

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL  
ESCOLA POLITÉCNICA  
BACHARELADO EM SISTEMAS DE INFORMAÇÃO**

**O USO DA INTELIGÊNCIA ARTIFICIAL PARA AUXILIAR NA  
GESTÃO DE NUMERÁRIO PARA OS CAIXAS ELETRÔNICOS  
DAS AGÊNCIAS**

**HENRIQUE PUGENS RAMIRES**

**Trabalho de Conclusão apresentado  
como requisito parcial à obtenção do  
grau de Bacharel em Sistemas de  
Informação na Pontifícia Universidade  
Católica do Rio Grande do Sul.**

**Orientador: Prof. Silvia Maria W Moraes**

**Porto Alegre  
2024**

# **O USO DA INTELIGÊNCIA ARTIFICIAL PARA AUXILIAR NA GESTÃO DE NUMERÁRIO PARA OS CAIXAS ELETRÔNICOS DAS AGÊNCIAS**

## **RESUMO**

Com a evolução da tecnologia e o surgimento da inteligência artificial (IA) tornou-se possível criar modelos que tenham maior eficiência comparados às atividades que o ser humano pode realizar, principalmente pela capacidade de analisar dados, identificar tendências e comportamentos. Este trabalho de conclusão de curso propõe uma solução de IA para apoiar a previsão de numerário para suprimento e retirada de caixas eletrônicos. Para isso construímos dois modelos de regressão para estimar entradas e saídas de numerário de uma agência bancária. A partir desses valores estimados pode-se definir a necessidade bem como calcular o valor próximo do ideal a ser solicitado para a transportadora de valores. Isso promoverá maior eficiência, menor custo com transporte de valores, possibilitando direcionar o numerário que antes estava ocioso para um empréstimo por exemplo, gerando mais rentabilidade para a instituição financeira e uma maior satisfação para os usuários com a disponibilidade dos serviços que envolvem numerário.

Palavras-Chave: Inteligência Artificial, Numerário, ATM.

<sup>1</sup> refere-se ao dinheiro em espécie, ou seja, as notas que são utilizadas no caixa eletrônico.

# **THE USE OF ARTIFICIAL INTELLIGENCE TO ASSIST IN CASH MANAGEMENT FOR BRANCH ATMS**

## **SUMMARY**

With the evolution of technology and the emergence of artificial intelligence (AI), it has become possible to create models with greater efficiency compared to activities that humans can perform, particularly due to their ability to analyze data, identify trends, and behaviors. This thesis proposes an AI solution to support cash supply and withdrawal prediction for ATMs. To achieve this, we constructed two regression models to estimate cash inflows and outflows at a bank branch. Based on these estimated values, it is possible to determine the cash needs and calculate the ideal amount to be requested from the cash-in-transit company. This will promote greater efficiency, lower transportation costs, and allow the previously idle cash to be redirected to other uses, such as loans, generating more profitability for the financial institution and greater satisfaction for customers with the availability of cash-related services.

Keywords: Intelligence, Artificial, Cash, ATM.

<sup>1</sup>refers to cash, that is, the banknotes that are used in the ATM.

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	<b>9</b>
<b>2. FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>10</b>
2.1 INTELIGÊNCIA ARTIFICIAL (IA) .....	10
2.2 INSTITUIÇÃO FINANCEIRA (BANCO) .....	13
2.3 CAIXA ELETRÔNICO .....	13
2.4 AGÊNCIA .....	13
2.5 TRANSPORTADORA DE VALORES.....	14
2.6 TRABALHOS RELACIONADOS .....	15
<b>3 METODOLOGIA</b> .....	<b>15</b>
<b>4 PROBLEMA DE SUPRIMENTO/RECOLHIMENTO DE NUMERÁRIO</b> .....	<b>17</b>
4.1 PROBLEMÁTICA.....	17
4.2 OBJETIVOS DO ESTUDO.....	18
4.3 OPORTUNIDADES COM GERENCIAMENTO DE NUMERÁRIO.....	19
4.4 RECURSOS NECESSÁRIOS .....	20
<b>5 DATASET</b> .....	<b>20</b>
5.1 OBTENÇÃO DE DADOS .....	20
5.2 ESTRUTURA DOS DADOS DISPONÍVEL.....	21
5.3 MANIPULAÇÃO DE DADOS .....	21
5.3.1 FILTRO POR CENTRAL E AGÊNCIA.....	22
5.3.2 SOMATÓRIO DOS VALORES DOS ATMS DA AGÊNCIA POR DIA .....	23
5.3.3 ANÁLISE DO GRÁFICO DIÁRIO.....	25
5.3.4 SOMATÓRIO DOS VALORES POR SEMANA .....	26
5.4 ESCOLHA DE ATRIBUTOS RELEVANTES PARA O DATASET.....	28
<b>6 DESENVOLVIMENTO</b> .....	<b>28</b>
6.1 TÉCNICA PARA OTIMIZAR HIPERPARÂMETROS.....	29
6.2 MÉTRICAS.....	30
6.3 REGRESSAO LINEAR.....	31
6.3.1 IMPLEMENTAÇÃO.....	31
6.3.2 ANÁLISE DO PROGNÓSTICO GERADO PELO MODELO.....	32
6.4 RANDOM FOREST REGRESSOR.....	36
6.4.1 IMPLEMENTAÇÃO.....	36
6.4.2 ANÁLISE DO PROGNÓSTICO GERADO PELO MODELO.....	37

<b>7 CONCLUSÃO.....</b>	<b>41</b>
<b>8 REFERÊNCIAS.....</b>	<b>43</b>

## LISTA DE FIGURAS

Figura 1 – Arquitetura .....	12
Figura 2 – Fluxo de Numerário.....	17
Figura 3 – Entradas, saídas e saldo por semana de 01/2024 a 05/2024.....	18
Figura 4 – Tabela de fechamento diário de entradas e saídas de dinheiro.....	21
Figura 5 – Método que recebe os fechamentos e filtra por central e agência...22	
Figura 6 – Tabela filtro de uma única central e agência.....	22
Figura 7 – Imagem mostrando que uma agência pode ter N ATMs.....	22
Figura 8 – Método de agrupamento e soma de valores por dia.....	23
Figura 9 – Tabela com agrupamento de valores por dia.....	23
Figura 10 – Tabela de entradas de dinheiro do mês de janeiro.....	24
Figura 11 – Tabela de saídas de dinheiro do mês de janeiro.....	24
Figura 12 – Calendário identificando o número da semana no mês.....	25
Figura 13– Método que calcula o número da semana no mês.....	27
Figura 14 – Método agrupa os valores por semana do mês.....	27
Figura 15 – Tabela das entradas semanais no mês de janeiro.....	27
Figura 16 – Tabela das saídas semanais no mês de janeiro .....	28
Figura 17 – Tabela com o agrupamento de valores dos ATMs.....	28
Figura 18 – Fórmula matemática para o Erro Quadrático Médio.....	30
Figura 19 – Código usado para apresentar Erro Quadrático Médio.....	31
Figura 20 – Código usado para a regressão linear.....	32
Figura 21 – Entradas de dinheiro real e predito validação.....	33
Figura 22 – Comparação de Saídas de dinheiro real e predito.....	33
Figura 23 – Entradas de dinheiro real e predito teste .....	34
Figura 24 – Saídas de dinheiro real e predito teste.....	34
Figura 25 – Valores de predição Entradas, saídas e saldo por semana .....	35
Figura 26 – Comparação de saldo real e saldo predito 01/2024 a 05/2024.....	35
Figura 27 – Modelo Random Forest Regressor.....	37
Figura 28 – Entradas de dinheiro real e predito validação.....	38
Figura 29 – Saídas de dinheiro real e predito validação.....	38
Figura 30 – Saídas de dinheiro real e predito.....	39
Figura 31 – Saídas de dinheiro real e predito.....	39
Figura 32 – Saídas de dinheiro real e predito.....	40

Figura 33 – Saídas de dinheiro real e predito.....40

## **LISTA DE SIGLAS**

ATM – Automated Teller Machine

IA - Inteligência Artificial

MSE - Mean Squared Error (erro quadrático médio)

## 1. INTRODUÇÃO

As agências bancárias possuem caixas eletrônicos, também conhecidos como *Automated Teller Machines (ATMs)*, onde os usuários podem realizar o saque e depósito de dinheiro em espécie. Para que o dinheiro fique disponível nos caixas eletrônicos, os colaboradores precisam abastecer os caixas eletrônicos.

