

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Predição de indicadores financeiros na área de Contabilidade com a utilização de Inteligência Artificial.

Letícia Cruz da Silva

Trabalho de Conclusão de Curso

MBA em Inteligência Artificial e Big Data

UNIVERSIDADE DE SÃO PAULO
Instituto de Ciências Matemáticas e de Computação

Predição de indicadores financeiros na área de
Contabilidade com a utilização de Inteligência Artificial

Letícia Cruz da Silva

USP - São Carlos
2024

Leticia Cruz da Silva

Predição de indicadores financeiros na área de Contabilidade com a utilização de Inteligência Artificial

Trabalho de conclusão de curso apresentado ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientadora: Profa. Dra. Solange O. Rezende

USP - São Carlos

2024

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTA TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi, ICMC/USP, com os dados fornecidos pelo(a) autor(a)

Silva, Letícia Cruz da
Predição de indicadores financeiros na área de Contabilidade com a utilização de Inteligência Artificial/ Letícia Cruz da Silva ; Orientadora Profa. Dra. Solange Oliveira Rezende. – São Carlos, 2024.
37 p. : il. (algumas color.) ; 30 cm.

Monografia (MBA em Inteligência Artificial e Big Data) –
Instituto de Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2024.

1. LaTeX. 2. abnTeX. 3. Classe USPSC. 4. Editoração de texto. 5. Normalização da documentação. 6. Tese. 7. Dissertação. 8. Documentos (elaboração). 9. Documentos eletrônicos. I. Rezende, Solange Oliveira, orient. I Título.

Letícia Cruz da Silva

Prediction of financial indicators in the Accounting area using Artificial Intelligence

Monograph presented to the Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, as part of the requirements for obtaining the title of Specialist in Artificial Intelligence and Big Data.

Concentration area: Artificial Intelligence

Advisor: Profa. Dra. Solange Oliveira Rezende

USP - São Carlos

2024

AGRADECIMENTOS

A Deus, por manter a minha fé e me ajudar a superar todos os momentos de dificuldade. A minha mãe Maria de Lourdes Cruz, por me inspirar com a sua garra e sabedoria a lutar por tudo aquilo que sonhamos, ainda que alguns momentos possam ser devastadoramente difíceis em nossas vidas. Ao meu marido Marcos Aurélio, por sempre me apoiar nas escolhas que faço, ser um companheiro especial e estar sempre ao meu lado. Aos meus amados filhos Pets: Clarinho, Kiko, Bob, Cristal, Frajola, Minnei, Nino, Penélope, Luna, Pandora, Alice, Princesa, Amora e Frazinho, aos quais, me dedico desde que os resgatei em situação de rua. A professora Solange e Roseli, por me proporcionarem o primeiro contato com o assunto, na Escola Avançada de Big Data Analysis em 2020. Aos professores e coordenadores do curso de MBA em Big Data e Inteligência artificial do ICMC-USP. Agradeço também aos meus colegas de turma Simone Rodrigues da Silva, Ézio José de Oliveira Rego e Arosti Nahas pela parceria e momentos de troca ao longo do curso.

DEDICATÓRIA

A minha filha Tuty (In Memoriam), por me mostrar o real sentido da vida, por ter me ensinado a ser forte, me permitir conviver com um espírito cheio de luz e me propiciar momentos que serão eternamente guardados em minha memória. Te amarei para todo o sempre minha pequena.

“A imaginação é mais importante que o conhecimento, porque o conhecimento é limitado, ao passo que a imaginação abrange o mundo inteiro.”

Albert Einstein

RESUMO

SILVA, Letícia Cruz da Predição de indicadores financeiros na área de Contabilidade com a utilização de Inteligência Artificial 2024. 37 f. Trabalho de conclusão de curso (MBA em Inteligência Artificial e Big Data) do Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, 2024.

Os indicadores financeiros de uma instituição, apresentam como premissa subsidiar informações relevantes para que os gestores e administradores possam ter o real conhecimento sobre a saúde financeira da organização. Com isso, se torna necessário a tempestividade na obtenção desses indicadores. Neste contexto, existe espaço para aplicação de Inteligência Artificial? A utilização de aprendizado de máquina pode auxiliar em algo? É possível ter essa informação de forma preditiva com o auxílio da IA? Como a IA pode contribuir neste processo de automação e predição das informações? Quais outras oportunidades permitem a implementação da IA? A resposta, parece difícil, mas já existem diversas reflexões sobre a utilização da IA na área de contabilidade. Nesse trabalho, Predição de indicadores financeiros na área de Contabilidade com a utilização de Inteligência Artificial, foram avaliadas soluções capazes de resolver a predição de indicadores financeiros na área de contabilidade com a utilização do aprendizado profundo, bem como oportunidades e desafios em criação de indicadores financeiros com IA na área de contabilidade. Também permitiu, tangibilizar o quão prejudicial é a falta da tecnologia nos processos de contabilidade em comparação com os benefícios que a IA pode trazer para os negócios, e constatar, que com a aplicação da IA, é possível ter a predição de forma tempestiva dos indicadores financeiros, mesmo quando os indicadores oscilam, bem como se antecipar a possíveis cenários.

Palavras-chave: Contabilidade; IA; Aprendizado Profundo; Indicadores Financeiros; Predição; Automação; Tempestividade; Aprendizado de máquina.

ABSTRACT

SILVA, Leticia Cruz da. Prediction of financial indicators in the Accounting area using Artificial Intelligence. 2024. 37 f. Completion of course work (MBA in Artificial Intelligence and Big Data) – Institute of Mathematics and Computer Science, University of São Paulo, São Carlos, 2024.

The premise of an institution's financial indicators is to support relevant information so that managers and administrators can have knowledge about the organization's financial health. Therefore, it is necessary to be timely in obtaining these indicators. In this context, is there room for the application of Artificial Intelligence? Can the use of machine learning help with anything? Can we have this information in a predictive way with the help of AI? How can AI contribute to this process of automating and predicting information? What other opportunities can we find with the implementation of AI? The answer seems difficult, but we have already found several reflections on the use of AI in the accounting area. In 1959, Arthur Lee Samuel, an engineer at MIT, defined machine learning as “a field of study that gives computers the ability to learn without being programmed to do so”. In this work, Prediction of financial indicators in the area of Accounting using Artificial Intelligence, solutions capable of solving the prediction of financial indicators in the area of accounting using deep learning were evaluated, as well as opportunities and challenges in creating financial indicators with AI in the accounting area. Finally, it was possible to make tangible how harmful the lack of technology is in accounting processes compared to the benefits that AI can bring to business. Therefore, it was possible to verify that with the application of AI, it is possible to predict financial indicators as well as anticipate possible scenarios.

Keywords: Accounting; AI; Neural networks; Deep Learning; Financial Indicators; Prediction; Automation; Machine learning.

LISTA DE FIGURAS

Figura 1 – Representação do esquema de funcionamento de uma rede neural artificial. Fonte: https://parajovens.unesp.br/o-que-e-uma-rede-social-e-para-que-serve/	21
Figura 2 – Marcos no desenvolvimento das redes neurais. Fonte: www.deeplearningbook.com.br/uma-breve-historiadasredesneuraisartificiais/	21
Figura 3 – Representação de algumas Arquiteturas de Redes Neurais. Fonte: https://www.asimovinstitute.org/neural-network-zoo/	22
Figura 4 – Representação do esquema de uma Célula Neuronal. Fonte: https://sites.icmc.usp.br/andre/research/neural/	24
Figura 5 – Representação do esquema de unidade MCCulloch – Pitts. Fonte: https://sites.icmc.usp.br/andre/research/neural/	24
Figura 6 – Representação do esquema de uma rede neural artificial. Fonte: https://sites.icmc.usp.br/andre/research/neural/	25
Figura 7 – Representação das etapas do processo. Fonte: Rezende, S. O. Sistemas inteligentes: fundamentos e aplicações. Editora Manole Ltda, 2003.....	26
Figura 8 – Representação variável alvo. Fonte: Autora.....	27
Figura 9 – Representação das variáveis. Fonte: Autora.....	27
Figura 10 – Análise da relação entre as variáveis. Fonte: Autora.....	28
Figura 11 – Representação da avaliação do modelo - MLP. Fonte: Autora.....	30
Figura 12 – Representação do valor real e previsão comparado ao historico dos dados - MLP. Fonte: Autora.....	30
Figura 13 – Representação da avaliação do modelo: Valor Real x Valor Previsto - MLP. Fonte: Autora.....	30
Figura 14 – Avaliação do modelo do treino x validação - LSTM. Fonte: Autora.....	31
Figura 15 – Representação da avaliação do modelo - LSTM. Fonte: Autora.....	31
Figura 16 – Representação da avaliação do modelo: Valor Real x Valor Previsto - LSTM. Fonte: Autora.....	32
Figura 17 – Representação da avaliação do Treino x Validação - GRU. Fonte: Autora.....	32
Figura 18 – Representação da avaliação do modelo - GRU. Fonte: Autora.....	33
Figura 19 – Representação da avaliação do modelo: Valor Real x Valor Previsto - GRU. Fonte: Autora.....	33
Figura 20 – Representação da avaliação do Treino x Validação - CNN. Fonte: Autora.....	34
Figura 21 – Representação da avaliação do Treino x Validação - GRU. Fonte: Autora.....	34
Figura 22 – Representação da avaliação do modelo - GRU. Fonte: Autora.....	34
Figura 23 – Representação com a predição dos indicadores. Fonte: Autora.....	35

