pesquisa. Essa revisão abrangeu literaturas dentro do campo de xadrez, inteligência artificial e interpretação de modelos de aprendizagem de máquina.

Essa fundamentação teórica foi pautada em artigos de diversos autores como Eduardo Prates Albuquerque; Nathan Ensmenger; Sonia Chernova; além de pesquisas em periódicos científicos de empresas renomadas e dissertações técnicas.

Após a parte teórica, começa a etapa de desenvolvimento do algoritmo capaz de jogar xadrez. Para isso, utilizamos a linguagem de programação Python e como biblioteca principal, Chess. Foi desenvolvido parâmetros de tabuleiro considerando posições estáticas das peças, podendo classificar em ordem numérica quais são as melhores ou piores posições dentro de determinada partida. Através das técnicas de

mixmax e negamax, foi possível avaliar a combinação desses fatores de forma dinâmica e em uma profundidade de jogo suficiente para chegar a uma solução ótima de lance sugerido durante as simulações de partidas.

Desenvolvido o algoritmo capaz de jogar xadrez, passamos para etapa de automatização da explicação do lance sugerido pela máquina. Esse mapeamento será feito através da coleta e avaliação do conjunto de possibilidades de lances avaliados pelo algoritmo durante a partida.

3.1 Classificação

Em termos de classificação desta pesquisa, segundo os enfoques clássicos de classificação de uma pesquisa científica, entende-se que esta pode ser enquadrada conforme se apresenta na sequência.

Quanto à Natureza, esta foi uma pesquisa Aplicada, já que fizemos o desenvolvimento e teste de nossas hipóteses através de uma simulação do problema em questão.

Quanto à Forma de Abordagem, a pesquisa foi predominantemente quantitativa, mapeando a resolução do problema central de forma aplicada.

Foi uma pesquisa Metodológica por ser pautada em um estudo histórico do xadrez e a importância da explicação da tomada de decisão de algoritmos de aprendizado de máquina.

Para isso, foram utilizados os seguintes recursos: Artigos científicos que abordam o âmbito estudado em diferentes óticas, assim como o entendimento de técnicas fundamentais para resolução do problema.

3.2 Proposta

Tem-se como proposta o desenvolvimento de um algoritmo capaz de jogar xadrez, permitindo o entendimento completo dos parâmetros de avaliação e execução. Com o algoritmo finalizado, almeja-se criar um conjunto de dados das jogadas consideradas durante a definição do melhor lance em determinada posição do tabuleiro. Tendo essas jogadas mapeadas, poderemos limpar o conjunto de dados, trazendo somente a variante principal dos melhores lances avaliados. Através da variante principal, teremos um diagnóstico completo do direcional de tomada de decisão, permitindo a automatização da explicação do lance jogado pela máquina em determinada posição do tabuleiro.

4. Desenvolvimento e resultados

Nesta parte do artigo, apresentam-se as fases e processos trilhados para conclusão do desenvolvimento do algoritmo capaz de jogar xadrez e a automatização da explicação do lance sugerido, assim como a demonstração dos resultados obtidos.

4.1 Desenvolvimento do algoritmo capaz de jogar xadrez

Para compreender todo o processo de tomada de decisão de um algoritmo de xadrez, estabelecemos o objetivo de desenvolver um do zero, possibilitando um caminho mais assertivo na resolução do problema central. Para isso, foi utilizada como linguagem de programação o Python, assim como a chess, a principal biblioteca do projeto, usada para simular um tabuleiro de xadrez e suas principais funções.

Inicialmente, foi necessária a construção de parâmetros estáticos, possibilitando a avaliação quantitativa e qualitativa das peças em determinada posição do tabuleiro. Para a construção desses parâmetros quantitativos e qualitativos, foi usado como referência o modelo de Função de avaliação simplificada proposto pela plataforma (*chess programming*), que reuniu conceitos definidos por jogadores profissionais de xadrez, conforme citado anteriormente no referencial teórico. (CHESS PROGRAMMING, 2022)

Na visão quantitativa, os seguintes parâmetros foram aplicados:

Peão = 100, Cavalo = 320, Bispo = 330, Torre = 500, Dama = 900 e Rei = 1000000

Na qualitativa, é observada além do valor estático das peças, o valor dinâmico considerando sua posição no tabuleiro, conforme descrito abaixo:

```
# Pontuação posicional dos peões
score_peoes = [
    0, 0, 0, 0, 0, 0, 0, 0,
    5, 10, 10, -20, -20, 10, 10, 5,
    5, -5, -10, 0, 0, -10, -5, 5,
    0, 0, 0, 20, 20, 0, 0, 0,
    5, 5, 10, 25, 25, 10, 5, 5,
    10, 10, 20, 30, 30, 20, 10, 10,
    50, 50, 50, 50, 50, 50, 50, 50,
    0, 0, 0, 0, 0, 0, 0, 0
]

# Pontuação posicional das torres
score_torres = [
    0, 0, 0, 5, 5, 0, 0, 0,
    -5, 0, 0, 0, 0, 0, 0, -5,
    -5, 0, 0, 0, 0, 0, 0, -5,
    -5, 0, 0, 0, 0, 0, 0, -5,
    -5, 0, 0, 0, 0, 0, 0, -5,
    -5, 0, 0, 0, 0, 0, 0, -5,
    5, 10, 10, 10, 10, 10, 10, 5,
    0, 0, 0, 0, 0, 0, 0, 0
]

# Pontuação posicional dos cavalos
score_cavalos = [
    -50, -40, -30, -30, -30, -30, -40, -50,
    -40, -20, 0, 5, 5, 0, -20, -40,
    -30, 5, 10, 15, 15, 10, 5, -30,
    -30, 0, 15, 20, 20, 15, 0, -30,
    -30, 5, 15, 20, 20, 15, 5, -30,
    -30, 0, 10, 15, 15, 10, 0, -30,
    -40, -20, 0, 0, 0, 0, -20, -40,
    -50, -40, -30, -30, -30, -30, -40, -50]

# Pontuação posicional da rainha
score_rainha = [
    -20, -10, -10, -5, -5, -10, -10, -20,
    -10, 0, 0, 0, 0, 0, 0, -10,
    -10, 5, 5, 5, 5, 5, 0, -10,
    0, 0, 5, 5, 5, 5, 0, -5,
    -5, 0, 5, 5, 5, 5, 0, -5,
    -10, 0, 5, 5, 5, 5, 0, -10,
    -10, 0, 0, 0, 0, 0, 0, -10,
    -20, -10, -10, -5, -5, -10, -10, -20]

# Pontuação posicional dos bispos
score_bispos = [
    -20, -10, -10, -10, -10, -10, -10, -20,
    -10, 5, 0, 0, 0, 0, 5, -10,
    -10, 10, 10, 10, 10, 10, 10, -10,
    -10, 0, 10, 10, 10, 10, 0, -10,
    -10, 5, 5, 10, 10, 5, 5, -10,
    -10, 0, 5, 10, 10, 5, 0, -10,
    -10, 0, 0, 0, 0, 0, 0, -10,
    -20, -10, -10, -10, -10, -10, -10, -20]

# Pontuação posicional do rei
score_rei = [
    20, 30, 10, 0, 0, 10, 30, 20,
    20, 20, 0, 0, 0, 0, 20, 20,
    -10, -20, -20, -20, -20, -20, -20, -10,
    -20, -30, -30, -40, -40, -30, -30, -20,
    -30, -40, -40, -50, -50, -40, -40, -30,
    -30, -40, -40, -50, -50, -40, -40, -30,
    -30, -40, -40, -50, -50, -40, -40, -30,
    -30, -40, -40, -50, -50, -40, -40, -30]
```

Figura 1 - Valor posicional das peças no tabuleiro

Após a construção matricial desses parâmetros avaliativos, é vinculada uma função capaz de gerar um score para a posição atual, possibilitando futuramente medir de forma recursiva qual o resultado após determinada cadeia de lance ser executada.