Conforme a região, o dia do mês e os feriados, a demanda por saque e depósito pode aumentar ou diminuir, necessitando de um gerenciamento de numerário para que não haja excedente ou para que não falte numerário nos caixas eletrônicos.

Ao faltar numerário no caixa eletrônico proporciona-se uma experiência negativa para o cliente, o que prejudica o nome da instituição financeira e faz ocorrer a diminuição do número de novos clientes, além de reduzir o número de usuários já existentes.

Quando ocorre de sobrar numerário, ocasiona uma perda financeira para a instituição, pois o dinheiro ocioso no caixa eletrônico poderia, por exemplo, trazer rentabilidade ao ser disponibilizado para a realização de um empréstimo pessoal ou comercial.

O presente trabalho tem como objetivo usar a inteligência artificial com dois modelos de regressão usando uma base histórica de entradas e saídas de numerário (depósitos e saques). Para treinar e testar os modelos, usamos dados de 01/2021 a 05/2024, de uma única agência. Isso poderá auxiliar na gestão de numerário, de forma com que disponibilize para os colaboradores da agência um valor sugerido que seja o mais próximo possível no momento de realizar o pedido de numerário para as transportadoras de valores.

Este documento está organizado em oito capítulos. O capítulo 1 é a introdução desse trabalho. O dois é a fundamentação teórica. O capítulo 2 é a metodologia. O capítulo 3 é o desenvolvimento. O capítulo 4 é o desenvolvimento. O capítulo 5 é o dataset. O capítulo 7

## 2. FUNDAMENTAÇÃO TEÓRICA

O presente estudo apresenta conceitos fundamentais relacionados ao alcance dos objetivos, embasados em artigos e sites do Governo Federal. Para um melhor entendimento do estudo, serão abordados nos itens abaixo as descrições dos principais conceitos utilizados.

### 2.1 INTELIGÊNCIA ARTIFICIAL (IA)

A inteligência artificial (IA) é uma área interdisciplinar que combina conceitos e técnicas de diversas áreas da ciência da computação. Segundo Silvio Pereira (IME-USP, p. 4) “Inteligência Artificial é uma ampla área de pesquisa que subdivide-se em diversas subáreas, cada uma delas adotando diferentes abordagens e tratando diferentes problemas que, em geral, são de alta complexidade (para os quais ainda não temos soluções satisfatórias).

Existem várias técnicas de IA, cada uma adequada para diferentes tipos de problemas. Alguns modelos de IA:

- Modelos de Regressão Linear
  - Regressão Linear Simples: Se o relacionamento entre as features (número da semana, número do mês) e o valor for linear, a regressão linear pode ser uma solução simples e interpretável.
  - Regressão Linear Múltipla: Similar à regressão linear simples, mas pode considerar múltiplas features ao mesmo tempo.

O algoritmo de regressão linear é mais adequado para prever variáveis contínuas e quantificar relações lineares entre uma variável dependente e uma ou mais variáveis independentes, sendo ideal para modelos simples e interpretáveis.

- Modelos Baseados em Árvores de Decisão
  - Decision Tree Regressor: Captura interações não lineares entre as features, mas pode ser suscetível ao overfitting se a árvore for muito profunda.

- Random Forest Regressor: Conjunto de árvores de decisão que ajuda a reduzir o overfitting ao criar múltiplas árvores de decisão e combinar seus resultados.
- Gradient Boosting Regressor: Outro modelo baseado em árvores, mas que constroi as árvores de forma sequencial, onde cada árvore tenta corrigir os erros da anterior.

Modelos baseados em árvores de decisão são mais adequados para problemas de classificação e regressão onde as relações entre variáveis são complexas, não lineares ou possuem interações entre variáveis. Eles lidam bem com dados categóricos e contínuos, são robustos a outliers, e fornecem interpretabilidade clara ao dividir os dados em regras de decisão simples.

- Modelos de Séries Temporais

- ARIMA (AutoRegressive Integrated Moving Average): Um modelo clássico para séries temporais que leva em consideração as auto correlações dos dados históricos.
- SARIMA (Seasonal ARIMA): Uma extensão do ARIMA que inclui componentes sazonais, que pode ser útil se seus dados apresentarem padrões sazonais (por exemplo, picos de gastos em certas épocas do ano).

Modelos de séries temporais são mais adequados para prever e analisar dados que seguem uma ordem temporal, capturando padrões como tendências, sazonalidade e autocorrelação. Eles são ideais para aplicações como previsão de vendas, preços de ações, demanda energética e dados meteorológicos, onde a dependência no tempo é fundamental.

- Modelos de Redes Neurais

- MLP Regressor (Multi-Layer Perceptron): Um tipo de rede neural que pode modelar relações não lineares complexas entre as features e o target.

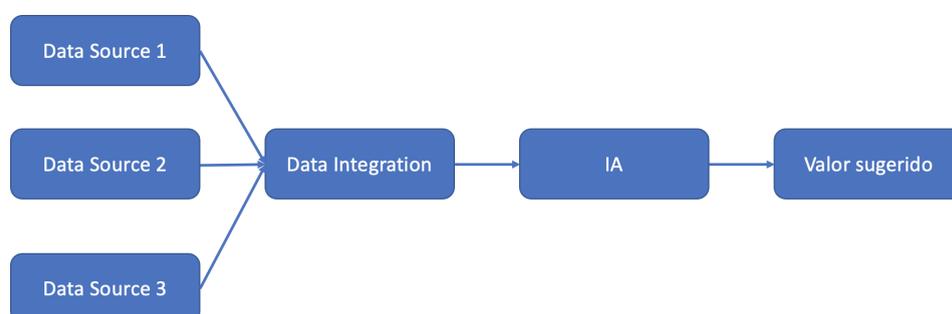
- Redes Neurais Convolucionais (CNN): Embora tipicamente usadas para dados de imagem, podem ser adaptadas para dados temporais estruturados, como séries temporais semanais ou mensais.

Modelos de redes neurais são mais adequados para problemas complexos e de alta dimensionalidade, como reconhecimento de padrões, classificação de imagens, processamento de linguagem natural, e previsão em cenários com relações não lineares. Eles são eficazes em capturar padrões ocultos e interações complexas entre variáveis, especialmente em grandes volumes de dados.

Os modelos podem usar dois tipos de aprendizado, sendo eles o aprendizado supervisionado que é treinado com dados rotulados, ou seja, entradas associadas a saídas corretas, para aprender a prever essas saídas em novos dados (ex: regressão, classificação) e o aprendizado não supervisionado que não tem acesso a rótulos e busca descobrir padrões ou agrupamentos nos dados (ex: clustering, redução de dimensionalidade).