LISTA DE TABELAS

Tabela 1 – Comparação das métricas de cada técnica utilizada.....	35
--------------------------------------------------------------------------	----

LISTA DE ABREVIATURAS E SIGLAS

IA - Inteligência Artificial
RPA - Robotic Process Automation
RNR – Rede Neural Recorrente
SVM - Máquinas de Vetores de Suporte
PCA - Análise de Componentes Principais
LSTM - Long Short Term Memory
GRU - Arquitetura Gated Recurrent Units

SUMÁRIO

1 INTRODUÇÃO	17
1.1 Contextualização	17
1.2 Justificativa	17
1.3 Objetivos	18
2 FUNDAMENTAÇÃO.....	19
2.1 Desafios na Contabilidade.....	19
2.2 Mineração de Dados e Técnicas Preditivas.....	20
2.3 Breve História das Redes Neurais Artificiais.....	21
2.4 Principais tipos de arquiteturas de Redes Neurais.....	22
2.5 Redes Neurais Recorrentes para Séries Temporais.....	23
2.5.1 Long Short Term Memory (LSTM)	23
2.5.2 Arquitetura Gated Recurrent Units (GRUs).....	23
2.6 Deep Learning.....	23
3 PROPOSTA: PREDIÇÃO DE INDICADORES FINANCEIROS	25
3.1 Identificação do problema	26
3.2 Pré processamento e exploração dos dados	26
3.3 Descrição dos pacotes utilizados	28
3.4 Técnicas utilizadas	28
3.5 Extração de padrões e modelagem	29
3.6 Pós processamento	29
3.6.1 Resultados obtidos com MLP.....	30
3.6.2 Resultados obtidos com LSTM	31
3.6.3 Resultados obtidos com GRU	32
3.6.4 Resultados obtidos com CNN	33
3.7 Uso do Conhecimento	35
4 CONCLUSÕES E TRABALHOS FUTUROS	36
5 REFERÊNCIAS	37

1 INTRODUÇÃO

1.1 Contextualização

A Inteligência Artificial (IA), traz diversas soluções para suprir as necessidades das organizações, permitindo assim, alavancar os negócios substancialmente. Isso propicia a reflexão de como a IA pode contribuir com a automação de atividades repetitivas, e que carecem de técnicas preditivas. Será possível, ganhar celeridade, nas informações que necessitam de agilidade na tomada de decisão, em especial, indicadores financeiros? A predição, é mais uma das aplicações que a IA está propiciando beneficiar a estratégia das empresas.

Nos últimos tempos, inúmeras organizações estão reestruturando os seus processos, e até mesmo, direcionando os colaboradores para a execução de novas tarefas, com o auxílio de Inteligência Artificial e automação das atividades. Assim como tantas outras áreas, os setores de contabilidade, controladoria e finanças também estão mirando em excelência operacional. Com o avanço da tecnologia, o poder da análise preditiva, aliada as técnicas de IA, está permitindo implicações positivas e a reconfiguração dessas atividades [1] [3] [5].

O que por sua vez, permite aos líderes refletirem dia após dia, se é possível melhorar o formato de atuação. Poderá a IA, apoiar na predição de indicadores financeiros? A IA, afetará as predições que atualmente, são realizadas de forma manual?

A predição, é um processo que utiliza-se dos dados históricos e padrões identificados para fazer previsões, permitindo antecipar-se a possíveis cenários de forma precisa e embasada nos dados. Por meio de eventos passados, é possível treinar os modelos com essas entradas, gerando saídas, com informações valiosas para a tomada de decisão. Para isso, utiliza-se técnicas de árvore de decisão, classificação, regressão, agrupamento, redes neurais, inferência bayesiana, redes neurais, por reforço, aprendizado profundo, dentre outras abordagens [9].

Portanto, espera-se com esse trabalho, enfatizar o quão valioso será, agregar o uso da IA com a automação de processos no dia a dia daqueles que atuam na entrega de indicadores financeiros. Apresentar as fases de pré-processamento, e possíveis desafios durante a execução. Compreender como está o estado da arte para essa área de estudo, e promover mudanças positivas, minimizando a atuação manual daqueles que trabalham na concepção dos indicadores financeiros das organizações. Por fim, ilustrar e mensurar os ganhos e desafios.

1.2 Justificativa

Nos últimos anos, muitas empresas têm reestruturado seus processos e redirecionado seus colaboradores para tarefas mais estratégicas, com o apoio da IA e da automação. Setores como contabilidade, controladoria e finanças estão buscando a excelência operacional através da adoção dessas tecnologias. A análise preditiva, impulsionada pela IA, está permitindo uma reconfiguração positiva dessas atividades, proporcionando aos líderes empresariais a oportunidade de melhorar continuamente suas estratégias de atuação.

Os indicadores financeiros são insumos essenciais para que gestores e administradores obtenham uma visão clara e precisa da saúde financeira de uma organização. A tempestividade na obtenção desses indicadores é crucial, pois permite a tomada de decisões informadas e estratégicas em tempo hábil. No entanto, a obtenção rápida e precisa desses dados pode ser um desafio significativo. É nesse contexto que a aplicação de Inteligência Artificial (IA) e aprendizado de máquina se apresenta como uma solução inovadora e eficaz.

A utilização de IA na contabilidade pode revolucionar a forma como os indicadores financeiros são gerados e analisados. Com o aprendizado profundo, é possível processar grandes volumes de dados e identificar padrões complexos que seriam imperceptíveis aos métodos tradicionais. Isso não apenas melhora a precisão das previsões, mas também permite a antecipação de cenários futuros,

proporcionando uma vantagem competitiva significativa para as organizações.

Além disso, a automação de processos contábeis com IA pode reduzir a incidência de erros humanos, aumentar a eficiência operacional e liberar os profissionais para se concentrarem em atividades mais estratégicas e de maior valor agregado. A implementação de IA na contabilidade também abre novas oportunidades, como a análise em tempo real de dados financeiros, a detecção de fraudes e a personalização de relatórios financeiros.

A predição, que utiliza dados históricos e padrões identificados para antecipar cenários futuros, é uma das aplicações mais promissoras da IA. Técnicas como árvores de decisão, classificação, regressão, agrupamento, redes neurais, inferência bayesiana, aprendizado por reforço e aprendizado profundo são empregadas para treinar modelos que geram informações valiosas para a tomada de decisão.

A relevância deste trabalho, reside na necessidade crescente de inovação na contabilidade e na busca por métodos mais eficazes para a gestão financeira. A aplicação de IA não só promete melhorar a tempestividade e a precisão dos indicadores financeiros, mas também transformar a prática contábil, tornando-a mais proativa e estratégica. A falta de tecnologia nos processos contábeis pode ser prejudicial, enquanto os benefícios que a IA pode trazer são vastos e significativos.

Portanto, este trabalho pretende tangibilizar a importância da IA na predição de indicadores financeiros, demonstrando como essa tecnologia pode contribuir para a automação e predição de informações, e explorar outras oportunidades que podem surgir com sua implementação.

1.3 Objetivos

O objetivo deste trabalho é demonstrar como a aplicação de Inteligência Artificial (IA) e aprendizado de máquina pode transformar a análise e predição de indicadores financeiros na área de contabilidade. A pesquisa busca avaliar soluções que utilizam aprendizado profundo para a predição de indicadores financeiros, explorando as oportunidades e desafios dessa tecnologia. Especificamente pretende-se:

1. Avaliar a eficácia da IA na predição de indicadores financeiros: Analisar como a IA pode melhorar a precisão e a tempestividade na obtenção de indicadores financeiros, permitindo uma visão mais clara e antecipada da saúde financeira da organização;
2. Explorar a automação de processos contábeis: Investigar como a automação com IA pode reduzir erros humanos, aumentar a eficiência operacional e liberar os profissionais para atividades mais estratégicas;
3. Identificar padrões e tendências: Utilizar aprendizado profundo para identificar padrões e tendências em grandes volumes de dados financeiros que seriam imperceptíveis aos métodos tradicionais;
4. Explorar a aplicação da IA na contabilidade: Investigar como a IA pode ser integrada aos processos contábeis para melhorar a eficiência e a precisão na geração de indicadores financeiros;
5. Propor um modelo preditivo: Desenvolver e validar um modelo preditivo de indicadores financeiros utilizando técnicas de aprendizado de máquina, demonstrando sua aplicabilidade e vantagens;

Este TCC busca, portanto, não apenas demonstrar a viabilidade técnica da aplicação da IA na predição de indicadores financeiros, mas também evidenciar os benefícios estratégicos e operacionais que essa tecnologia pode trazer para a contabilidade e a gestão financeira das organizações.

