

PREVENDO TENDÊNCIAS NO MERCADO DE AÇÕES POR MEIO DE REDES NEURAIS RECORRENTES: UMA PROPOSTA DE ENSINO A DISTÂNCIA GAMIFICADO

Fabriciu Alarcão Veiga Benini

Área da Indústria

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo – IFSP, São Carlos, SP, Brasil.

benini@ifsp.edu.br

Victoria Barboza de Castro Cunha

Pós-Graduação em Gestão de Projetos

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo – IFSP, Pirituba, SP, Brasil.

victoria.cunha@aluno.ifsp.edu.br

Resumo

Este trabalho propõe um curso de Ensino a Distância (EaD) gamificado, desenvolvido na plataforma Moodle com integração de Google Colab e Python, para ensinar a previsão de tendências no mercado de ações e, potencialmente em outros ativos de renda variável, utilizando Redes Neurais Recorrentes (*Recurrent Neural Networks - RNNs*). O objetivo é democratizar o acesso à educação financeira avançada, permitindo que não especialistas apliquem técnicas de análise financeira e programação para a tomada de decisões de investimento mais informadas. O curso foi estruturado em 14 seções, com material didático autoral, artigos complementares e atividades práticas gamificadas, incluindo a criação de *templates* de RNNs em Python para simulação de análises preditivas. Os resultados preliminares demonstram o potencial da abordagem para engajar alunos, mesmo sem conhecimento prévio em finanças ou programação, no aprendizado de conceitos complexos e na aplicação prática de técnicas avançadas de previsão. Acredita-se que o curso contribua para a disseminação do conhecimento sobre o uso de inteligência artificial no mercado financeiro, fomentando uma participação mais consciente e estratégica dos investidores.

Palavras-chave: Mercado de Ações; Predição; Redes Neurais Recorrentes; Curso EAD; Moodle; Gamificação.

PREDICTING STOCK MARKET TRENDS THROUGH RECURRENT NEURAL NETWORKS: A GAMIFIED DISTANCE LEARNING PROPOSAL

Abstract

The prediction of technical indicators in the stock market aids investors in making more informed buying and selling decisions. The adoption of technology and data science, particularly recurrent neural networks and Python, enhances the accuracy of these predictions. The development of the Gamified Distance Learning course presented here facilitates the understanding of investment analysis using these technologies. Through Moodle, incorporating Google Colab and Python, the course offers non-experts the ability to apply financial analysis and programming. An innovative feature is the provision of Recurrent Neural Network templates, allowing even novices to customize their neural networks to align with investment strategies and buying and selling decisions. This practical approach, supplemented with interactive content, aims to democratize access to advanced financial education, enhancing informed participation in the stock market on a national scale.

Keywords: stock market; prediction; recurrent neural networks; distance learning course; Moodle; gamification.

1 INTRODUÇÃO

O mercado de ações, em sua essência, é uma entidade altamente dinâmica e multifacetada, cujas flutuações são influenciadas por uma miríade de fatores tanto endógenos quanto exógenos. Investidores e analistas financeiros, na busca incessante por decifrar os padrões e tendências subjacentes a esse mercado, frequentemente se deparam com o desafio de antecipar seus movimentos futuros uma tarefa complexa (Elder, 2006; Tibúrcio Silva; Carvalho; Nunes, 2012).

A volatilidade do mercado de ações, caracterizada por rápidas e significativas variações de preços, reflete a natureza intrinsecamente instável desse ambiente. Esse aspecto, associado à complexidade das variáveis que influenciam as ações, confere ao mercado um caráter imprevisível, um cenário em que as certezas são escassas e as surpresas, frequentes. Elder (2006) argumenta que, para navegar com maiores chances de acerto nesse terreno volátil, é imperativo que os investidores desenvolvam uma compreensão profunda dos princípios de operação do mercado e adotem estratégias robustas de investimento.

Por outro lado, Tibúrcio Silva, Carvalho e Nunes (2012) examinam o impacto das notícias no comportamento dos preços das ações, destacando a complexa relação entre informações, percepções de investidores e dinâmica do mercado. O estudo sugere que as notícias, sejam elas econômicas, políticas ou de outra natureza, têm o potencial de alterar

significativamente a percepção de valor por parte dos investidores, desencadeando ajustes nos preços das ações.

Em meio a essa complexidade, a capacidade de prever movimentos do mercado assume uma importância crítica, não apenas para a realização de ganhos financeiros, mas também como uma forma de mitigar riscos. Investidores e analistas, portanto, recorrem a uma ampla gama de ferramentas analíticas, desde análises fundamentais e técnicas até modelos quantitativos avançados, na tentativa de extrair padrões e antecipar futuras trajetórias do mercado. Contudo, é fundamental reconhecer que, apesar dos avanços nas metodologias de análise e na disponibilidade de dados, a previsão dos mercados acionários ainda está sujeita a incertezas significativas. Fatores imprevisíveis, como eventos geopolíticos, mudanças regulatórias ou mesmo a psicologia coletiva dos investidores, podem rapidamente alterar o curso do mercado, desafiando as previsões mais bem fundamentadas (Zouaghia; Kodia; Ben Said, 2024).