Esses são alguns modelos de IA, sendo que cada um deles tem suas próprias aplicações e desafios. A IA é uma área em constante evolução, novas técnicas e abordagens estão sendo desenvolvidas o tempo todo.

Figura 1 – Arquitetura



## 2.2 INSTITUIÇÃO FINANCEIRA (BANCO)

Uma instituição financeira é uma entidade que atua no setor financeiro, oferecendo uma variedade de serviços e produtos financeiros. Essas instituições desempenham um papel fundamental na economia, facilitando o fluxo de dinheiro, fornecendo crédito e auxiliando na gestão de riscos financeiros.

Conforme o Banco Central do Brasil,

“Banco é uma instituição financeira especializada em intermediar o dinheiro entre poupadores e aqueles que precisam de empréstimos, além de custodiar (guardar) esse dinheiro. Ele providencia serviços financeiros para os clientes (saques, empréstimos, investimentos, entre outros). Os bancos são supervisionados pelo Banco Central (BC), que trabalha para que as regras e regulações do Sistema Financeiro Nacional (SFN) sejam seguidas por eles.”

Diante do conceito exposto, observa-se que existem diversos tipos de bancos, como o de câmbio, comercial, de desenvolvimento, de investimento, múltiplo, caixas econômicas e banco nacional de desenvolvimento Econômico e Social.

## 2.3 CAIXA ELETRÔNICO

Um caixa eletrônico, também conhecido como *Automated Teller Machine* (ATM), é um dispositivo eletrônico que permite que os clientes de instituições financeiras realizem várias transações bancárias sem a necessidade de interação direta com um funcionário do banco. Os caixas eletrônicos estão disponíveis em locais públicos, como agências bancárias, shoppings, supermercados e aeroportos, proporcionando conveniência e acesso aos serviços bancários fora do horário de funcionamento dos bancos.

## 2.4 AGÊNCIA

A agência bancária é uma unidade operacional de uma instituição financeira, responsável por prestar serviços bancários a seus clientes. Cada agência bancária é administrada por um gerente e sua equipe, que são responsáveis por gerenciar as operações diárias da agência e garantir que os serviços bancários sejam oferecidos com eficiência e eficácia.

Os serviços oferecidos pelas agências bancárias podem variar dependendo do tamanho e do tipo de banco, mas geralmente incluem serviços bancários básicos, como depósitos, retiradas, transferências de dinheiro e pagamento de contas.

A agência é, segundo Eduardo Swiech (2009, p. 5):

“vista como uma ‘empresa dentro da empresa’, ou seja, uma unidade de negócios que define suas táticas e formas operacionais, alinhadas com os Normativos e o Planejamento Estratégico da Matriz, para o mercado local onde está inserida.”.

Dessa forma, além dos serviços bancários básicos como o saque nos ATMs, as agências bancárias também podem oferecer empréstimos pessoais e comerciais, investimentos em títulos e ações, serviços de seguro, entre outros. As agências bancárias podem estar localizadas em áreas urbanas ou rurais e algumas instituições financeiras também oferecem serviços bancários por meio de agências móveis, que podem visitar comunidades remotas para prestar serviços financeiros.

A agência tem como responsabilidade gerenciar o numerário que ela precisa para operar, sendo assim é preciso decidir o valor de retirada e suprimento de dinheiro dos ATMs da agência para solicitar os pedidos para as transportadoras de valores.

## **2.5 TRANSPORTADORA DE VALORES**

Uma transportadora de valores é uma empresa especializada na prestação de serviços de transporte seguro de dinheiro, documentos e outros objetos de valor entre instituições financeiras, como bancos, e outros destinos específicos. Essas empresas desempenham um papel crucial na logística financeira, garantindo que grandes quantidades de dinheiro sejam movimentadas de forma eficiente e segura entre agências bancárias, caixas eletrônicos, e outros locais que demandam alta segurança.

Equipadas com veículos blindados e tecnologia de ponta, as transportadoras de valores utilizam procedimentos rigorosos para proteger os ativos que transportam. Além disso, contam com equipes treinadas para lidar com situações de risco e protocolos de segurança que minimizem a exposição a roubos e fraudes durante o transporte.

Essas empresas não só facilitam a circulação de numerário, mas também asseguram que as operações financeiras dos bancos possam ser realizadas sem interrupções, contribuindo para a estabilidade e a segurança do sistema bancário.

## **2.6 TRABALHOS RELACIONADOS**

Os artigos intitulados "Um Estudo sobre o Uso da Inteligência Artificial pelos Bancos Brasileiros" (LEMOS, B.V.; COSTA, G.; LEITE, K.M.; SILVA, M.R.; PEREZ, G.; PIRES, M.G. Editora: Convibra.) e "Previsão de demanda e reposição de numerário em uma rede de caixas eletrônicos" (PAIXA, R.C.; MESQUITA, M.A. XXVII Encontro Nacional de Engenharia de Produção, 2007.) são de suma pertinência para o presente trabalho, uma vez que o primeiro citado explora de maneira abrangente a aplicação da inteligência artificial nas instituições financeiras do Brasil e o segundo fornece embasamento para auxiliar nas possíveis causas da demanda dos ATMs, ambos auxiliando o alcance do objetivo geral.

## **3. METODOLOGIA**

O modelo escolhido para o desenvolvimento da proposta é Aprendizagem Supervisionada, com o algoritmo de Regressão Linear, onde foi escolhida uma agência, utilizando os atributos de número da semana no mês e número do mês, para o alvo o valor de entrada e saída de dinheiro.

A regressão linear é um método estatístico utilizado para modelar a relação entre uma variável dependente contínua e uma ou mais variáveis independentes. Os passos principais da regressão linear são os seguintes:

1. Formulação do problema: Definir claramente qual é a variável dependente que se deseja prever e quais são as variáveis independentes disponíveis para a análise.
2. Coleta de dados: Obter um conjunto de dados que contenha valores para a variável dependente e as variáveis independentes relevantes.

3. **Análise exploratória:** Realizar uma análise inicial dos dados para entender sua estrutura, verificar a presença de valores ausentes, outliers ou problemas de distribuição.
4. **Divisão dos dados:** Separar os dados em dois conjuntos: conjunto de treinamento e conjunto de teste. O conjunto de treinamento será utilizado para ajustar o modelo, enquanto o conjunto de teste será usado para avaliar sua performance.
5. **Ajuste do modelo:** Nesta etapa, os coeficientes da regressão linear são estimados usando um método como o método dos mínimos quadrados. O objetivo é encontrar a linha (ou hiperplano) que melhor se ajusta aos dados, minimizando a soma dos erros quadráticos entre as observações e as previsões do modelo.
6. **Avaliação do modelo:** Avaliar o desempenho do modelo utilizando métricas apropriadas. As métricas fornecem informações sobre a qualidade do ajuste do modelo e sua capacidade de fazer previsões precisas.
7. **Interpretação dos coeficientes:** Analisar os coeficientes estimados para entender a direção e a magnitude do efeito das variáveis independentes sobre a variável dependente. Os coeficientes indicam quanto a variável dependente se altera para cada unidade de alteração nas variáveis independentes.
8. **Validação e previsões:** Usar o modelo ajustado para fazer previsões em novos dados e avaliar seu desempenho. Essa etapa envolve aplicar o modelo às variáveis independentes desconhecidas e avaliar a precisão das previsões em relação aos valores reais da variável dependente.
9. **Refinamento e aprimoramento:** Se necessário, fazer ajustes no modelo, como adicionar ou remover variáveis independentes, transformar

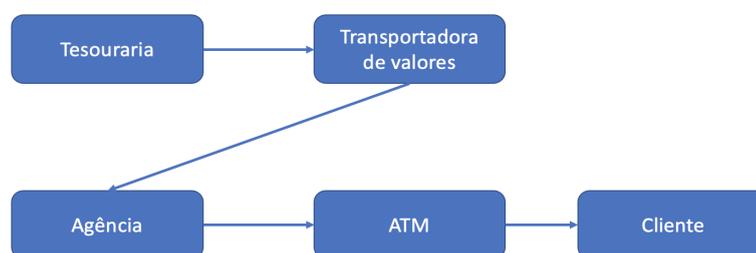
variáveis ou utilizar técnicas de regularização, para melhorar sua capacidade de previsão.