2 FUNDAMENTAÇÃO

A busca por ganho de agilidade e tempestividade na tomada de decisão se faz presente nas pesquisas acadêmicas. Atualmente, muito se fala sobre automação robótica de processos (RPA), e o desenvolvimento de softwares que auxiliem no atendimento dessa necessidade. Estudos revelam, a importância em direcionar os colaboradores para tarefas que possibilitem explorar o potencial humano. Com isso, observa-se o uso de soluções tecnológicas em atividades repetitivas [1] [3] [9].

Por outro lado, ainda existem lacunas a serem exploradas em atividades com alto grau de complexidade. Isso acaba desafiando a busca por determinadas soluções. Nesse contexto, o estudo de técnicas de previsão por meio de Inteligência Artificial (IA) surge como uma oportunidade promissora para atender a essa demanda.

A aplicação de IA, especialmente através do aprendizado de máquina e aprendizado profundo, pode transformar a maneira como as organizações lidam com dados complexos e não lineares. A previsão de indicadores financeiros, por exemplo, pode se beneficiar enormemente dessas tecnologias, proporcionando maior precisão e tempestividade na obtenção de informações cruciais para a tomada de decisão [5]. A IA pode não apenas automatizar processos, mas também oferecer insights preditivos que auxiliam na antecipação de cenários futuros, melhorando a gestão proativa das finanças empresariais [9].

Dessa forma, destaca-se o uso de técnicas de previsão por meio de soluções de IA, como uma oportunidade para satisfazer essa demanda. As áreas que se beneficiam com tais soluções de automação, muitas vezes, ainda se limitam a tarefas operacionais. Como exemplo, processos contábeis, fiscais e trabalhistas. Isso reforça a importância de se aprofundar em soluções para a automação de atividades com cunho estratégico [1] [2] [3] [9].

A literatura acadêmica já apresenta diversas reflexões sobre a utilização da IA na contabilidade, destacando tanto as oportunidades quanto os desafios. A implementação de soluções de aprendizado profundo, por exemplo, pode enfrentar obstáculos técnicos e organizacionais, mas os benefícios potenciais superam os desafios [1] [2] [5].

Portanto, aprofundar-se em soluções de IA para a automação e previsão de indicadores financeiros é não apenas relevante, mas necessário. A tecnologia pode transformar a prática contábil, oferecendo maior precisão, eficiência e capacidade de antecipação. Este estudo busca contribuir para a literatura existente, oferecendo uma análise detalhada das oportunidades e desafios, bem como propondo soluções práticas para a implementação eficaz da IA na contabilidade [1] [5].

2.1 Desafios na Contabilidade

Projetar informações futuras, se antecipar a cenários, e tomar decisões de forma tempestiva é um grande desafio para profissionais da área contábil. No dia a dia, os colaboradores precisam atuar contra o tempo para satisfazer prazos e demandas urgentes. Dessa forma, analisar grandes volumes de dados, realizar projeções e extrair possíveis insights pode ser uma tarefa desafiadora. Encontrar profissionais especializados para automação e construção de modelos preditivos também pode ser considerado um gargalo.

Por outro lado, gestores e clientes ambicionam precisão nas informações disponibilizadas, e que o profissional tenha mais tempo para atuar de forma consultiva se antecipando a possíveis cenários e apoio nas estratégias das organizações.

Dentre as informações que são reportadas pelo profissional, e que são essenciais no dia a dia do profissional, temos o Ativo. O ativo é um componente importante nas demonstrações financeiras. Ele permite a avaliação da posição financeira da entidade. É uma informação crucial para apoiar na tomada de decisões e refletir com transparência os recursos que a organização utiliza para gerar receitas e consequentemente lucros.

Se antecipar a possíveis cenários que possam influenciar a estratégia da empresa é fundamental para

garantir a sustentabilidade e a competitividade da empresa. O declínio dos ativos pode ter forte impacto perante as áreas operacionais e financeiras. Para evitar esses impactos se faz necessário adotar uma postura proativa, atualizações tecnológicas e automação dos processos.

2.2 Mineração de Dados e Técnicas Preditivas

A mineração de dados, ou *data mining*, é um processo que envolve a análise de grandes volumes de dados para identificar padrões, tendências e anomalias que não são facilmente perceptíveis [4] [10]. Permite prever tendências e consegue processar e analisar dados em grande escala. Utilizada amplamente em várias organizações, ajuda na transformação de dados brutos para informações valiosas.

Dentre as principais técnicas é possível citar:

1. Regressão;
2. Classificação;
3. Associação;
4. Séries Temporais;
5. Redes Neurais;
6. Agrupamento (Clusterig).

São métodos avançados que utilizam dados históricos, algoritmos estatísticos e técnicas de machine learning para prever eventos futuros. Dentre as principais técnicas é possível citar:

1. Regressão Linear e Logística;
2. Árvores de Decisão;
3. Florestas Aleatórias;
4. Redes Neurais;
5. Máquinas de Vetores de Suporte (SVM);
6. Análise de Séries Temporais;
7. K-Means Clustering;
8. Análise de Componentes Principais (PCA).

Essas técnicas são fundamentais para a análise preditiva, propiciam extrair insights valiosos e a realização de previsões precisas. Com isso, permiti-se as organizações a tomada de decisões de forma tempestiva e com diferencial estratégico.

Entre as técnicas preditivas mais relevantes estão as técnicas de aprendizado de máquina (machine learning) e o aprendizado profundo (deep learning). O aprendizado de máquina envolve a criação de algoritmos que podem aprender e fazer previsões a partir de dados. Esses algoritmos são treinados com grandes volumes de dados históricos e, uma vez treinados, podem prever resultados futuros com base em novos dados. Na contabilidade, isso pode incluir a previsão de receitas, despesas, fluxos de caixa e outros indicadores financeiros.

O aprendizado profundo, uma subcategoria do aprendizado de máquina, utiliza redes neurais artificiais com múltiplas camadas para modelar padrões complexos nos dados. Essa técnica é particularmente eficaz para lidar com grandes volumes de dados e identificar relações não lineares que podem não ser evidentes através de métodos tradicionais. Na contabilidade, o aprendizado profundo pode ser utilizado para detectar fraudes, prever falências e analisar tendências financeiras.

A aplicação dessas técnicas preditivas na contabilidade oferece vários benefícios. Permite uma análise mais precisa e tempestiva dos indicadores financeiros, o que é crucial para a tomada de decisões estratégicas.

No entanto, a implementação dessas técnicas também apresenta desafios. A qualidade dos dados é fundamental para a eficácia dos modelos preditivos, e a coleta e preparação de dados podem ser tarefas complexas e demoradas. Além disso, a interpretação dos resultados preditivos requer conhecimento

especializado, tanto em contabilidade quanto em ciência de dados.

Apesar desses desafios, a automação e a predição na contabilidade através de técnicas de IA representam uma área de grande potencial. Ainda que obstáculos técnicos e organizacionais muitas vezes se façam presentes, os benefícios potenciais superam os desafios [5].

2.3 Breve História das Redes Neurais Artificiais

O desenvolvimento do cérebro humano é mais intenso nos primeiros dois anos, mas continua ao longo da vida. Pesquisadores se inspiraram, para criar sistemas inteligentes, resultando no modelo de neurônio artificial e redes neurais, capazes de realizar tarefas de classificação e reconhecimento de padrões [12].

Em 1943, Warren McCulloch e Walter Pitts publicaram um artigo modelando uma rede neural simples com circuitos elétricos para explicar o funcionamento dos neurônios. Este trabalho foi fundamental para o desenvolvimento das redes neurais artificiais [12].




Figura 1 – Representação do esquema de funcionamento de uma rede neural artificial.
 Fonte: < <https://parajovens.unesp.br/o-que-e-uma-rede-social-e-para-que-serve/> >

Abaixo, a representação dos demais marcos históricos que se sucederam para evolução e pesquisa [12].