Para percorrer as posições de forma recursiva e obter o melhor resultado possível, foi utilizado o negamax, variante secundária do famoso algoritmo de minimax. Com o negamax, na árvore de jogadas, a perda de um jogador é o ganho do outro, sendo ideal para avaliação em jogos de 2 pessoas, como é no jogo de Xadrez. Na sequência, a esquematização do funcionamento do miximax:




Figura 2 - Representação do funcionamento do minimax

Após avaliar de forma recursiva quais os melhores lances para cada jogador, o algoritmo define a melhor jogada na posição atual do tabuleiro e o executa.

Definiu-se também, que o minimax é aplicado para uma profundidade 4. Ao final de toda recursividade, será avaliada a posição final do tabuleiro, indicando se essa jogada atual que está sendo feita, pode ou não afetar positivamente a partir do lance atual a ser jogado.

5. Tipos de movimentos e a automatização de sua explicação

Para explicação do lance sugerido e jogado pela máquina, será necessária a utilização da biblioteca Pandas. Através dessa biblioteca, é construído um dataframe com as jogadas avaliadas durante a recursividade do negamax, possibilitando medir de forma quantitativa cada uma delas. Tendo as jogadas e a avaliação do tabuleiro em mãos, a cadeia de melhores jogadas é mapeada, trazendo como explicação somente os lances que importam.

A partir variante principal, é realizada uma conversão textual da sequência de movimentos avaliadas pelo algoritmo, trazendo uma explicação sintetizada do processo de tomada de decisão para o melhor lance.

Conforme apresentado nas explicações abaixo, os movimentos podem ser classificados de duas formas: movimentos de captura e movimentos táticos.

5.1 Explicação de movimentos táticos e a automatização da explicação

Para que os movimentos possam ser explicados, usamos como parâmetro a casa de saída e de destino das jogadas da cadeia de melhores movimentos. Cada uma das peças possui uma explicação lógica baseada na linha e coluna do tabuleiro que está localizada. A partir disso, o algoritmo de explicação avalia cada uma das peças jogadas e apresenta a motivação da movimentação em questão.



Figura 3 - Tabuleiro sujeito a movimentação f3e5 > c8d7 > d3c4 > d7b5

Para a situação acima, foi jogado f3e5 partindo da ideia de que o oponente jogaria c8d7, portanto, seria necessário responder com d3c4 e a movimentação final do adversário seria d7b5. A explicação dessa sequência se deu da seguinte forma:

[MOVIMENTO TÁTICO] -> d7 para b5 -> Bispos agregam valores extras estando nessa posição do tabuleiro, pois facilitam o acesso ao rei e rainha do adversário

[MOVIMENTO TÁTICO] -> d3 para c4 -> Damas são encorajadas a ficarem no centro pois conseguem controlar mais posições e voltar facilmente para o seu lado do tabuleiro para facilitar a proteção do rei.

[MOVIMENTO TÁTICO] -> c8 para d7 -> É importante garantir que os bispos estejam longe das bordas e dos cantos

[MOVIMENTO TÁTICO] -> f3 para e5 -> Cavalos se movem mais devagar por isso controlar o centro, evitando as fileiras b/g e principalmente as bordas, é de extrema importância

Figura 4 - Explicação da movimentação f3e5 > c8d7 > d3c4 > d7b5

5.2 Explicação de movimentos de captura e a automatização da explicação




Figura 5 - Tabuleiro sujeito a movimentação b5c6 > b4c3 > d3c3 > d7c6

```
[MOVIMENTO DE CAPTURA] -> Movimento de d7 para c6 -> Adversário conquistará um bispo
[MOVIMENTO DE CAPTURA] -> Movimento de d3 para c3 -> você conquistará um bispo
[MOVIMENTO DE CAPTURA SOB AMEAÇA] -> Movimento de b4 para c3 -> Adversário conquistará um cavalo mas irá perder seu bispo
[MOVIMENTO DE CAPTURA SOB AMEAÇA] -> Movimento de b5 para c6 -> você conquistará um cavalo mas você irá perder seu bispo
```

Figura 6 - Explicação da movimentação b5c6 > b4c3 > d3c3 > d7c6

Na figura 6, pode-se observar que a avaliação do algoritmo ponderou a vantagem das capturas para os dois lados. Caso o jogo siga da forma indicada, um bispo e um cavalo será capturado em cada um dos lados, porém, a vantagem do tabuleiro ainda será a favor do lado branco, considerando os valores qualitativos das outras peças no tabuleiro.