Após a conclusão de todos os passos, será escolhida uma agência bancária para realizar uma simulação onde o prognóstico da Inteligência Artificial vai ser comparado com o valor real necessário para o abastecimento de numerário, com intuito verificar que a solução proposta funciona.

#### 4. PROBLEMA DE SUPRIMENTO/RECOLHIMENTO DE NUMERÁRIO

Para que os caixas eletrônicos tenham dinheiro disponível, eles devem realizar o suprimento e retirada de numerário conforme a necessidade semanalmente, sendo necessário que o numerário saia da tesouraria e chegue até a agência bancária ou saia da agência bancária e seja transportado até a tesouraria. Para isso, é necessário contratar uma transportadora de valores (carro forte) para transportar o numerário.

Figura 2 – Fluxo de numerário



O abastecimento dos ATMs varia conforme a semana do mês, a região, os feriados, entre outros, fazendo com que a demanda diária seja crescente ou decrescente em relação à média.

##### 4.1 PROBLEMÁTICA: COMO UTILIZAR A INTELIGÊNCIA ARTIFICIAL PARA GERENCIAR MELHOR O ABASTECIMENTO DO ATM?

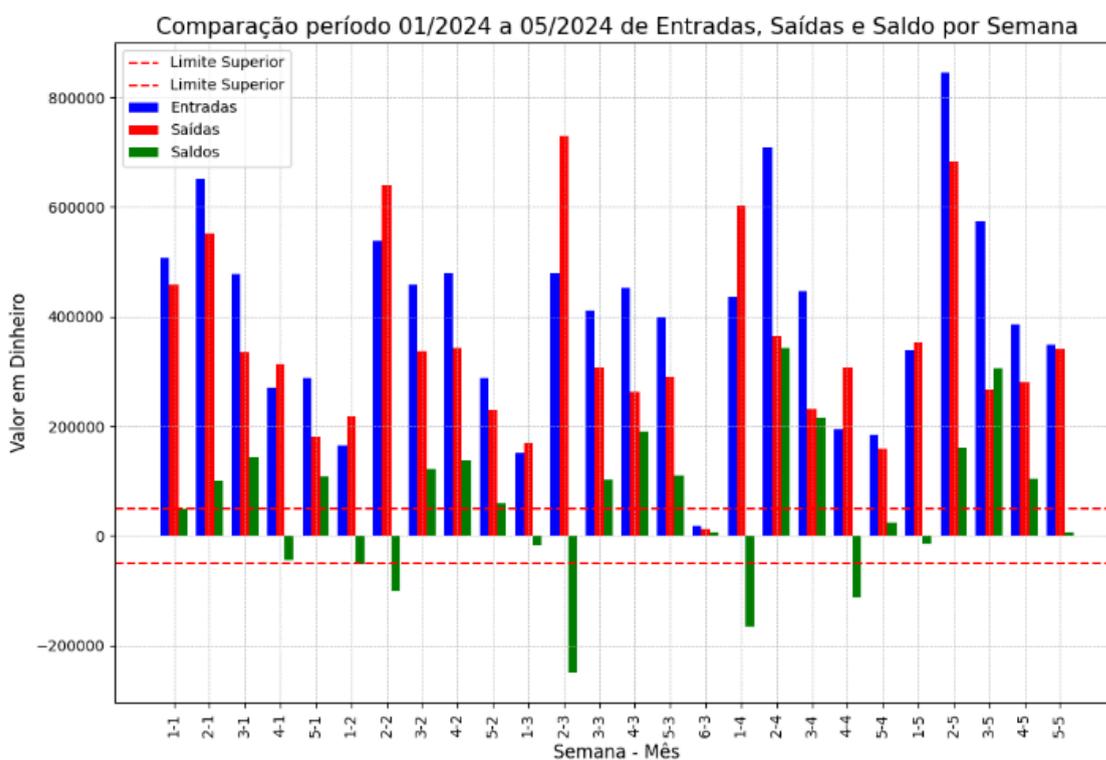
Ao não gerenciar corretamente o valor de abastecimento dos caixas eletrônicos, é gasto valores desnecessários com transportadoras, além de que dinheiro parado é depreciado, não trazendo nenhum benefício para a instituição financeira.

As barras tracejadas em vermelho demonstram a margem de erro na qual o modelo teria que se enquadrar ao projetar um valor.

O valor de abastecimento varia de acordo com a sazonalidade, feriados, poder aquisitivo da região, datas de maior recebimento de salários de acordo com a região, entre outros. Considerando isso, saber o valor correto não é algo trivial de se fazer, pois a tomada equivocada da decisão de valor ocasiona prejuízo devido ao numerário excedente no ATM ou transportes desnecessários devido a falta dele.

A figura abaixo mostra as entradas, saídas e saldos de 01/2024 a 05/2024, a agência deve definir a margem de segurança para mais e para menos, ilustrada na linha tracejada em vermelho, a inteligência artificial vai prever quando esses valores ultrapassarem a margem de segurança definida pela agência, para que o numerário seja utilizado de uma forma mais eficiente, podem ser solicitado o suprimento ou retirada para a transportadora de valores.

Figura 3 – Entradas, saídas e saldo por semana de 01/2024 a 05/2024



## 4.2 OBJETIVOS DO ESTUDO

Diante da problemática abordada no item 4.1, torna-se indispensável a existência de uma solução efetiva para esse problema. Conforme visto no item

2.1, a inteligência artificial pode analisar grandes volumes de dados para identificar padrões.

Visando alcançar a solução do problema, primeiramente precisa-se alcançar os objetivos específicos, que são:

- Definir atributos a serem utilizados na IA;
- Coletar dados para treino e teste;
- Adaptar o algoritmo para a utilização dos atributos definidos;
- Realizar o treino e teste para validar o modelo;
- Utilizar o modelo acompanhando o abastecimento de numerário em uma agência para avaliar o seu sucesso.

Atingindo os objetivos específicos da proposta e verificando que a IA pode ser aplicada na solução desta dificuldade ao efetuar a análise do histórico de transações financeiras de cada agência, é possível alcançar o objetivo geral da proposta, que consiste em validar a IA por meio de um modelo de regressão linear capaz de prever o valor adequado para o suprimento e retirada de numerário dos caixas eletrônicos.

#### **4.3 OPORTUNIDADES COM GERENCIAMENTO DE NUMERÁRIO**

Diante da problemática discutida anteriormente, analisa-se as oportunidades geradas a partir da resolução desta dificuldade. Observa-se que o valor de numerário ocioso no ATM pode ter funcionalidades financeiras para a instituição que tragam valorização do capital referido. Assim, a redução de excedente numerário contribuiria para o crescimento da instituição financeira, pois a instituição poderia aplicar o dinheiro excedente no financiamento de diversas atividades financeiras e de empréstimo.

Um exemplo é usar esse dinheiro para conceder empréstimos a pessoas físicas e empresas, bem como para investir em títulos e outras formas de investimento. Ao conceder empréstimos, o banco cobra juros dos tomadores de empréstimo, o que ajuda a gerar lucro para a instituição. O dinheiro também pode ser usado para financiar outras atividades bancárias, como fornecer crédito para cartões de crédito, hipotecas e outras linhas de crédito.