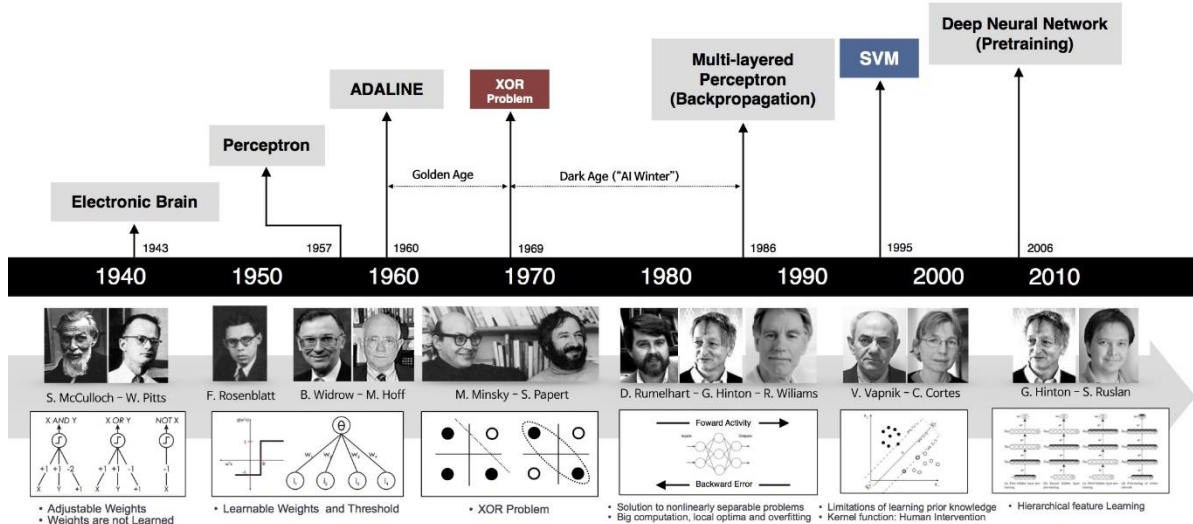


Figura 2 – Marcos no desenvolvimento das redes neurais.
 Fonte: < <https://www.deeplearningbook.com.br/uma-breve-historia-das-redes-neurais-artificiais/> >

2.4 Principais tipos de arquiteturas de Redes Neurais

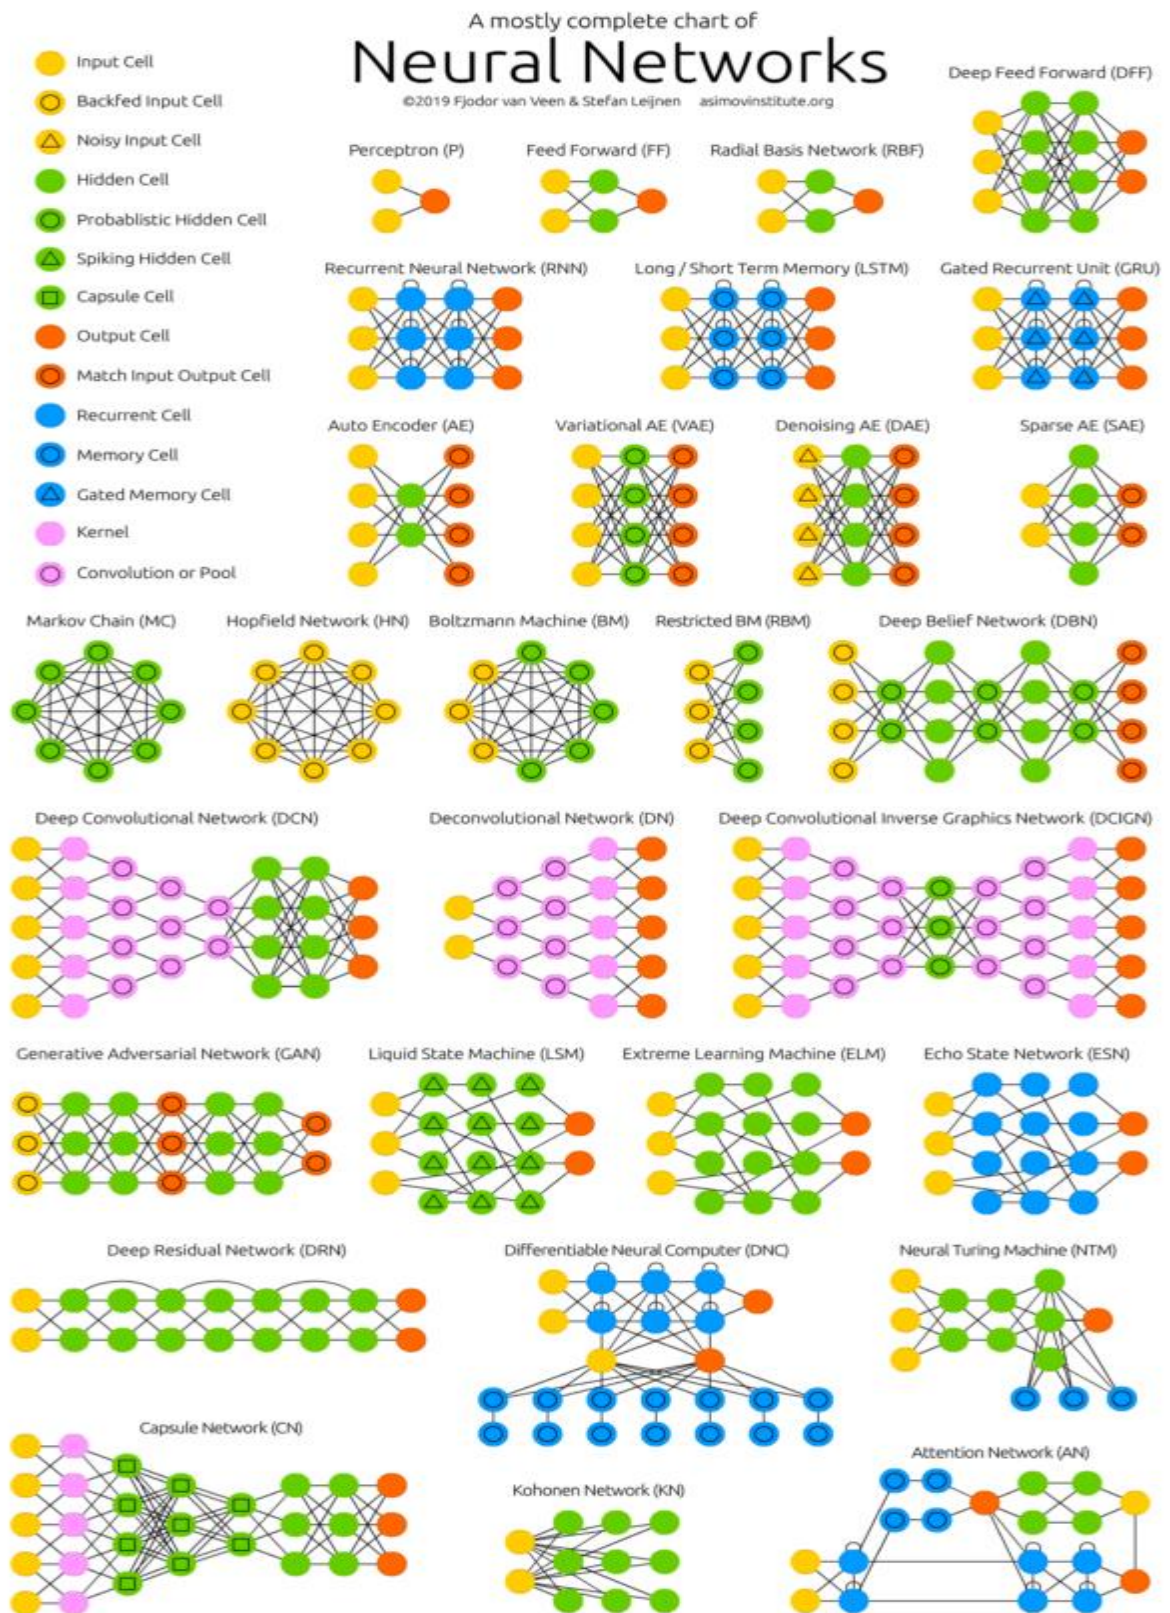


Figura 3 – Representação de algumas Arquiteturas de Redes Neurais.

Fonte: < <https://www.asimovinstitute.org/neural-network-zoo/> >

Dentre as principais arquiteturas disponíveis para Redes Neurais Artificiais, temos [6][8][12]:

1. **Perceptron Simples:** É a forma mais básica, consistindo em apenas uma camada de neurônios.
2. **Redes Neurais Feedforward:** Informação transmitida em uma única direção, da entrada para a saída.
3. **Redes Neurais Convolucionais (CNNs):** Principalmente usadas para reconhecimento de imagens, são formadas por camadas convolucionais que identificam características locais.
4. **Redes Neurais Recorrentes (RNNs):** Projetadas para lidar com dados sequenciais, como séries temporais e textos, possuem conexões cíclicas que permitem a retenção de estados anteriores.

2.5 Redes Neurais Recorrentes para Séries Temporais

As redes neurais recorrentes (RNNs) são projetadas para reconhecer padrões em sequências de dados, como séries temporais. Logo, são particularmente úteis em tarefas onde a ordem dos dados é crucial, como na previsão de séries temporais, tradução de idiomas e reconhecimento de fala.