No âmbito da análise financeira, as séries temporais financeiras, caracterizadas por sua volatilidade, não-linearidade e ruído, apresentam um desafio considerável para os métodos tradicionais de previsão. Nesse contexto, as Redes Neurais Recorrentes (*Recurrent Neural Networks - RNNs*) emergem como uma ferramenta poderosa, devido à sua habilidade ímpar de processar sequências de dados e capturar dinâmicas temporais. Diversos estudos, como os realizados por Fleck *et al.* (2016) e Nelson (2017), demonstraram a eficácia das RNNs na previsão de séries temporais financeiras. Esses estudos validam a superioridade das RNNs em capturar padrões complexos e não lineares que são comuns em dados financeiros, superando, assim, muitas técnicas tradicionais de previsão.

Uma evolução notável dentro da família das RNNs é a *Long Short-Term Memory* (LSTM), uma variante projetada para superar as limitações das RNNs tradicionais, especialmente em relação ao problema do desaparecimento do gradiente. As LSTMs permitem que a rede retenha informações por períodos mais longos, tornando-as excepcionalmente adequadas para a análise de séries temporais financeiras, cuja dependência de longo prazo e precisão na previsão são fundamentais (Dhokane; Agarwal, 2024). Essa característica é particularmente relevante para o mercado financeiro, em que as condições futuras são frequentemente dependentes de eventos passados.

No contexto da implementação, Python emergiu como uma linguagem de programação de escolha no campo da ciência de dados e aprendizado de máquina, oferecendo

um ecossistema rico em bibliotecas especializadas. Para a implementação de LSTMs, bibliotecas como *TensorFlow* e *Keras* facilitam a construção, treinamento e avaliação de modelos de aprendizado profundo com interfaces de alto nível e eficiência computacional. O *TensorFlow*, desenvolvido pela Google, fornece um *framework* abrangente com suporte extensivo para redes neurais, incluindo LSTMs, enquanto o *Keras*, que agora é integrado ao *TensorFlow* como uma interface de alto nível, permite a criação de modelos de forma mais intuitiva e simplificada. Dhokane e Agarwal (2024) demonstram a aplicabilidade prática das LSTMs no contexto financeiro, utilizando essas poderosas bibliotecas Python para modelar e prever movimentos de ações com base em dados históricos.

Nguyen, Kend e Le (2024) ilustram como a educação financeira e tecnológica é vital para profissionais em setores específicos, como a auditoria, nos quais a compreensão da tecnologia digital se torna cada vez mais fundamental para a execução eficaz de suas funções. O estudo ressalta a necessidade de adaptar os programas educacionais para incorporar tanto conhecimentos financeiros quanto tecnológicos, preparando os profissionais para enfrentar os desafios e aproveitar as oportunidades apresentadas pela era digital. Nesse contexto, a gamificação se apresenta como uma metodologia promissora para a educação e o treinamento no domínio financeiro. Diahyleva, Yurzhenko e Kononova (2024) demonstraram, em seus estudos sobre cursos online de Inglês Marítimo, como a gamificação pode introduzir uma dinâmica renovada no aprendizado, sugerindo seu potencial para transformar a educação financeira. Assim como a gamificação revitalizou o ensino de idiomas em ambientes virtuais, sua aplicação no ensino de conceitos financeiros, especialmente no uso de RNNs para a previsão de ações, promete uma abordagem mais interativa e engajadora, facilitando o entendimento e a prática dessas técnicas avançadas em um ambiente tão volátil quanto o mercado de ações.

É importante ressaltar que as ações, foco principal deste estudo, são um tipo de ativo que compõem a classe mais ampla da renda variável. Esta classe inclui diversos outros instrumentos financeiros, como fundos imobiliários, *Exchange Traded Funds (ETFs)*, derivativos e *commodities*, cada um com suas próprias características e dinâmicas de mercado. Embora o curso proposto utilize dados de ações para demonstrar a aplicação das RNNs na previsão de tendências, os princípios e técnicas ensinados são adaptáveis para a análise de outros ativos de renda variável. A capacidade de modelar séries temporais complexas e identificar padrões de comportamento inerentes às RNNs as torna uma

ferramenta valiosa para investidores que buscam diversificar suas estratégias de análise e otimizar suas decisões de investimento em diferentes mercados.

Com base nesses antecedentes, este estudo propõe uma metodologia educacional inovadora, utilizando um ambiente de aprendizado à distância gamificado para ensinar a previsão de tendências no mercado de ações utilizando RNNs. Sua maior contribuição prática é desmistificar a complexidade das RNNs e torná-las acessíveis a um público mais amplo, que pode não ter formação avançada em ciência de dados ou finanças. O uso da gamificação busca engajar os participantes, tornando o aprendizado mais interativo e prazeroso, o que é essencial para facilitar a compreensão de conceitos complexos e a aplicação prática de técnicas avançadas de previsão. Portanto, ao integrar a robustez das RNNs com estratégias de ensino gamificadas, espera-se não apenas expandir o entendimento e a aplicabilidade dessas técnicas avançadas em finanças, mas também promover uma educação mais eficaz e envolvente sobre previsão de séries temporais no contexto do mercado de ações.