Além disso, a redução da deficiência de numerário tem por consequência a diminuição dos custos com transportadoras de valores e a elevação da satisfação dos clientes, diminuindo também a perda de usuários.

#### **4.4 RECURSOS NECESSÁRIOS**

Para o desenvolvimento desse trabalho proposto, se faz necessário realizar o estudo de como é realizado a gestão de numerário em uma instituição financeira, entender a composição e estrutura de dados utilizados nos caixas eletrônicos de uma agência bancária, com a finalidade de escolher os dados apropriados para utilização na inteligência artificial.

Através dos dados históricos dos suprimentos e os saques nos caixas eletrônicos utilizados em modelo de inteligência artificial que permite prever valores futuros. Após esse desenvolvimento, deverá ser realizado um estudo da viabilização para a sugestão de valor de abastecimento com numerário nos caixas eletrônicos.

### **5. DATASET**

Neste trabalho utilizamos um dataset especialmente selecionado para atender às necessidades específicas do projeto. Este conjunto de dados não é apenas um recurso fundamental para o desenvolvimento e teste de nossos modelos de IA, mas também um elemento crucial para a validação de nossas hipóteses e resultados. A escolha cuidadosa do dataset, juntamente com a atenção meticulosa aos detalhes na sua preparação e manipulação, reflete o compromisso com a precisão e a relevância prática do estudo. A seguir, detalharemos as características do dataset, incluindo sua origem, estrutura, e as transformações realizadas para otimizar sua aplicabilidade no contexto de IA, garantindo assim a robustez e a confiabilidade das análises realizadas. cabe ressaltar que usamos dados reais, porém as informações que identificam as centrais e agências foram modificadas.

#### **5.1 OBTENÇÃO DE DADOS**

O dataset utilizado foi obtido a partir de dados reais de uma instituição financeira, uma base de dados restrita que oferece informações detalhadas sobre entradas e saídas diárias dos ATMs. A escolha desta fonte foi motivada pela necessidade de ter o histórico para que a IA consiga realizar o prognóstico de pedidos futuros. O período dos dados coletados abrangem de 01/01/2022 a 31/05/2024, seguindo as diretrizes éticas e legais pertinentes.

Foi realizado um estudo inicial para validar que as transações que por algum motivo de erro de sistema foram desfeitas, não constam nessa base de dados, todos os valores estavam presentes sem que tenha sido preciso a remoção de valores, como se trata de atributos de central, agência, entrada, saída de valores e data, não houve a necessidade de normalização. As manipulações realizadas foram essenciais para garantir que os dados estivessem em um formato adequado para análise e para melhorar a precisão e desempenho dos modelos de IA desenvolvidos.

## 5.2 ESTRUTURA DOS DADOS DISPONÍVEL

Os dados estão armazenados no data lake, é composto pela CENTAL referente às regiões do Brasil sendo elas Norte, Nordeste, Centro-Oeste, Sudeste e Sul, a AGENCIA pertencente a central, o identificador do caixa eletrônico chamado TERMINAL, o valor de entrada em dinheiro chamado ENTRADA, o valor de saída de dinheiro chamado de SAIDA e a DATA de quando foi contabilizado esses valores, destacando que esse processamento ocorre na madrugada, somando todos os valores por dia para cada registro.

Figura 4 – Tabela de fechamento diário de entradas e saídas de dinheiro

CENTRAL	AGENCIA	TERMINAL	ENTRADA	SAIDA	DATA
NORTE	0418	10035173	312480.00	125356.00	08/03/2021
SUL	0312	10000139	231670.00	189345.0	16/02/2021
NORTE	0418	10035174	331260.00	107825.00	08/03/2021

## 5.3 MANIPULAÇÃO DE DADOS

Antes de aplicar técnicas de inteligência artificial, os dados foram meticulosamente filtrados e pré-processados. Este processo incluiu a aplicação de filtros de data e agência, a agregação e soma de valores de caixas eletrônicos por agência, a separação detalhada dos valores de entradas e saídas. Adicionalmente, os dados foram manipulados para facilitar a visualização em gráficos, permitindo uma análise mais precisa e informada.

### 5.3.1 FILTRO POR CENTRAL E AGÊNCIA

Para o estudo da solução do problema de gestão de numerário, foi selecionado inicialmente uma única central e agência, de forma a simplificar a validação do modelo e posteriormente expandir para as demais agências.

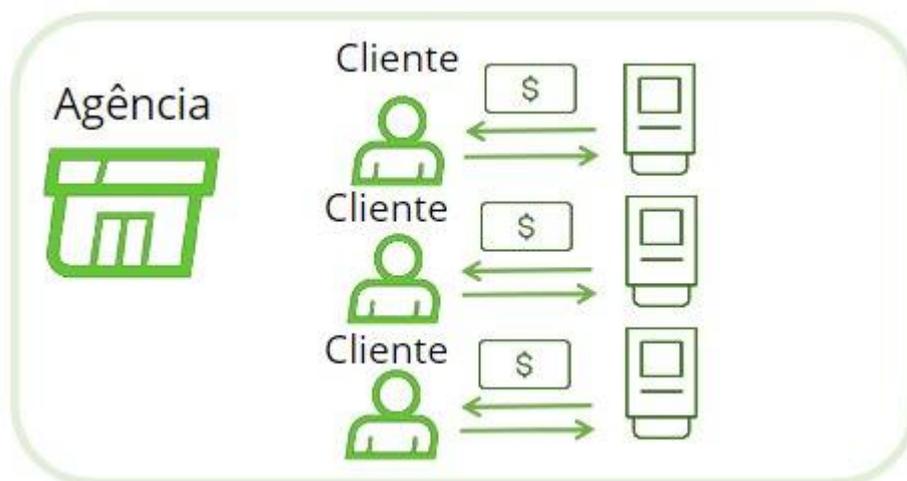
Figura 5 – Método que recebe as fechamentos e filtrar por central e agência

```
private static List<Fechamento> filtrarPorCentralEAgencia(List<Fechamento> fechamentos) {
    return fechamentos
        .stream()
        .filter(fechamento -> "NORTE".equals(fechamento.getCentral()) && "0418".equals(fechamento.getAgencia()))
        .collect(Collectors.toList());
}
```

Figura 6 – Tabela filtro de uma única central e agência

CENTRAL	AGENCIA	TERMINAL	ENTRADA	SAIDA	DATA
NORTE	0418	10035173	312480.00	125356.00	08/03/2021
NORTE	0418	10035174	331260.00	107825.00	08/03/2021

Figura 7 – Imagem mostrando que uma agência pode ter N ATMs



### 5.3.2 SOMATÓRIO DOS VALORES DOS ATMs DA AGÊNCIA POR DIA

Em uma agência pode se ter N ATMs, isso faz com que tenha um registro por ATM a cada dia, nessa etapa temos como objetivo agrupar os valores de entrada e saída de dinheiro por dia. Então realizamos a soma de todos os ATMs pertencentes à central e a agência escolhida, com intuito de unificar esses valores por dia. Isso possibilitou gerar um gráfico e tentar identificar comportamentos e tendências.