Diferente das redes neurais tradicionais, as RNNs possuem uma “memória” interna que lhes permite manter informações sobre entradas anteriores. Isso é essencial para capturar dependências temporais nos dados ou que envolvam dados sequenciais.

Existem várias arquiteturas de RNNs, sendo as mais comuns as Long Short-Term Memory (LSTM) e as Gated Recurrent Units (GRU). Elas foram desenvolvidas para resolver problemas de longo prazo, como o desaparecimento do gradiente, que afeta as RNNs tradicionais [6] [8]. São redes com loops, permitindo que as informações persistam [12].

2.5.1 Long Short Term Memory (LSTM)

Em 1997, Sepp Hochreiter e Jürgen Schmidhuber propuseram o LSTM como uma solução para problemas de gradiente. Eles introduziram células de memória que podem manter informações por longos períodos, controladas por três tipos de portas: a porta de entrada, a porta de esquecimento e a porta de saída. O LSTM tem ampla aplicação como tarefas de reconhecimento de fala, geração de texto, previsão de séries temporais, análise de sentimentos, dentre outras tarefas.


2.5.2 Arquitetura Gated Recurrent Units (GRUs)

Gated Recurrent Units (GRUs), arquitetura de rede neural recorrente (RNN) proposta por Kyunghyun Cho et al. As GRUs foram desenvolvidas como uma simplificação das Long Short-Term Memory (LSTM) para lidar com os problemas de dependências de longo prazo e desaparecimento do gradiente, comumente encontrados em RNNs tradicionais. As GRUs também são úteis para tarefas envolvendo sequências, como processamento de linguagem natural, reconhecimento de fala e séries temporais [8].

2.6 Deep Learning

Deep Learning (Aprendizado Profundo), é um subcampo do aprendizado de máquina. Utiliza redes neurais artificiais com múltiplas camadas (deep neural networks) para modelar padrões complexos em grandes volumes de dados. Redes Neurais Artificiais são métodos computacionais que utilizam um modelo matemático baseado na estrutura neural de seres inteligentes, aprendendo e adquirindo conhecimento por meio da experiência [11]. O sistema nervoso é composto por uma rede muito complexa de células chamadas neurônios. Eles desempenham um papel crucial no controle das funções e comportamentos do corpo humano, bem como no raciocínio. Os neurônios consistem em dendritos, que são terminais de entrada, um corpo celular central, e axônios, que são longos terminais de saída.

A seguir, uma figura com a representação da célula neuronal humana [8].




Constituintes da célula neuronal - esquema.

Figura 4 – Representação do esquema de uma Célula Neuronal
 Fonte: <<https://sites.icmc.usp.br/andre/research/neural/>>

Os neurônios se comunicam por meio de sinapses, que são áreas de contato entre dois neurônios onde os impulsos nervosos são transmitidos. Quando um neurônio A recebe impulsos, ele os processa e, ao atingir um certo limiar, dispara, liberando neurotransmissores que viajam do corpo celular ao longo do axônio até um dendrito de outro neurônio B. Esses neurotransmissores podem alterar a polaridade da membrana pós-sináptica, podendo inibir ou excitar a geração de novos impulsos no neurônio B. Esse processo é influenciado por diversos fatores, como a estrutura da sinapse e o tipo de neurotransmissor envolvido [6] [8] [11].

Por sua vez, uma rede neural artificial consiste em múltiplas unidades de processamento, cujo funcionamento é relativamente simples. Essas unidades são geralmente interligadas por canais de comunicação, cada um com um peso específico. As unidades realizam operações apenas com seus dados locais, que são as entradas recebidas através de suas conexões. A inteligência de uma Rede Neural Artificial surge das interações entre essas unidades de processamento. A operação de uma unidade de processamento, proposta por McCullock e Pitts em 1943, pode ser descrita da seguinte forma:

1. Sinais são apresentados na entrada;
2. Cada sinal é multiplicado por um peso, que determina sua influência na saída da unidade;
3. A soma ponderada dos sinais é calculada, resultando em um nível de atividade;
4. Se esse nível de atividade ultrapassar um certo limite (threshold), a unidade gera uma resposta de saída específica [6] [8] [11].



Esquema de unidade McCullock - Pitts.

Figura 5 – Representação do esquema de unidade MCCullock – Pitts.
 Fonte: <<https://sites.icmc.usp.br/andre/research/neural/>>




Figura 6– Representação do esquema de uma rede neural artificial.
 Fonte: <<https://sites.icmc.usp.br/andre/research/neural/>>

1. **Camada de Entrada:** onde os padrões são apresentados à rede;
2. **Camadas Intermediárias:** onde é feita a maior parte do processamento;
3. **Camada de Saída:** onde o resultado final é concluído e apresentado [11].

A aplicação de Deep Learning na predição de indicadores financeiros contábeis é uma área promissora que pode propiciar a tempestividade na obtenção dos indicadores e fazer uma mudança significativa na predição das informações com previsões mais precisas. Dessa forma, reduzindo a necessidade de uma tarefa até então realizada em muitas organizações de forma manual. Permitindo também, redução de tempo e recursos. Porém, a precisão do modelo requer qualidade dos dados de entrada necessitando de dados completos.

3 PROPOSTA: PREDIÇÃO DE INDICADORES FINANCEIROS

Com a necessidade de inovação e predição de indicadores financeiros, este trabalho pretende tangibilizar a importância da IA, demonstrando como essa tecnologia poderá contribuir para a automação e predição de informações.

Abaixo, serão apresentadas as etapas percorridas, para resolução do problema levantado inicialmente:

1. Identificação do problema;
2. Exploração dos dados e pré processamento;
3. Extração de padrões e modelagem;
4. Pós-Processamento.



Figura 7 – Representação das etapas do processo.
 Adaptado de: Rezende, S. O. Sistemas inteligentes: fundamentos e aplicações. Editora Manole Ltda, 2003

3.1 Identificação do problema

Antes do início das tarefas do processo, se faz necessário a realização de um estudo. O intuito, é adquirir o conhecimento inicial do assunto [13].

3.2 Pré processamento e exploração dos dados

Essa etapa, permite adequar os dados que serão trabalhados para o formato adequado com a limpeza, transformação e demais tratamentos para iniciar a etapa de extração de padrões [4]. A exploração dos dados é importante para entender o conjunto de dados e identificar possíveis padrões.

As informações trabalhadas, foram extraídas da página de Relações com Investidores do Banco Bradesco [16]. O relatório extraído, foi proveniente dos arquivos de séries históricas da organização referente ao ano de 2019 até o segundo trimestre de 2024.

Dentre as informações disponíveis para escolha, a decisão de utilizar a Sheet de “Ativo Contábil” como objeto de estudo nesse trabalho, decorreu dos insights que esses dados representam. Ativos contábeis, são recursos controlados pela empresa que têm valor econômico futuro e são esperados gerar benefícios. Eles incluem itens como dinheiro, contas a receber, estoques, imóveis e equipamentos. Esses ativos são registrados no balanço patrimonial e ajudam na avaliação da saúde financeira da empresa [14] [15].

A Sheet escolhida, contém 22 linhas (ou trimestres). Foram utilizados 11 indicadores, sendo eles: “disponibilidades”, “instrumentos financeiros”, “oper_arrendamento_mercantil”, “provisao_para_perda_esperada”, “credito_tributario”, “inves_coligada_controlada”, “imobilizado”, “intangivel”, “depreciacao_amortizacoes”, “outros_ativos” e “provisao_valor_recuperavel”.

Os campos foram reestruturados no formato de tabela. As informações são geradas trimestre a trimestre, sendo que o último período fechado, é o segundo trimestre de 2024.

O principal objetivo, ao término do trabalho, será alcançar a predição de indicadores financeiros na área de Contabilidade com a utilização de Inteligência Artificial. E dessa forma, otimizar o trabalho manual e aumentar a segurança no valor previsto e esperado para os trimestres subsequentes.

Cada linha do dataset, representa os valores provenientes dos últimos três meses. As informações trabalhadas, se tratam de uma série multivariada, como temos mais de uma variável. Nesse trabalho, utilizou-se a variável Provisão_para_perda_esperada como variável alvo, as demais, foram utilizadas como variáveis preditoras.

A seguir, será realizado o plot, usando o índice para ver a evolução ao longo do tempo, da variável de Provisao_para_perda_esperada. Por se tratar de uma informação temporal, além das etapas de análise,

se fez indispensável ordenar a informação de trimestre e defini-lá como índice.




Figura 8 – Representação variável alvo.
Fonte: Autora.

Uma alternativa seria a análise univariada, usando o histórico da série. Porém, como o relatório contém outros dados, é possível utilizar as demais variáveis para ver se têm alguma relação. Para a coluna data é realizada a conversão como index da tabela. Utilização do TO_DATETIME para a conversão do dataframe, e posterior gravação como índice do dataframe. Para o formato as datas, utilização do pacote MDATES, pois permite converter a data para m e y (Mês e Ano).