2 FUNDAMENTAÇÃO TEÓRICA

As RNNs distinguem-se das redes neurais *feedforward* pela presença de ciclos em sua topologia, permitindo que informações de estados anteriores sejam utilizadas no processamento atual. Essa característica confere às RNNs uma "memória" dinâmica, tornando-as adequadas para lidar com sequências de dados e problemas nos quais a temporalidade e a ordem são essenciais para a compreensão e previsão de padrões (Benini, 2008). A pesquisa de De Souza, Ferreira e Benini (2022) ilustra a aplicação de RNNs, com um enfoque em LSTMs na precificação do mercado de ações, destacando como essas redes aproveitam indicadores técnicos para fornecer previsões confiáveis. Esta abordagem sublinha o potencial das LSTMs em decifrar as complexidades do mercado financeiro, oferecendo *insights* valiosos que transcendem as capacidades de modelos preditivos mais tradicionais.

A arquitetura das LSTMs é projetada para reter informações ao longo de extensos intervalos temporais, por meio de uma configuração de portas de esquecimento, entrada e saída. A porta de esquecimento tem a função de determinar quais dados serão removidos do estado da célula, enquanto a porta de entrada é responsável por integrar novas informações ao estado da célula. Por fim, a porta de saída decide quais informações serão transmitidas para a fase subsequente do processo. Essa estrutura possibilita que as LSTMs capturem dependências de longo prazo, tornando-as ferramentas extremamente valiosas para análises de

séries temporais, particularmente na previsão de tendências no mercado de ações, para o qual o entendimento de eventos passados e a memória de longa duração são fundamentais para a acurácia das previsões (Saber; Naeher; Bendecheche, 2024).

Para elucidar o processo de implementação de redes LSTM utilizando a linguagem Python, é pertinente referenciar o estudo de Nguyen *et al.* (2024), que desenvolveu o *HydroEcoLSTM*, um pacote Python com interface gráfica para modelagem hidroecológica com redes neurais LSTM. Este trabalho exemplifica uma aplicação prática de LSTMs, oferecendo uma perspectiva concreta sobre como essas redes podem ser implementadas em Python.

A configuração de uma LSTM em Python inicia-se com a importação de bibliotecas essenciais, como *Keras* e *TensorFlow*, que disponibilizam as funcionalidades necessárias para a construção e o treinamento de redes neurais. A definição da arquitetura da rede envolve a determinação de aspectos como o número de camadas e unidades, bem como as funções de ativação a serem utilizadas. Posteriormente, o modelo é compilado, estabelecendo-se o otimizador e a função de perda a ser aplicada. O treinamento é realizado mediante um conjunto de dados, permitindo que a rede aprenda a realizar previsões ou classificações. Após o treinamento, o modelo é avaliado e se torna apto para realizar inferências sobre novos conjuntos de dados. Para o contexto de previsão de ações utilizando LSTM, De Souza, Ferreira e Benini (2022) descrevem sua implementação voltada para a plataforma Moodle, com auxílio de um fluxograma.

É essencial reconhecer a importância dessa plataforma, em conjunto com a educação em programação, para aprimorar a compreensão e aplicação de conceitos complexos, como os envolvidos na configuração de RNNs utilizando Python. O trabalho de Levez e Benini (2020) demonstra a eficácia do Moodle em facilitar um aprendizado autônomo e personalizado, essencial para a assimilação profunda de tópicos avançados em programação e ciência de dados. Por outro lado, a inclusão da programação como um elemento central na formação educacional, conforme explorado por Candiani *et al.* (2022), sublinha a relevância de integrar o ensino de programação nas práticas pedagógicas, especialmente em contextos de Ensino a Distância (EaD).

Embora o foco de Candiani *et al.* (2022) seja o *Scratch*, a ênfase aqui recai sobre a essência de seu argumento: a programação como uma habilidade fundamental no cenário educacional moderno, diretamente aplicável ao uso de Python para configurar RNNs. A

combinação do Moodle com um currículo que enfatiza habilidades de programação prepara os alunos não apenas para entender teorias complexas, mas também para aplicá-las de forma prática, como na configuração e no uso de RNNs em Python. Essa abordagem não apenas facilita a compreensão dos conceitos, mas também permite que os estudantes apliquem esses conhecimentos em cenários reais, um aspecto crucial na aprendizagem de disciplinas técnicas. Portanto, ao integrar o Moodle a um currículo focado em programação, podemos criar um ambiente de aprendizagem que não apenas transmite conhecimento, mas também capacita os alunos a aplicar esse conhecimento de maneira prática e eficaz, essencial para a compreensão e implementação de tecnologias avançadas como as RNNs.

A integração da gamificação no ensino à distância, especialmente quando focada no aprendizado de programação e análise de dados, tem demonstrado um impacto significativo na motivação e no engajamento dos estudantes. A abordagem lúdica proposta por Casaque *et al.* (2023) no contexto da robótica pode ser adaptada para o ensino de Python e RNNs, oferecendo uma metodologia inovadora para o curso descrito, que visa democratizar a educação financeira avançada através do Moodle, utilizando Google Colab e Python.

O conceito de gamificação, como elucidado por Casaque *et al.* (2023), utiliza elementos típicos de jogos para enriquecer o processo educacional, tornando-o mais envolvente e interativo. No ambiente Moodle, isso se traduz na implementação de missões, níveis progressivos, e recompensas virtuais, criando um ambiente dinâmico que estimula o aprendizado autônomo e a aplicação prática dos conceitos de programação em Python, essenciais para a manipulação e análise de dados em investimentos. A pesquisa de Oliveira *et al.* (2022) também ressalta a eficácia da gamificação no aprendizado remoto, sugerindo que estratégias de engajamento baseadas em jogos podem ser aplicadas com sucesso no ensino de conceitos complexos. Integrar tais estratégias no curso de análise financeira pode facilitar a compreensão e a aplicação prática de RNNs por parte dos alunos, promovendo uma experiência de aprendizado mais ativa e participativa.