Figura 8 – Método de agrupamento e soma de valores por dia

```
private static List<FechamentoValorData> agregarEntradasPorData(List<Fechamento> fechamentos) {
    // Usando um HashMap para somar os valores por data
    Map<LocalDate, BigDecimal> mapaSomado = new HashMap<>();

    for (Fechamento fechamento : fechamentos) {
        mapaSomado.merge(fechamento.getData(), fechamento.getEntradaDinheiro(), BigDecimal::add);
    }

    // Transformando o mapa em uma lista de fechamentos
    return mapaSomado.entrySet().stream()
        .map(entry -> new FechamentoValorData(entry.getValue(), entry.getKey()))
        .collect(Collectors.toList());
}
```

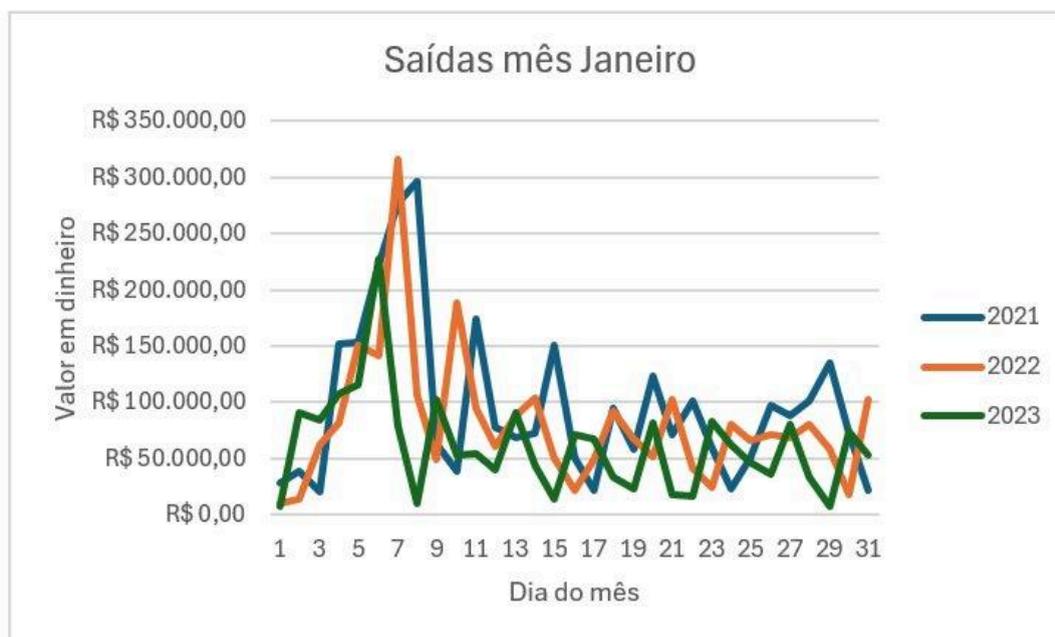
Figura 9 – Tabela com o agrupamento de valores por dia

ENTRADA	SAIDA	DATA
18345.00	63451.00	03/03/2021
39876.00	71345.00	04/03/2021
38467.00	15112.00	05/03/2021
55456.00	148908.00	06/03/2021
97978.00	180596.00	07/03/2021
37489.00	102340.00	08/03/2021
28140.00	49879.00	09/03/2021
27345.00	95980.00	10/03/2021

Figura 10 – Tabela das entradas de dinheiro do mês de janeiro



Figura 11 – Tabela das saídas de dinheiro do mês de janeiro



### 5.3.3 ANÁLISE DO GRÁFICO DIÁRIO

Foi identificado que em 2021, ainda estávamos em pandemia, teve um comportamento distinto dos demais anos, onde se teve maior movimentação na entrada e saída de dinheiro. Apesar da aceleração da mudança em direção a transações digitais, a movimentação em dinheiro foi maior comparada a outros anos.

No início do mês (primeiros 5 a 10 dias), houve um aumento nos valores, pois há geralmente um aumento nas transações em dinheiro devido ao recebimento de salários, pensões, benefícios sociais e outros pagamentos recorrentes. As pessoas costumam sacar dinheiro para pagar contas, realizar compras e cobrir outras despesas essenciais. Muitos pagamentos de contas, como aluguel, hipotecas, serviços públicos, e outras despesas fixas, são feitos no início do mês. Isso pode aumentar a demanda por saques em dinheiro.

Restante do mês, após o pico no início do mês, a maioria das despesas fixas já foi paga, e as pessoas começam a ajustar seus gastos de acordo com o que sobrou após as despesas iniciais, neste período, as transações em dinheiro podem refletir gastos discricionários, como entretenimento, alimentação fora de casa, e compras não essenciais.

Os fatores responsáveis pelo volume de saque são:

- **Pagamento de Despesas:** Saques são realizados quando há necessidade de dinheiro em espécie para pagar despesas que não podem ser feitas com métodos digitais, como aluguel em algumas situações, compras em estabelecimentos que preferem ou aceitam apenas dinheiro, ou para cobrir pequenos gastos do dia a dia.
- **Imprevistos:** Saques também podem ser feitos em situações emergenciais, onde o acesso rápido a dinheiro em espécie é necessário.
- **Falta de Acesso a Pagamentos Digitais:** Em áreas onde os pagamentos digitais são menos acessíveis ou em caso de falhas nos sistemas eletrônicos, as pessoas podem sacar dinheiro para garantir que terão recursos disponíveis.

Fatores motivadores dos depósitos:

- **Recebimento de Pagamentos em Espécie:** Depósitos são comuns quando indivíduos ou empresas recebem pagamentos em dinheiro e precisam transferir esses valores para suas contas bancárias para facilitar o gerenciamento ou para segurança.
- **Economia e Poupança:** Algumas pessoas preferem depositar o dinheiro que sobrou após pagar as despesas, como uma forma de economizar.
- **Recebimento de Dinheiro por Terceiros:** Depósitos podem ser realizados após receber dinheiro de terceiros, como de amigos ou familiares, para que esses valores sejam creditados em uma conta bancária.
- **Negócios e Comércio:** Comerciantes e pequenos negócios frequentemente depositam a receita do dia ou da semana em sua conta bancária para evitar manter grandes quantias em espécie, o que pode ser um risco de segurança.

#### 5.3.4 SOMATÓRIO DOS VALORES POR SEMANA

Após a análise no gráfico dos valores diários, tendo em vista que os pedidos devem ser realizados uma vez por semana, foi realizado o agrupamento dos valores semanal, onde cada semana do mês é representada por um número. Dessa forma ficou mais próximo da real necessidade, onde o problema requer uma análise semanal.

Figura 12 – Calendário identificando o número da semana no mês

**Março de 2019**

Dom	Seg	Ter	Qua	Qui	Sex	Sáb
					1	2
3	4	5	6	7	8	9
10	11	12	13	14	15	16
17	18	19	20	21	22	23
24	25	26	27	28	29	30
31						

Figura 13 – Método que calcula o número da semana no mês

```
private static int buscarNumeroDaSemanaNoMes(LocalDate data) {
    // Foi definido que o início da semana seria em um domingo e o final da semana um sábado
    WeekFields weekFields = WeekFields.of(DayOfWeek.SUNDAY, minimalDaysInFirstWeek: 1);

    return data.get(weekFields.weekOfMonth());
}
```

Figura 14 – Método agrupa os valores por semana do mês

```
private static List<FechamentoValorSemanaMes> agregarEntradasPelaSemana(List<FechamentoValorDia> fechamentoValorDiaList) {
    // Agrupa os valores pelo número da semana no mês
    Map<Integer, Map<Integer, BigDecimal>> groupedExpenses =
        fechamentoValorDiaList
            .stream()
            .collect(Collectors.groupingBy(
                linha -> buscarNumeroDaSemanaNoMes(linha.getData()), // número da semana no mês
                Collectors.groupingBy(
                    linha -> linha.getData().getMonthValue(), // mês
                    Collectors.reducing(BigDecimal.ZERO, FechamentoValorDia::getValor, BigDecimal::add) // soma dos valores
                )
            ));

    // Mapeia o agrupamento para uma lista de SemanaMes
    return groupedExpenses
        .entrySet()
        .stream()
        .flatMap(entry -> entry.getValue().entrySet().stream()
            .map(innerEntry -> new FechamentoValorSemanaMes(entry.getKey(), innerEntry.getKey(), innerEntry.getValue())))
        .collect(Collectors.toList());
}
```

Figura 15 – Tabela das entradas semanais no mês de janeiro



Figura 16 – Tabela das saídas semanais no mês de janeiro



#### 5.4 ESCOLHA DE ATRIBUTOS RELEVANTES PARA O DATASET

A seleção de atributos foi um processo criterioso, focado em inserir critérios, como relevância para o problema de pesquisa, qualidade dos dados e disponibilidade. Os atributos escolhidos foram o valor de entrada, valor de saída, número da semana no mês e o mês, por serem considerados fundamentais para a proposta de prognóstico de pedidos.