Utilização da função make_subplots para criar plots das 22 linhas e permitir analisar o comportamento de cada série que auxiliarão na previsão da variável alvo.




Figura 9 – Representação das variáveis.
Fonte: Autora.

Com o plot do gráfico a seguir (plot.area), é possível analisar com mais facilidade e ver que as variáveis preditoras apresentam relação entre si:

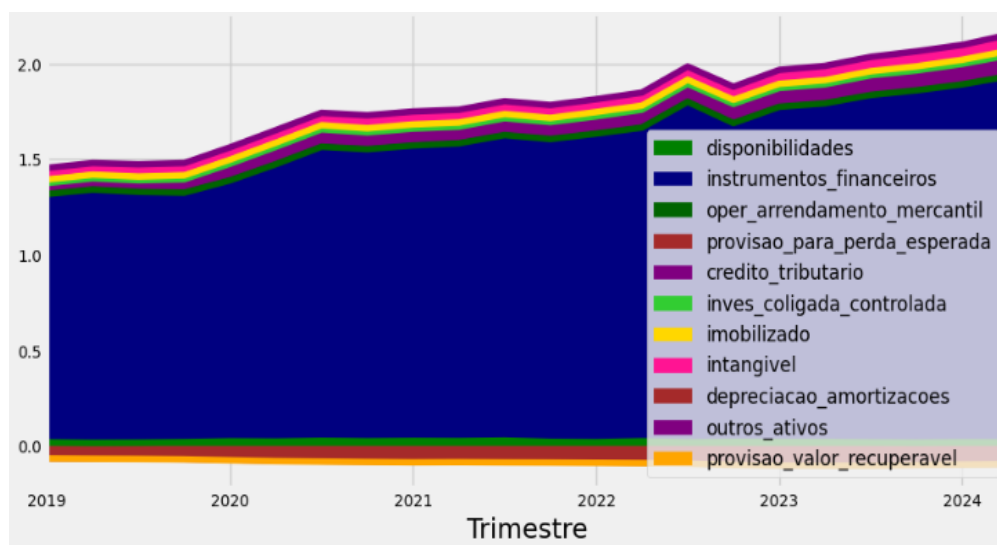


Figura 10 – Análise da relação entre as variáveis.
Fonte: Autora.

3.3 Descrição dos pacotes utilizados

Para alcançar os objetivos estabelecidos e explorar as respostas, para os questionamentos iniciais, esse trabalho abordou o uso de Redes Neurais Artificiais na predição de indicadores financeiros. Dentre os pacotes e bibliotecas que foram utilizados em sua construção, destaca-se o uso de:

O TensorFlow foi utilizado como base para a construção dos modelos. E o Keras, uma API que roda sobre o TensorFlow, facilitando a criação e o treinamento dos modelos de Deep Learning. Para a manipulação dos dados, utilizou-se: Numpy nas operações matemáticas e o Pandas na organização e análise de conjuntos de dados. Para visualização, o Matplotlib, Seaborn e Plotly, utilizados para criar os gráficos e possibilitar as visualizações dos dados. O que permitiu a interpretação dos resultados com maior facilidade. Além desses, também foi empregado o Matplotlib.dates (mdates), para exibir os gráficos que envolviam várias datas, facilitando a apresentação da análise temporal.

Para construção das Camadas da Rede Neural, o uso da função layers do Keras, a qual, contribuiu na criação das diversas camadas da rede neural, cada uma desempenhando um papel específico no processamento das informações trabalhadas. Para o processamento dos dados, utilizou-se:

Sklearn.preprocessing.MinMaxScaler: Importada do pacote preprocessing do Sklearn para padronizar os dados, ajustando-os na mesma escala, esse processo se fez essencial para o treinamento eficaz do modelo.

3.4 Técnicas utilizadas

Dentre os tipos de Redes Neurais que foram trabalhadas, destaca-se a utilização de:

- LSTM (Long Short-Term Memory), um tipo de rede neural recorrente (RNN). Escolhida por ter um bom resultado com dados sequenciais e séries temporais, especialmente quando há dependências de longo prazo;
- CNNs (Convolutional Neural Network), são mais conhecidas por processamento de imagens. Utilizada por também ser empregada para séries temporais;
- GRU é uma variante simplificada das LSTM. Também utilizada por retornar um bom resultado para dados sequenciais. Possui menos portas que o LSTM, o que resulta em uma arquitetura

- mais simples e rápida para treinar;
- MLP é uma rede neural artificial tradicional, composta por múltiplas camadas de perceptrons. Não apresenta o conceito de memória temporal, o que a torna menos adequada para dependências temporais e pode prejudicar a sua performance frente a outras técnicas. Técnica utilizada como ponto de partida, antes de avançar para modelos mais complexos.

Para avaliação, foram utilizadas as métricas abaixo, as quais, permitiram medir qual modelo apresentou melhor performance e aprendizado, frente as informações trabalhadas:

- Mean Directional Accuracy (MDA): Mede a porcentagem de tempo que a direção da previsão corresponde à direção real do valor;
- Mean absolute error: Permite calcular o erro médio absoluto (MAE) entre os valores previstos pelo modelo e os valores reais. Logo, é útil por fornecer uma medida que permiti entender o quão errado é o erro nas previsões do modelo;
- Mean squared error (MSE): Calcula o erro quadrático médio entre as previsões e os valores reais;
- Explained variance score (EVS): Mede a variância explicada pelo modelo entre previsões e valores reais;
- Root squared Error RMSE: usada para medir a precisão das previsões de um modelo em relação aos valores reais. Quanto menor, mais preciso.

3.5 Extração de padrões e modelagem

Na etapa de extração de padrões é realizada a escolha e a configuração de um ou mais algoritmos. Esse momento também permiti compreender qual será a melhor técnica a ser empregada. Importante enfatizar, que muitas vezes, será necessário o ajuste dos parâmetros [4].

Dessa forma, foi realizada a divisão dos dados, sendo que 80% dos dados serão para treino (17 registros), e 20% para teste (5 registros):

```
Tamanho da Amostra de Treino: 17  
Tamanho da Amostra de Teste: 5
```

Como os dados se tratam de uma série temporal, a ordem é necessária devido o componente de data (diferente de outros modelos que se faz necessário ser aleatório).

Os dados, não apresentam a mesma escala, sendo necessário ao se trabalhar com redes neurais artificiais, deixá-los padronizados.

Para isso, é aplicada a normalização das variáveis preditoras por meio do MinMaxScaler do sklearn, depois aplicar o padronizador com o método fit (objeto do MinMaxScaler), para aplicar apenas aos dados de treino com o formato do numpy (como estão no formato pandas, é necessário alterar). Depois, foi aplicado o padronizador com o método transform nos dados de treino e teste ficando os dados padronizados. Para a variável alvo, também foi aplicado um novo padronizador.

Foi criado um dataset final por meio de uma função, onde por meio do loop, são acrescentados a treino e teste (X e Y para ambos).

3.6 Pós processamento

Na etapa de pós processamento, os algoritmos poderão gerar uma grande quantidade de padrões, sendo que muitos, não serão importantes. Logo, é primordial o uso de medidas que possibilitem analisar o desempenho e qualidade dos padrões encontrados [4]. Para análise do desempenho de cada técnica, foram utilizadas as métricas a seguir:

3.6.1 Resultados obtidos com MLP

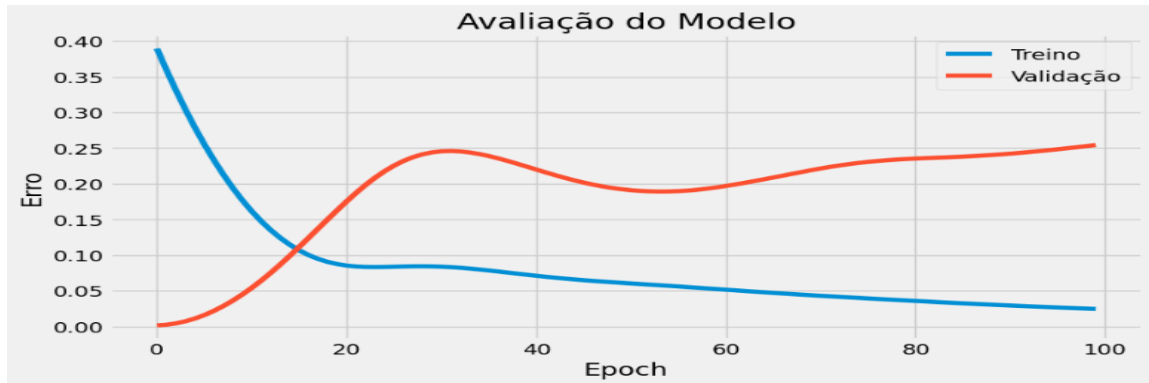


Figura 11 – Representação da avaliação do modelo - MLP
Fonte: Autora.