Além disso, Bogni *et al.* (2022) destacam a importância de conteúdos interativos e visuais na gamificação, um princípio que pode ser transferido para a estruturação do curso proposto. Ao oferecer *templates* de RNNs no Moodle, os alunos têm a oportunidade de visualizar e modificar esses modelos, reforçando o aprendizado através da experimentação e personalização, o que é vital para a compreensão de estratégias de investimento baseadas em dados. Por fim, Da Silva *et al.* (2021) abordam a gamificação em um contexto específico da

eletrônica orientada à robótica, mas o princípio de criar um ambiente de aprendizado gamificado que encoraje a experimentação também pode ser adaptado para o ensino de Python e RNNs no contexto financeiro. Oferecer um curso que simula cenários de investimento reais, permitindo que os alunos apliquem seus conhecimentos em Python para analisar dados do mercado de ações, pode resultar em uma compreensão mais profunda e em habilidades práticas mais robustas.

3 MATERIAL E MÉTODOS

Considerando que este trabalho surgiu da convergência entre duas áreas, quais sejam, previsão de tendências no mercado de ações e educação à distância gamificada, os materiais e métodos envolvidos contemplam diversos elementos-chave. Primeiramente, são utilizadas redes neurais recorrentes para a previsão de tendências no mercado de ações, conforme visto em Nelson (2017). Essas redes têm a capacidade de analisar padrões em séries temporais complexas, capturando dependências temporais e oferecendo um potencial maior de precisão preditiva (Haykin, 2001). Além disso, o ambiente de aprendizado à distância está sendo projetado com elementos gamificados, como desafios, recompensas e interatividade, a fim de tornar o processo de aprendizagem mais envolvente e motivador para os alunos, conforme defendido por Candiani, Rossi e Benini (2020) e Levez e Benini (2018).

Para tanto, inicialmente, buscou-se identificar os padrões e tendências históricas no mercado de ações que podem ser capturados e analisados por meio das RNNs. Isso envolveu analisar dados passados do mercado, identificar comportamentos recorrentes e entender como esses padrões podem ser utilizados para prever movimentos futuros na bolsa de valores.

Num segundo momento, procedeu-se com a avaliação da eficácia das RNNs na previsão de tendências no mercado de ações. Nesse quesito, foi investigado até que ponto essas redes eram capazes de capturar as complexidades dos dados do mercado financeiro e fornecer previsões precisas. Assim sendo, foram realizadas análises métricas de desempenho, a exemplo da acurácia das previsões em relação aos resultados reais.

Já a terceira etapa fundamentou-se na avaliação da gamificação do ambiente de aprendizado à distância. O ambiente gamificado teve de ser projetado para incorporar desafios, recompensas e interatividade na apresentação dos conceitos relacionados à previsão de tendências no mercado de ações. Para tanto, configurou-se o Moodle por meio do módulo “Lição”, por meio do qual foi possível estruturar as trilhas de cada módulo, fazendo com que

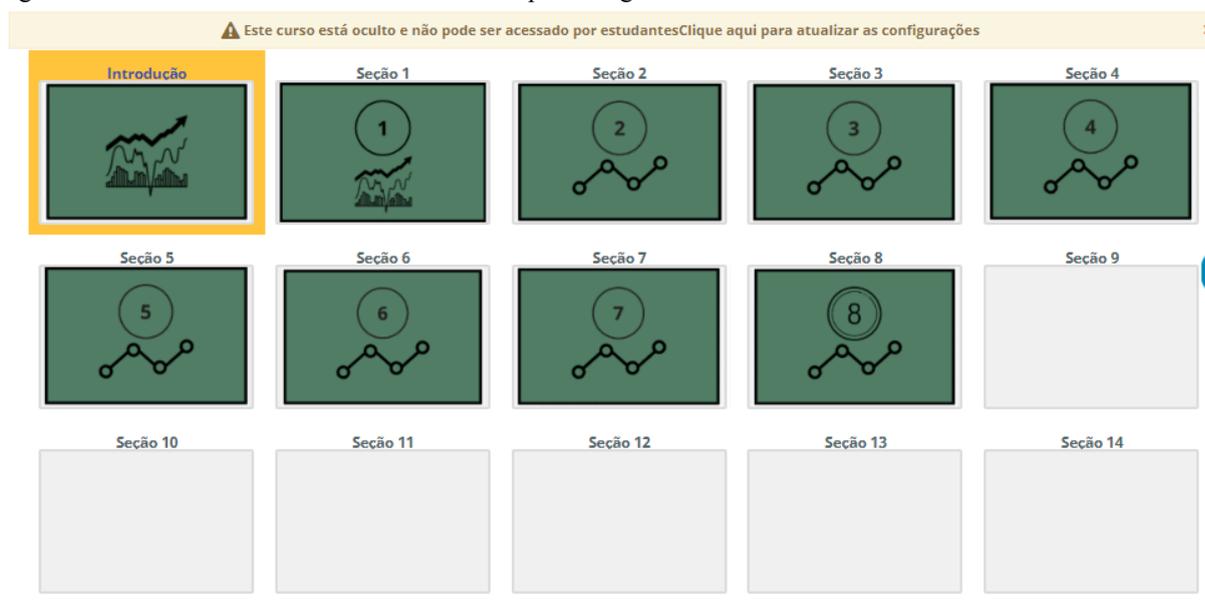
o aluno tenha de responder às questões para que possa marcar as tarefas como concluídas e “mudar de fase”, seguindo a lógica da gamificação. Ademais, utilizou-se o *plugin Level Up* para a criação de um sistema de ranqueamento que serve tanto para o aluno monitorar o seu progresso no curso quanto para autoavaliar o seu desempenho em comparação aos demais cursistas, simulando um ambiente de competição saudável entre os participantes.