5.3 Avaliação do desempenho do algoritmo desenvolvido

Para avaliação da eficiência do algoritmo desenvolvido, foi realizada uma comparação de resolução de lances com um algoritmo consolidado, o Stockfish 14. Temos nas figuras 7, 8 e 9 lado a lado os tabuleiros com os lances de cada algoritmo, em uma posição final de jogo.

Nas figuras 7 e 8, os lances jogados pelo algoritmo desenvolvido e o Stockfish são iguais, indicando eficiência na resolução do problema enfrentado no tabuleiro através da sequência: Peão e6 para e7, Bispo g8 para f7, Rei Branco captura o Bispo em f7, Rei preto se movimenta de h8 para h7.

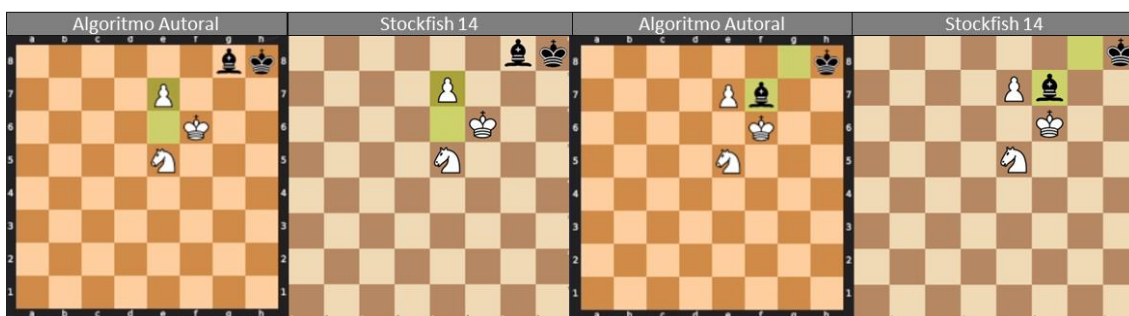


Figura 7 - Comparação de lances jogados entre algoritmo desenvolvido e Stockfish 14




Figura 8 - Comparação de lances jogados entre algoritmo desenvolvido e Stockfish 14

Já na figura 9, temos uma divergência de resolução entre o algoritmo autoral e o Stockfish 14, onde respectivamente o Peão vai para e8 promovendo a Dama, enquanto Cavalo de e5 vai para g4, bloqueando a rota de fuga do rei adversário.

Na sequência, o Stockfish finaliza a partida com xeque-mate em Dama g8 com mais 3 lances, enquanto o algoritmo do projeto demanda mais 6 lances para chegar no mesmo resultado com Dama em g4. Portanto, temos um indicativo claro de que apesar de uma eficiência de 80% (4 lances iguais de 5 testados em comparação com um algoritmo consolidado) a resolução final indicada pelo Stockfish é mais otimizada em função do menor número de lances necessários para o encerramento da partida.

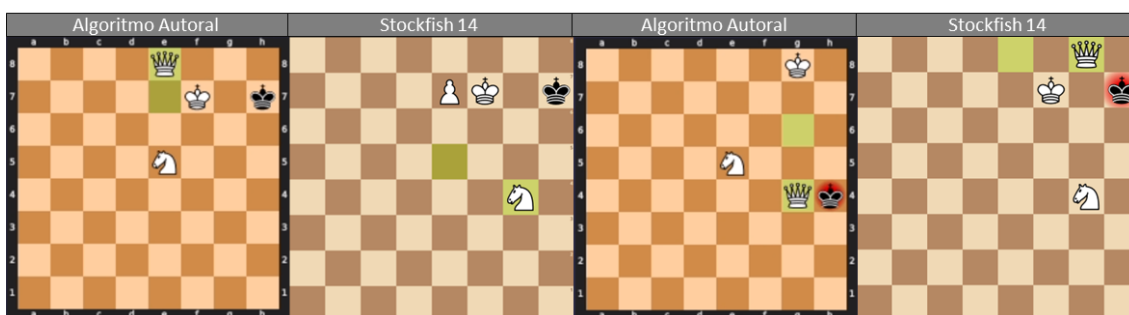


Figura 9 - Comparação de lances jogados entre algoritmo desenvolvido e Stockfish 14

Uma hipótese é que aumentando bruscamente a profundidade de recursividade do Minimax, poderá ser alcançado um resultado semelhante ao proposto pelo Stockfish nessa mesma posição da figura 9.