Figura 17 – Tabela com o agrupamento de valores dos ATMs

ENTRADA	SAIDA	NUMERO_SEMANA	MES
322456.00	807458.00	2	3
403786.00	609766.0	3	3
201232.00	403433.00	4	3

## 6 DESENVOLVIMENTO

Para o desenvolvimento nesse artigo foi testado todos modelos citados no item 2.1, e selecionando os modelos que mais se aproximaram nas etapas de validação e treino, sendo eles o modelo de Regressão Linear e o Modelo Random Forest Regressor.

Para cada modelo foi definido etapas de desenvolvimento para obter o valor de entrada e saída preditos, sendo eles:

- Descoberta de melhores hiperparâmetros para o modelo usando dados de 2021 e 2022 para treino e 2023 para validação.
- Configuração do melhor hiperparâmetro para o modelo usando de 2021 e 2022 para treino e 01/2024 a 05/2024 para teste.
- Projeção do gráfico com os valores de entradas, saídas e saldo de 01/2024 a 05/2024.
- Comparação do saldo real com o saldo predito para o período de e 01/2024 a 05/2024.

## 6.1 TÉCNICA PARA OTIMIZAR HIPERPARÂMETROS

O GridSearchCV é uma ferramenta do scikit-learn que automatiza a busca pelos melhores hiperparâmetros de um modelo de machine learning. Ele testa todas as combinações possíveis de um conjunto pré-definido de parâmetros, utilizando validação cruzada para avaliar o desempenho de cada combinação. A combinação que apresenta o melhor desempenho com base em uma métrica específica (como acurácia, MSE, etc.) é selecionada como a melhor.

Parâmetros utilizados no GridSearchCV:

- **estimator**: Define o modelo de machine learning que será otimizado.
- **param\_grid**: É um dicionário onde as chaves são os nomes dos hiperparâmetros do modelo e os valores são listas de valores que você deseja testar para cada hiperparâmetro
- **scoring**: Define a métrica que será usada para avaliar o desempenho do modelo durante a validação cruzada. No caso, `neg_mean_squared_error` é usado, o que significa que o GridSearchCV avaliará o modelo com base no erro quadrático médio negativo (o MSE é negativo porque o GridSearchCV tenta maximizar a métrica, então ele inverte o sinal).
- **cv**: Refere-se à validação cruzada (cross-validation). Aqui, o dataset será dividido em 5 partes (folds). O modelo será treinado em 4 dessas partes e testado na parte restante. Isso será

repetido 5 vezes, cada vez com uma parte diferente usada como conjunto de teste. O desempenho médio em todas as iterações será usado para avaliar cada combinação de hiperparâmetros.

- **n\_jobs:** Define o número de processadores a serem usados para executar a busca. -1 significa que todos os processadores disponíveis no sistema serão usados, acelerando a execução.
- **verbose:** Controla o nível de mensagens de log exibidas durante a execução do GridSearchCV. verbose=1 exibirá uma quantidade moderada de informações no console, como o progresso das combinações sendo testadas. Valores mais altos (2, 3, etc.) fornecerão mais detalhes, enquanto 0 suprime a maioria das mensagens.
- **random\_state:** É usado para garantir a reprodutibilidade dos resultados. Ele define a semente do gerador de números aleatórios utilizado por métodos que envolvem algum tipo de aleatoriedade, como a inicialização de pesos em redes neurais, a divisão de dados em treino e teste, ou a amostragem de dados.

## 6.2 MÉTRICAS

O Erro Quadrático Médio (MSE, do inglês *Mean Squared Error*) é uma métrica usada para avaliar a performance de modelos de regressão. Ele calcula a média dos quadrados dos erros, onde o erro é a diferença entre o valor real e o valor previsto pelo modelo.

Figura 18 – Fórmula matemática para o Erro Quadrático Médio

### Fórmula Matemática

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Onde:

- $y_i$  é o valor real para a  $i$ -ésima amostra.
- $\hat{y}_i$  é o valor previsto pelo modelo para a  $i$ -ésima amostra.
- $n$  é o número total de amostras.

Figura 19 – Código usado para apresentar Erro Quadrático Médio

```
# Calculando o erro quadrático médio  
mse = mean_squared_error(y_test, y_pred)  
print(f'Mean Squared Error: {mse}')
```

## 6.3 REGRESSAO LINEAR

Vamos iniciar o desenvolvimento utilizando o modelo de regressão linear e, em seguida, validar se os resultados obtidos são satisfatórios. Optamos por iniciar o desenvolvimento com o modelo de regressão linear, pois, à primeira vista, fez sentido para o nosso objetivo de prever valores futuros com base na análise da base histórica. A simplicidade e a eficácia desse modelo tornaram uma escolha lógica no primeiro momento.

### 6.3.1 IMPLEMENTAÇÃO

A implementação do algoritmo foi realizada em Python, aproveitando a facilidade de uso dessa linguagem. O processo incluiu algumas configurações necessárias para ler o arquivo de dados, utilizar a biblioteca de regressão, e gerar gráficos de forma eficiente.

Figura 20 – Código usado para a regressão linear

```

# Criando um pipeline com PolynomialFeatures e LinearRegression
pipeline = Pipeline([
    ('poly', PolynomialFeatures()),
    ('scaler', StandardScaler()),
    ('lin_reg', LinearRegression())
])

# Definindo os parâmetros para o GridSearchCV
param_grid = {
    'poly__degree': [1, 2, 3, 4]
}

# Configurando o GridSearchCV
grid_search = GridSearchCV(
    estimator=pipeline,
    param_grid=param_grid,
    cv=5,
    scoring='neg_mean_squared_error',
    n_jobs=-1,
    verbose=1)

# Treinando o modelo com GridSearchCV
grid_search.fit(X_train, y_train)

# Melhores parâmetros e melhor modelo
print("Best parameters:", grid_search.best_params_)
best_model = grid_search.best_estimator_

# Fazendo previsões para o ano de 2023
y_pred = best_model.predict(X_val)

```

### 6.3.2 ANÁLISE DO PROGNÓSTICO GERADO PELO MODELO

O gráfico demonstra que o passo de validação de entradas, tende a fazer a predição menor que os valores reais e os valores de saída preditos tendem a ser maiores do que os valores reais.