4 RESULTADOS E DISCUSSÃO

O primeiro resultado deste trabalho envolveu a estruturação do *design* da trajetória de aprendizagem no Moodle. O maior desafio aqui foi organizar as informações de uma maneira que o cursista, mesmo sem conhecimento prévio no assunto, pudesse começar a entender sobre bolsa de valores, séries históricas, suas formas de representação gráfica e topologias de redes neurais. Dessarte, criou-se um módulo específico na trilha de aprendizagem para listar as técnicas de análise gráfica existentes, definir tendências de ações e também listar as análises de predição temporal através de redes neurais, a fim de tornar a apresentação do conteúdo mais modular e introduzir tópicos mais difíceis que pudessem contar mais pontos na gamificação ao final da jornada.

Ao todo, ficou estabelecido que o curso contará com 14 seções, das quais oito já foram elaboradas com material didático próprio e conteúdos extras que conferem pontos adicionais na jornada do cursista. Portanto, essa etapa de estruturação permitiu mapear quais conteúdos deveriam ser ministrados, a fim de que os alunos aprendessem desde o mais básico, partindo da definição de termos comuns no mercado de ações, até chegar à simulação das análises do mercado financeiro de fato. O primeiro resultado, na própria interface do Moodle, pode então ser visualizado na Figura 1.

Figura 1 - Menu inicial do curso com a trilha de aprendizagem

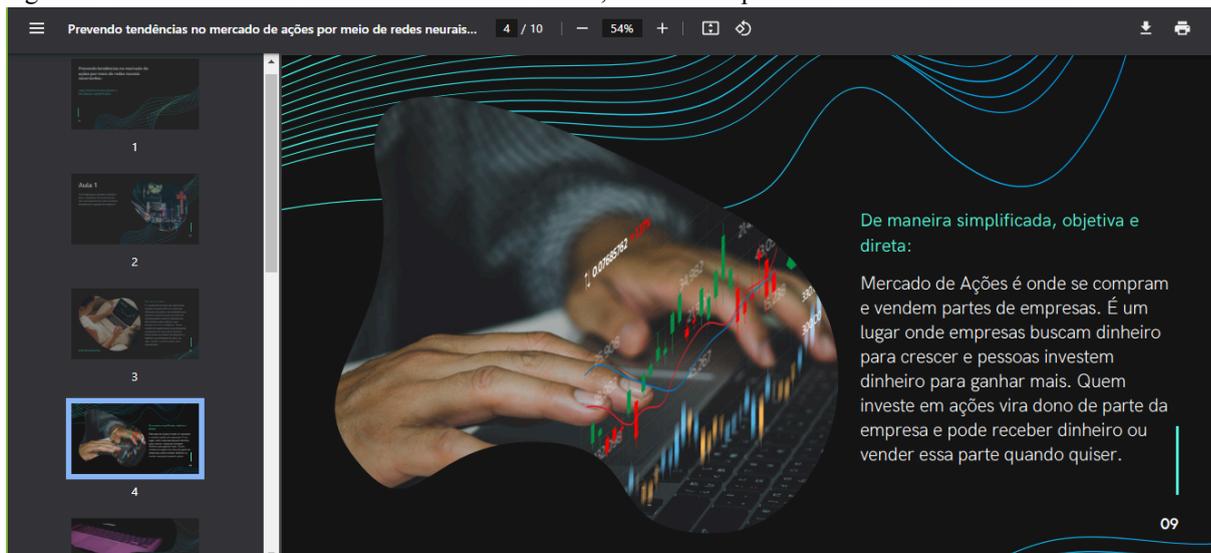


Fonte: Elaborado pelo(s) autor(es).

O segundo resultado foi composto pela criação do conteúdo autoral do curso. O material foi preparado no Canva como um recurso externo à plataforma Moodle, mas facilmente anexado a ela, por ser visualmente agradável para os fins didáticos a que se destina o curso. Ainda na primeira seção do curso, incluíram-se algumas funcionalidades para estimular a troca de ideias entre os cursistas, adicionando uma aba de “Dúvidas” e outra para “Avisos”, pois é nessa etapa introdutória que os alunos precisam de maior orientação ou mesmo de maior motivação para manter-se no curso (Ofosu-Ampong *et al.*, 2020; Bakhanova, 2020). Uma apresentação do material didático autoral está indicada na Figura 2.