No eixo X tenho as épocas do modelo, e no Y o erro do modelo.




Figura 12 – Representação do valor real e previsão comparado ao histórico dos dados - MLP.
Fonte: Autora.

Aqui tenho apenas análise do Valor Real x Valor Previsto, embora tenha ficado próximo do real, é importante ver a taxa de erros.

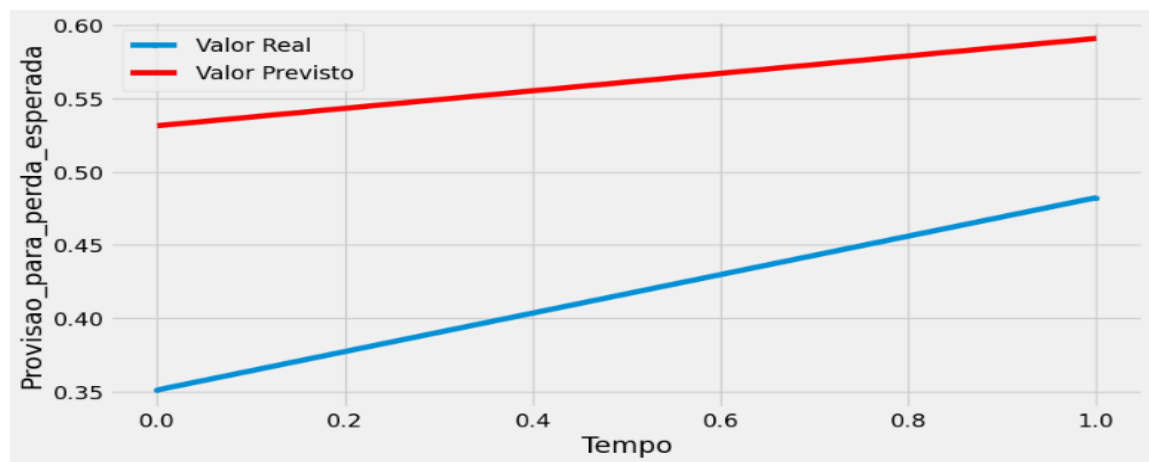


Figura 13 – Representação da avaliação do modelo: Valor Real x Valor Previsto - MLP.
Fonte: Autora.

Métricas – MLP.

MDA: 1.0
MAE: 0.14441244034349987
MSE: 0.022138014264828254
RMSE: 0.14878848834781624
EVS Score: 0.7019668180741527

3.6.2 Resultados obtidos com LSTM

LSTM é uma arquitetura de aprendizado profundo e normalmente retorna uma performance melhor. As etapas de exploração e pré- processamento foram realizadas com os mesmos pacotes e parâmetros. Modificação apenas na mudança da arquitetura.

Etapa de treinamento do modelo e avaliação:




Figura 14 – Avaliação do modelo do treino x validação - LSTM.
Fonte: Autora.




Figura 15 – Representação da avaliação do modelo - LSTM.
Fonte: Autora.




Figura 16 – Representação da avaliação do modelo: Valor Real x Valor Previsto - LSTM.
Fonte: Autora

Métricas – LSTM.

MDA: 1.0
 MAE: 0.05901757101600458
 MSE: 0.005363894083791421
 RMSE: 0.07323861060800799
 EVS Score: 0.1909416152902228

3.6.3 Resultados obtidos com GRU

GRU é uma arquitetura de aprendizado profundo e simplificada em comparação a LSTM. Normalmente retorna uma performance melhor. Foram considerados os mesmos pacotes. Etapas de exploração e Pré-Processamento foram realizadas da mesma forma. Modificação com a mudança da arquitetura.




Figura 17 – Representação da avaliação do Treino x Validação - GRU.
Fonte: Autora.




Figura 18 – Representação da avaliação do modelo - GRU.
Fonte: Autora.

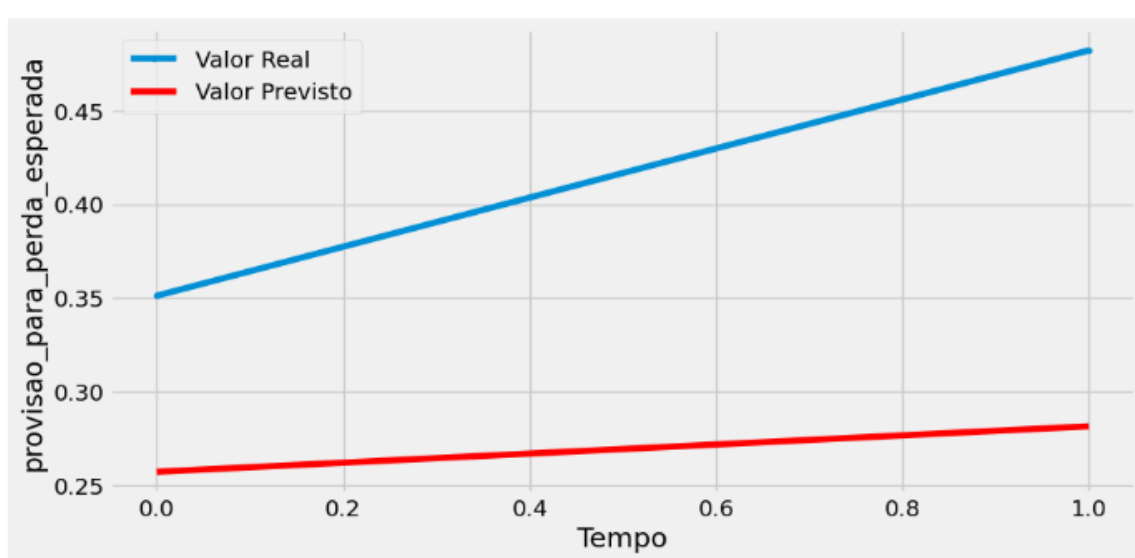


Figura 19 – Representação da avaliação do modelo: Valor Real x Valor Previsto - GRU.
Fonte: Autora.

Métricas – GRU.

MDA: 1.0
 MAE: 0.14757697554051807
 MSE: 0.02463578396091426
 RMSE: 0.15695790506028762
 EVS Score: 0.3364095668116456

3.6.4 Resultados obtidos com CNN

CNN, é uma arquitetura de aprendizado profundo. Embora trabalhe com imagens, funciona com dados em formatos tabulares. Diferente dos outros modelos que atuam com camadas de memória, atua com camadas convolucionais (multiplicação de matrizes). As etapas de exploração e Pré- Processamento foram realizadas sem alterações. Modificação com a mudança da arquitetura. Modelagem por meio do CNN, redução de dimensionalidade com MaxPoolingID.




Figura 20 – Representação da avaliação do Treino x Validação - CNN.
Fonte: Autora.




Figura 21 – Representação da avaliação do modelo - CNN.
Fonte: Autora.

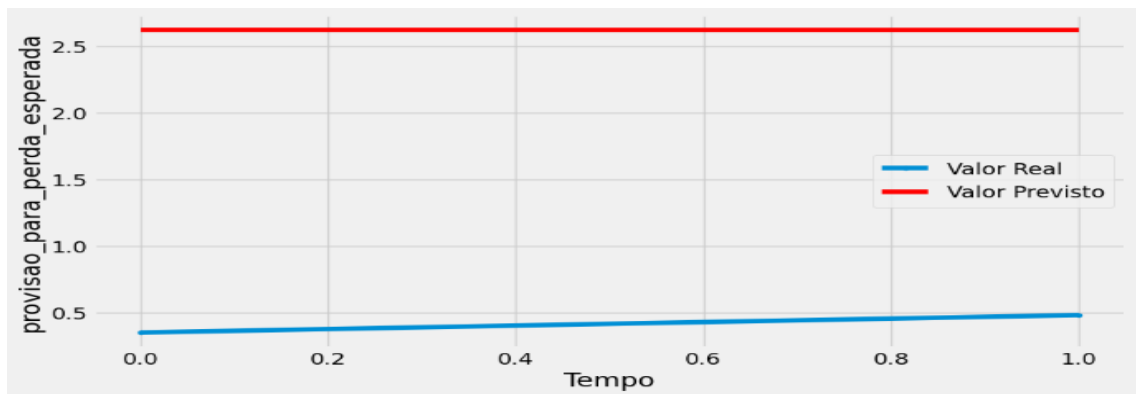


Figura 22 – Representação da avaliação do modelo: Valor Real x Valor Previsto - CNN.
Fonte: Autora

Métricas – CNN.