6. Conclusões e Trabalhos Futuros

A área de explicação da tomada de decisão de algoritmos de aprendizado de máquina é nova e está ebulindo em diversos segmentos e países. Acreditamos que aprofundar este tema e desenvolvê-lo no mesmo patamar que outras tecnologias e soluções, é um passo benéfico para escalabilidade na resolução de problemas recorrentes em toda sociedade.

Por ter desenvolvido o algoritmo desde a parte inicial, possibilitou um diagnóstico completo de quais os parâmetros importantes para tomada de decisão durante o jogo de Xadrez. Esse entendimento foi fundamental na construção da explicação e direcionamento de sua automatização. Compilar o conjunto de lances avaliados pela máquina em forma de tabela foi um grande passo para automatizar a análise explicativa, uma vez que possibilitou o mapeamento da variante principal dos melhores lances que foram considerados durante a recursividade em busca da melhor solução. Esse conjunto de fatores colaboraram para o resultado que era esperado no desenvolvimento do projeto, sendo este uma explicação automatizada de forma sintetizada e de simples entendimento do processo de tomada de decisão do algoritmo desenvolvido. Após a avaliação da performance do algoritmo em comparação com o Stockfish 14, concluímos também que em trabalhos futuros será necessário aumentar a profundidade de recursividade do Minimax, a fim de encontrar soluções mais otimizadas.

Acredita-se que essa solução para explicação possa ser aplicada em diversos cenários além do âmbito do xadrez, assim como em outros tipos de algoritmos. Portanto, sugere-se que em trabalhos futuros, o método aplicado seja utilizado em outra situação além do xadrez. Sugerimos também, que instituições de ensino usem o recurso de explicação de tomada de decisão de máquina a fim de maximizar o aprendizado de seus alunos, podendo acelerar a curva de aprendizado e entendimento dos mesmos.

Referências

- DAS, Devleena; CHERNOVA, Sonia. Leveraging Rationales to Improve Human Task Performance. 2020. Tese (Doutorado) - Georgia Institute of Technology, Cagliari, Itália, 2020.
- BEDNARZ, Tomasz; WELLS, Lindsay. Explainable AI and Reinforcement Learning - A Systematic Review of Current Approaches and Trends. 2021 - University of New South Wales, Sidney, Australia, 2021
- McKinsey Global Institute. Notes from the AI frontier insights from hundreds of use cases. 2018. Disponível em <https://www.mckinsey.com/>. Acesso em: 1 de novembro de 2021.
- ALBUQUERQUE, Eduardo. Inteligência artificial: aplicação do algoritmo Minimax em um jogo de xadrez. Curso de Sistemas de Informação Universidade Estadual de Mato Grosso do Sul, Brasil, Mato Grosso do Sul, 2016.

ESMENGER Nathan. Is chess the drosophila of artificial intelligence? A social history of an algorithm. School of Information, University of Texas at Austin, Estados Unidos da América, Texas, 2011.

MARQUES, Bruno Oliveira. Inteligência artificial explicável para análise de partidas de futebol. Universidade Federal do Rio Grande do Sul, Brasil, Porto Alegre, 2019.

Holzinger, Andreas; Goebel, Randy; Fong, Ruth; Moon, Taesup; Müller, Klaus-Robert; Samek, Wojciech. xxAI – Explainable AI Methods – A Brief Overview. 2020 - International Workshop Held in Conjunction with ICML 2020.

[Chess Programming 2022] Simplified Evaluation Function. https://www.chessprogramming.org/Simplified_Evaluation_Function. Acesso em 10 de outubro de 2022.

[Chess Programming 2022] Minimax. <https://www.chessprogramming.org/Minimax> Acesso em 10 de outubro de 2022.