Dando sequência à construção do conteúdo introdutório, o terceiro resultado envolveu o emprego do recurso do Moodle para anexação de artigos extras que complementassem o material autoral acerca das técnicas de análise de ações. Esses artigos foram importantes porque, às vezes, os cursistas podem ter dificuldade para absorver uma linguagem mais técnica ou mesmo acadêmica sobre um tema sobre o qual não detêm nenhum conhecimento prévio (Bakhanova, 2020). Na tentativa de ampliar as opções de entendimento, portanto, procurou-se indicar materiais extras que fossem selecionados com base na sua pertinência e acurácia sobre o tópico de cada módulo.

Figura 2 - Material didático autoral elaborado no Canva, anexado ao primeiro módulo do curso EaD



Fonte: Elaborado pelo(s) autor(es).

Alternativamente, esse recurso também atende ao requisito educativo do ensino EaD, o qual visa promover o letramento digital a partir do uso de fontes confiáveis, disponíveis em acesso aberto (Pinheiro; Pinheiro, 2021). Estas poderão ser usadas pelos cursistas para que aprendam a reconhecer os materiais adequados à própria aprendizagem, norteados por pesquisas futuras mais aprofundadas sobre o tema e estimulando um engajamento autônomo no ensino pelo estudante (Ab Rahman; Ahmad; Hashim, 2019; Pinheiro; Pinheiro, 2021). Nesse sentido, o espaço Colab do Google também foi empregado para atingir esse resultado, uma vez que, por meio dele, os participantes poderão compartilhar códigos em Python e criar um ambiente de aprendizagem em paralelo ao Moodle, no qual consigam reconhecer-se como partícipes na construção do conhecimento prático sobre simulações de análise usando redes neurais.

Por fim, em linha com o resultado anterior, um módulo específico foi implementado no Moodle acerca dos aspectos relativos à programação com as redes neurais, com o intuito de exemplificar como seria a aplicação das análises preditivas de investimentos. Esse tipo de atividade em que o aluno consegue testar os conhecimentos auxilia na gamificação tanto pela criação de um sentimento gregário em torno de um objetivo comum (Bakhanova, 2020), quanto pela tangibilização necessária dos problemas a serem solucionados por meio da simulação da teoria (Haykin, 2001; Ofosu-Ampong *et al.*, 2020). Nesse contexto o Google Colab representou um espaço de aprendizagem facilmente incorporado ao Moodle, que permitiu, de igual modo, uma diferenciação entre redes neurais artificiais profundas, também

chamadas de *deep learning* (Fleck *et al.*, 2016), daquelas mais comuns nos gráficos de análise técnica denominados de *candlestick* (Debastiani, 2007).

Como a análise técnica de padrões formados em um *candlestick* está entre os métodos utilizados para estimar a tendência de preço de um determinado papel na bolsa de valores (Leonel; Oliveira Neto, 2016), proporcionar essa diferenciação no ambiente de aprendizagem voltado à análise de investimentos financeiros com base em inteligência artificial agregou diversos benefícios à trilha de aprendizagem. Primeiro, ela permitiu um processamento de grandes volumes de dados, o que se tornou facilitado pela infraestrutura técnica do Google Colab. Segundo, possibilitou ao cursista compreender modelagens financeiras não lineares. Terceiro, facilitou o processo de automatização das previsões financeiras. Quarto, ajudou a processar séries temporais mais complexas – que apresentam preços de ações e taxas de câmbio, por exemplo –, viabilizando a captura de padrões sazonais de maior volatilidade entre as tendências. Quinto, conduziu a análises mais completas baseadas em notícias, mídias sociais e outros dados de texto, nos quais se expressam os sentimentos em torno da volatilidade da Bolsa. Isso é particularmente relevante nesse tipo de análise, em virtude de as informações e notícias terem um impacto significativo nos preços dos ativos (Elder, 2006; Carneiro, 2018; Farias; Salim; Santos, 2021). Sexto, pode ser combinada com outros métodos de análise, como modelos estatísticos tradicionais, para formar modelos *ensemble* (Haykin, 2001; Fleck *et al.*, 2016). Salienta-se que essa abordagem combinada, além de resultar em previsões mais robustas e precisas, está alinhada mais uma vez ao requisito da autonomia no ensino EaD (Ab Rahman; Ahmad; Hashim, 2019). Conforme visto anteriormente, o aluno dessa modalidade de ensino EaD precisa ser apresentado aos ferramentais que viabilizarão a aprendizagem por conta própria e, nesse contexto, os resultados obtidos até o presente demonstraram que é possível a interface da inteligência artificial com outros métodos para previsão de tendências através do ensino gamificado no Moodle. Tais métodos inclusive oferecem um potencial a ser descoberto de modo independente pelos estudantes, mas que também pode vir a ser explorado em pesquisas futuras.

5 CONCLUSÕES

Em resumo, o principal resultado obtido consistiu no desenvolvimento da primeira parte do ambiente de aprendizado gamificado no Moodle, a partir do aprofundamento do conhecimento em RNNs. Dentre os resultados secundários, priorizou-se, nesta primeira

metade do projeto, a identificação de padrões históricos e a avaliação da eficácia das RNNs no contexto pesquisado, uma vez que tais elementos são fundamentais para aprofundar o conhecimento sobre a previsão de tendências no mercado de ações e fornecer uma abordagem inovadora para o ensino de diversos conceitos financeiros. Nesse sentido, avança-se na teoria sobre o tema ao buscarem-se respostas para perguntas específicas relacionadas à previsão de tendências no mercado de ações por meio da inteligência artificial, expressa neste trabalho na forma das redes neurais recorrentes (RNNs).