MDA: 0.0
 MAE: 2.2081616344887025
 MSE: 4.880340203150073
 RMSE: 2.20914920346048
 EVS Score: -0.013310628147980008

Comparação do desempenho para cada técnica utilizada:

MODELO	MDA	MAE	MSE	RMSE	EVS SCORE
MLP	1.0	0.14441244034349987	0.022138014264828254	0.14878848834781624	0.7019668180741527
LSTM	1.0	0.05901757101600458	0.005363894083791421	0.07323861060800799	0.1909416152902228
GRU	1.0	0.14757697554051807	0.02463578396091426	0.15695790506028762	0.3364095668116456
CNN	0.0	2.2081616344887025	4.880340203150073	2.20914920346048	-0.013310628147980008

Tabela 01 – Comparação das métricas de cada técnica utilizada.

Fonte: Autora

Dentre os 4 modelos treinados, o que resultou as melhores métricas com exceção do EVS SCORE, foi a arquitetura LSTM.

Abaixo, predição realizada para todos os indicadores. A possibilidade de antecipar-se a essas informações, possibilita as organizações, a tomada de decisão de forma tempestiva e diferencial estratégico.

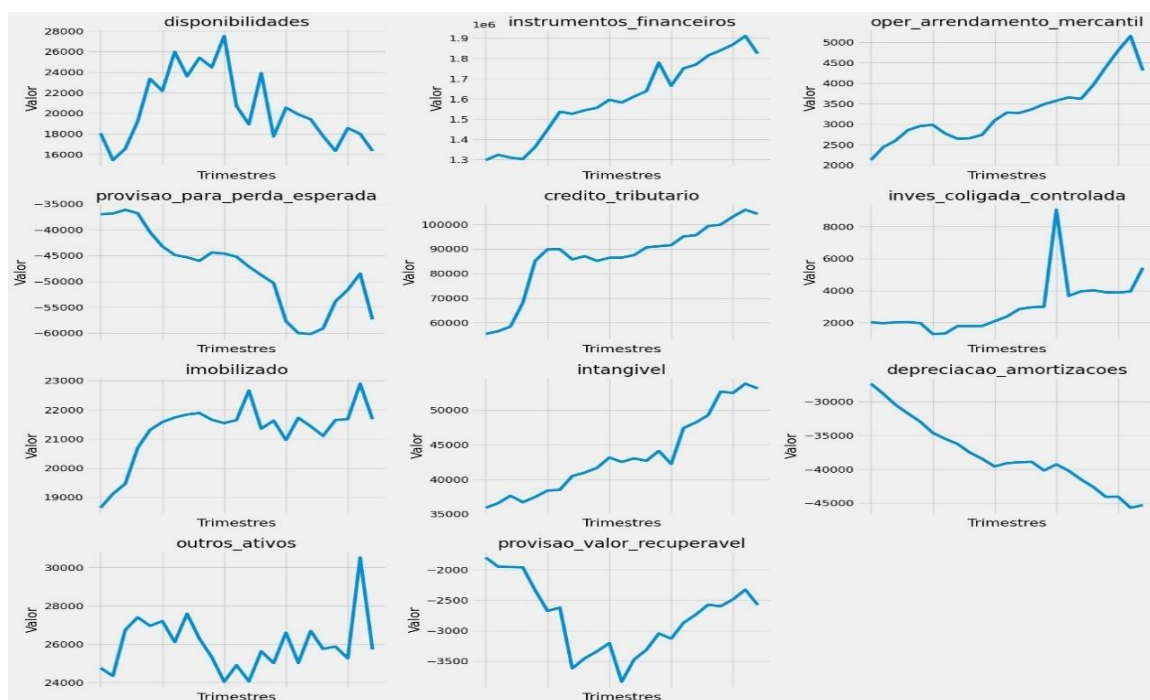


Figura 23 – Representação com a predição dos indicadores.

Fonte: Autora

3.7 Uso do Conhecimento

A sistematização do know-how de uma organização, permite a agilidade no processo de tomada de decisão. Logo, permite tempestividade e qualidade em responder as demandas do mercado.

Com a aquisição do conhecimento necessário, esse estudo poderá contribuir na contabilidade com a redução ou até mesmo eliminação de tarefas que até então eram executadas de maneira totalmente manual para predição de indicadores financeiros. Além da área contábil, outras áreas que compartilham da mesma necessidade, poderão contar com a predição de informações que são primordiais para o sucesso do negócio.

4 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho foi abordado a Predição de indicadores financeiros na área de Contabilidade com a utilização de Inteligência Artificial. O objetivo principal foi realizar a predição de indicadores na área contábil. Ao término, foi possível concluir que com a predição de indicadores, além da área contábil, outros setores também poderão se beneficiar com essas técnicas como Finanças e Controladoria. Esses departamentos, necessitam ganhar tempestividade e se antecipar a possíveis cenários que poderão impactar, ou até mesmo mudar, a direção a ser tomada pela organização.

Atualmente, muitas já estão adicionando aos seus processos, o poder da predição no seu dia a dia. Como exemplo, a medicina na predição de doenças, a área financeira para se antecipar a queda ou aumento do dólar ou venda de ações, o RH para se antecipar a saída de um funcionário ou até mesmo, as áreas de vendas na venda de um produto.

Com a predição dos indicadores, é possível a automação de processos que até então oneram diversas horas ou dias dos colaboradores que ficam imersos nessas atividades. A mudança de estratégia de forma tempestiva, permite as organizações se anteciparem a possíveis cenários.

A Inteligência Artificial, pode apoiar na predição dos indicadores. E além disso, promover a melhoria nos processos vigentes, e o direcionamento dos colaboradores para atividades analíticas gerando resultado para o negócio.

Ao longo do trabalho, foi possível constatar a evolução nas técnicas de predição e seu crescimento ao longo dos anos. A tecnologia está avançando de forma rápida, o que acaba beneficiando aqueles que precisam automatizar e trazer melhorias para o dia a dia.

Entretanto, o desafio de facilitar o acesso para aqueles que não possuem conhecimento técnico, se fazem presentes. Como trabalhos futuros, pode-se considerar a importância de uma interface que facilite a utilização e assimilação de forma simples para os usuários. Além disso, pretende-se incrementar a base de dados que foi utilizada, com informações de novos períodos (trimestres futuros).

5 REFERÊNCIAS

- [1] ASSIS, Andre. **Gestão em Automação nos Processos Contábeis com o uso da Tecnologia**, 2022. Disponível em: <<http://localhost/jspui/handle/123456789/486>>. Acessado em: 04 de Junho de 2024.
- [2] MARTINS, Diego. **Automação Contábil: Menos custo mais agilidade**. Amazon, 2023.
- [3] CORRÊA, Josi. **Como o Grupo São José reduziu em 80% o tempo investido na elaboração de relatórios gerenciais de 28 lojas**. Treasy, 2024.< <https://www.treasy.com.br/blog/grupo-sao-jose/>>. Acessado em: 04 de Junho de 2024.
- [4] REZENDE, S. O. **Sistemas inteligentes: fundamentos e aplicações**. Editora Manole Ltda, 2003
- [5] **Contabilidade preditiva: análise de dados e tomada de decisão**, disponível em <<https://confi.net.br/blog/todos/contabilidade-preditiva-analise-de-dados/>>. Acessado em 05 de Setembro de 2024.
- [6] SILVA, Iran Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes Neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.
- [7] MUELLER, John Paul; MASSARON, Luca. **Aprendizado de máquina para leigos**. Rio de Janeiro : Alta Books, 2019.
- [8] HAYKIN, Simon. **Redes Neurais: princípios e práticas**. 2.ed.. Porto Alegre: Bookman, 2001.
- [9] BARI, Anasse; CHAOUCHI, Mohamed; JUNG Tommy. **Análise Preditiva para Leigos**. Rio de Janeiro: Alta Books, 2019.
- [10] SILVA, Leandro Augusto da; PERES, Sarajane Marques; BOSCARIOLI, Clodis. **Introdução á mineração de dados: com aplicações em R**. Rio de Janeiro: GEN LTC, 2016.
- [11] **Redes Neurais Artificiais**, disponível em <<https://sites.icmc.usp.br/andre/research/neural/>> Acessado em 07 de Setembro de 2024.
- [12] **Deep Learning Book**, disponível em <<https://www.deeplearningbook.com.br/uma-breve-historia-das-redes-neurais-artificiais/>>. Acessado em 08 de Setembro de 2024.
- [13] Fayyad, U., G. Piatetsky-Shapiro, & P. Smyth (1996). **The KDD process for stracting usefull knowledge from volumes of data**. Communication of the ACM 39(11), 27-34.
- [14] RIBEIRO, Osni Moura. **Contabilidade Avançada**. 6.ed.. São Paulo: Saraiva, 2018.
- [15] PADOVEZE, Clóvis Luis. **Manual de Contabilidade Básica**. 9.ed.. São Paulo: Atlas, 2014.
- [16] Relatórios, disponível em <<https://www.bradeskori.com.br/informacoes-ao-mercado/relatorios-e-planilhas/relatorios/>> Acessado em 01 de Outubro de 2024.