Ao combinar as técnicas avançadas de previsão com o ambiente gamificado de aprendizado à distância, esta proposta contribui para a capacitação de alunos em prol de um melhor entendimento do mercado de ações e da aquisição de habilidades práticas na previsão de tendências, voltadas a decisões de investimento mais fundamentadas e estratégicas. Conseqüentemente, espera-se que os participantes do curso EaD sejam capazes de analisar melhor as oportunidades e riscos inerentes às transações da Bolsa, o que poderá impactar na disseminação isonômica do acesso à educação financeira no país.

Referências

AB RAHMAN, R.; AHMAD, S.; HASHIM, U. R. A study on gamification for higher education students' engagement towards education 4.0. In: **Intelligent and Interactive Computing**. Springer, Singapore, 2019. p. 491-502.

BAKHANOVA, E. *et al.* Targeting social learning and engagement: What serious games and gamification can offer to participatory modeling. **Environmental Modelling & Software**, v. 134, p. 104846, 2020.

BENINI, F.A.V.. **Rede neural recorrente com perturbação simultânea aplicada no problema do caixeiro viajante**. 2008. Dissertação (Mestrado) - Universidade de São Paulo, São Carlos, 2008. Disponível em: <http://www.teses.usp.br/teses/disponiveis/18/18153/tde-29042009-102601/>. Acesso em: 31 mar. 2024.

BOGNI, G.; PINHEIRO, M.; BENINI, F.. Construção De Curso Ead Gamificado Sobre Esp32 Programado Em Micropython. **CONICT - Congresso de Inovação, Ciência e Tecnologia, Brasil**, oct. 2022. Disponível em: <https://ocs.ifsp.edu.br/conict/xiiiconict/paper/view/8512%26gt/3061>. Data de acesso: 07 Apr. 2024.

CANDIANI, T.; LEME, J. C. da S.; PAIXÃO, G. A.; BENINI, F.A.V. Scratch como introdução à programação na formação docente: relato de experiência em EAD. **Extensão Tecnológica: Revista de Extensão do Instituto Federal Catarinense**, v. 9, n. 17, p.

105–122, 2022. DOI: 10.21166/text.v9i17.2164. Disponível em: <https://publicacoes.ifc.edu.br/index.php/RevExt/article/view/2164>. Acesso em: 7 de abril 2024.

CANDIANI, T. L.; ROSSI, C. S.; BENINI, F.A.V. Estruturação da Plataforma Moodle para Curso de Programação como Recurso Pedagógico para Professores. **11o CONGRESSO DE INICIAÇÃO CIENTÍFICA E TECNOLÓGICA DO IFSP (XI CONICT)**, 1–5, 2020. Disponível em: <http://ocs.ifsp.edu.br/index.php/conict/xiconict/paper/view/6885>. Acesso em: 13 nov. 2021.

CARNEIRO, A. C. **Relação entre Educação Financeira e Aversão ao Risco**. Trabalho de Conclusão de Curso (Graduação em Administração de Empresas) – Centro de Ciências Sociais, Departamento de Administração, Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, 2018.

CASAQUE, R.; DE CASTRO, J.; BENINI, F.A.V.. Gamificação Em Ambiente De Simulação Robótica Para Ensino À Distância. **CONICT - Congresso de Inovação, Ciência e Tecnologia, Brasil**, oct. 2023. Disponível em: <https://ocs.ifsp.edu.br/conict/xivconict/paper/view/10074%26gt/3655>. Data de acesso: 07 Apr. 2024.

DA SILVA, S.; GOMES, R.; BENINI, F.. Gamificação Em Práticas De Eletrônica Orientada À Robótica Para Ambiente Virtual De Aprendizagem. **CONICT - Congresso de Inovação, Ciência e Tecnologia, Brasil**, sep. 2021. Disponível em: <https://ocs.ifsp.edu.br/conict/xiiconict/paper/view/7715%26gt/2217>. Data de acesso: 07 Apr. 2024.

DEBASTIANI, C. A. **Candlestick: Um Método para Ampliar Lucros na Bolsa de Valores**. Novatec, São Paulo, 2007.

DE SOUZA, C. F.; FERREIRA, W.; BENINI, F.A.V.. Precificação Na Bolsa De Valores Com Auxílio De Rede Neural Recorrente E Indicadores Técnicos **CONICT - Congresso de Inovação, Ciência e Tecnologia (2022)**: n. pág. Web. 31 Mar. 2024. Disponível em: <https://ocs.ifsp.edu.br/conict/xiiiconict/paper/view/8441>; Data de acesso: 31 mar. 2024.

DHOKANE, R. M.; AGARWAL, S.. A Predictive Model of the Stock Market Using the LSTM Algorithm with a Combination of Exponential Moving Average (EMA) and Relative Strength Index (RSI) Indicators. **Journal of The Institution of Engineers (India): Series B**, 2024. Disponível em: <https://doi.org/10.1007/s40031-024-01037-8>. Acesso em: 31 mar. 2024.

DIAHYLEVA, O.; YURZHENKO, A.; KONONOVA, O. Gamification techniques in Maritime English online courses: Motivating learners in virtual environments. **Advances in Mobile Learning Educational Research**, 2024. Disponível em: <https://www.syncsci.com/journal/AMLER/article/view/AMLER.2024.01.008>. Acesso em: 7 de abril 2024.

ELDER, A. **Aprenda a operar no mercado de ações**. Rio de Janeiro: Elsevier, 2006.

FARIAS, T. A.; SALIM, P. H.; SANTOS, R. R. S. Aversão Ao Risco E Resposta Comportamental: Uma Exploração Histórico-Econômica. **Revista de Estudos Sociais**, [S. l.], v. 22, n. 45, 2021. DOI: 10.19093/res8496. Disponível em: <https://periodicoscientificos.ufmt.br/ojs/index.php/res/article/view/8496>. Acesso em: 18 out. 2022.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. M. Redes neurais artificiais: princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47-57, 2016. Disponível em: <https://periodicos.utfpr.edu.br/recit/article/view/4330>. Acesso em: 02 de fev. 2022.

HAYKIN, S. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

LEONEL, T. M. C.; OLIVEIRA NETO, O. J. Eficiência dos padrões altistas de candlesticks na predição da reversão do preço das ações. **Revista Gestão, Inovação e Negócios**, v. 1, n. 2, p. 24-39, 2016. Disponível em: <http://periodicos.unievangélica.edu.br/index.php/administracao/article/view/1716>. Acesso em: 22 de out. 2022.

LEVEZ, F. B.; BENINI, F. A. V. Um uso comparativo do Moodle: Curso Presencial X Ensino à Distância. **V Congresso de Extensão e V Mostra de Arte e Cultura**, Barretos. 05 nov. 2018. Disponível em: <https://www.researchgate.net/publication/328748487>. Acesso em: 13 nov. 2020.

LEVEZ, F. B.; BENINI, F. A. V. Ensinando interatividade aos professores da pré-escola com auxílio do Moodle em sala de aula. In: **Língua Portuguesa e os Estudos Literários e Linguísticos Produzidos no Brasil**. Atena Editora, 2020, p. 52-58. Disponível em: <https://doi.org/10.22533/at.ed.1082019025>. Acesso em: 7 de abril 2024.

NELSON, D. M. Q. **Uso de redes neurais recorrentes para previsão de séries temporais financeiras**. 2017. Dissertação (Mestrado em Ciência da Computação) – Instituto de Ciências Exatas, Universidade Federal de Minas Gerais. Belo Horizonte, 2017. Disponível em: <https://repositorio.ufmg.br/bitstream/1843/ESBF-AM2NTS/1/davidmichaelquirinonelson.pdf>. Acesso em: 31 mar. 2024.

NGUYEN, P.T.; KEND, M.; LE, D.Q. (2024), Digital transformation in Vietnam: the impacts on external auditors and their practices, **Pacific Accounting Review**. Disponível em: <https://doi.org/10.1108/PAR-04-2023-0051>. Acesso em: 02 de abril de 2024.

NGUYEN, T. V.; TRAN, V. N.; TRAN, H.; BINH, D. V.; *et al.* Hydroecolstm: A Python Package with Graphical User Interface for Hydro-Ecological Modelling with Long Short-Term Memory Neural Network. **SSRN**, 2024. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4769476. Acesso em: 7 de abril 2024.

OFOSU-AMPONG, K. *et al.* Are we ready for Gamification? An exploratory analysis in a developing country. **Education and Information Technologies**, v. 25, n. 3, p. 1723-1742, 2020.

OLIVEIRA, M.; CUNHA, V.; BENINI, F.A.V.. Gamificação em Projetos 3D para Ensino de Robótica a Distância. **CONICT - Congresso de Inovação, Ciência e Tecnologia**, Brasil, oct. 2022. Disponível em: <https://ocs.ifsp.edu.br/conict/xiiiiconict/paper/view/8612%26gt/3081>. Data de acesso: 07 Apr. 2024.

PINHEIRO, R. C.; PINHEIRO, B. M. G. N. Dimensões crítica e ética nas práticas de letramento digital em um jogo educativo digital. **DELTA: Documentação de Estudos em Lingüística Teórica e Aplicada**, [s. l.], v. 37, n. 2, 2021. Disponível em: <https://doi.org/10.1590/1678-460X202149228>. Acesso em: 27 fev. 2023.

SABER, T.; NAEHER, D.; BENDECHECHE, M. Intelligent computational methods for economics. **Expert Systems**, 2024. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/exsy.13523>. Acesso em: 7 de abril 2024.

TIBÚRCIO SILVA, C. A. CHAVES DE CARVALHO, C.; NUNES, D. M. S. O que move o preço da ação? uma abordagem sobre a influência das notícias no mercado acionário. **Revista de Administração Contabilidade e Sustentabilidade**, v. 2, n. 3, p. 1-13, 2012. Disponível em: <https://doi.org/10.18696/reunir.v2i3.50>. Acesso em: 27 fev. 2022.

ZOUAGHIA, Z.; KODIA, Z.; BEN SAID, L. A Novel AutoCNN Model for Stock Market Index Prediction. **Journal of Telecommunications and the Digital Economy**, v. 12, n. 1, p. 612-636, 2024. Disponível em: <https://doi.org/10.18080/jtde.v12n1.843>. Acesso em: 31 mar. 2024.