Figura 21 – Entradas de dinheiro real e predito validação

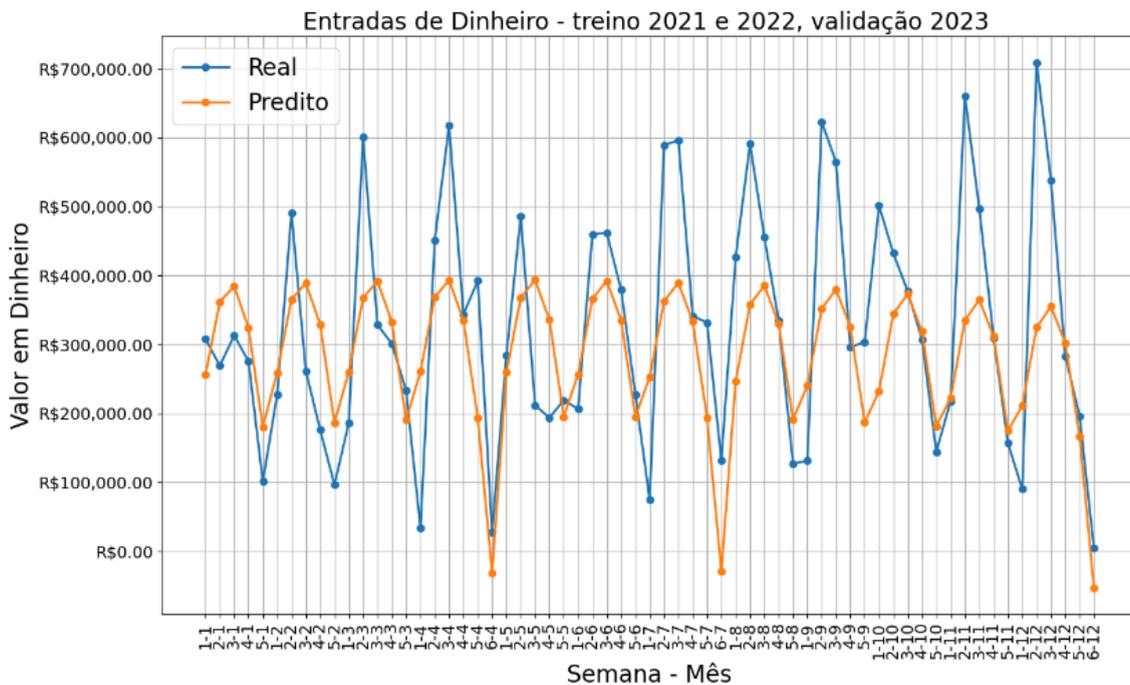
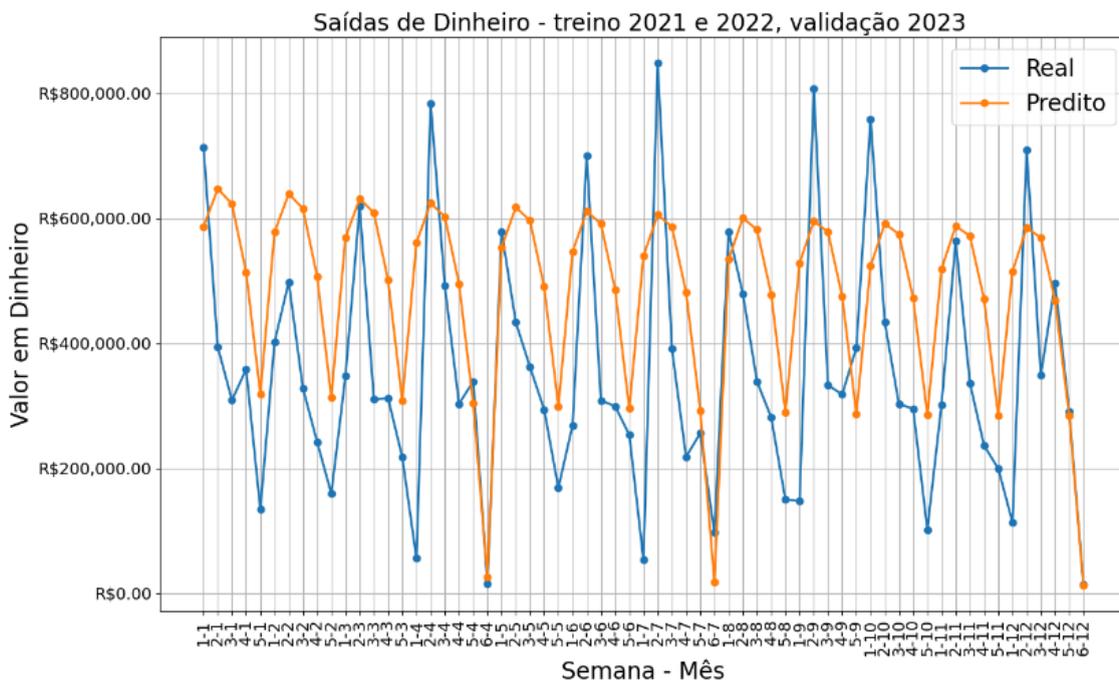


Figura 22 – Saídas de dinheiro real e predito validação



Após encontrar o hiperparâmetro mais adequado, foi configurado, usando 2021 a 2022 como treino e para teste 01/2023 a 05/2023. Permanecendo assim

como na etapa de validação com o valor predito de entradas abaixo do valor real e o valor de saídas previsto acima do valor real.

Figura 23 – Entradas de dinheiro real e predito teste

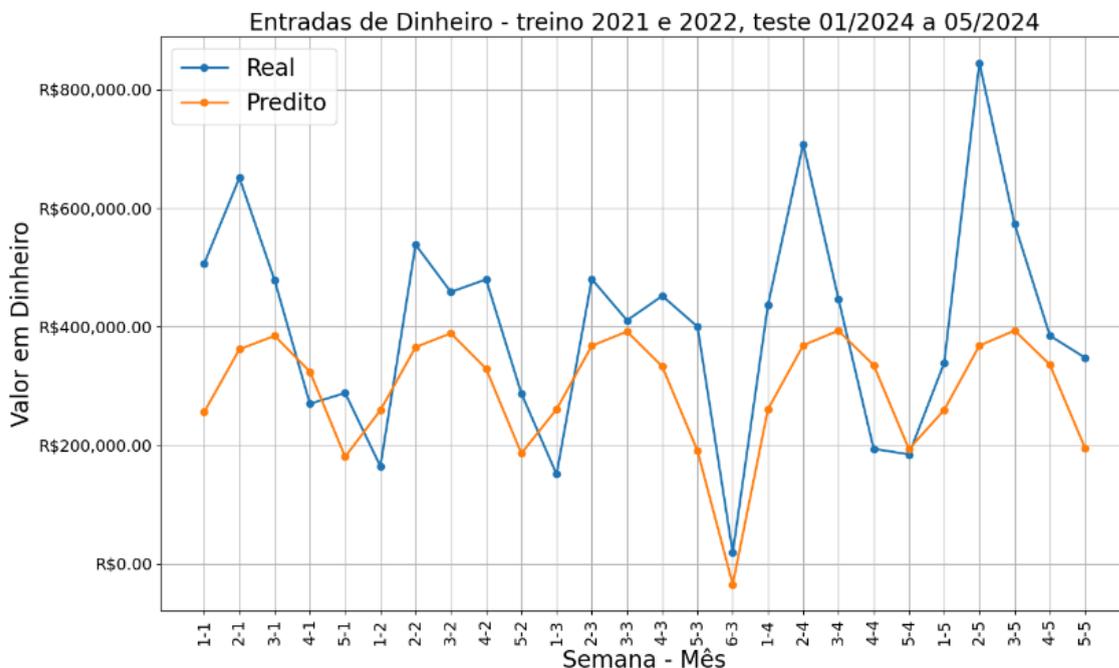
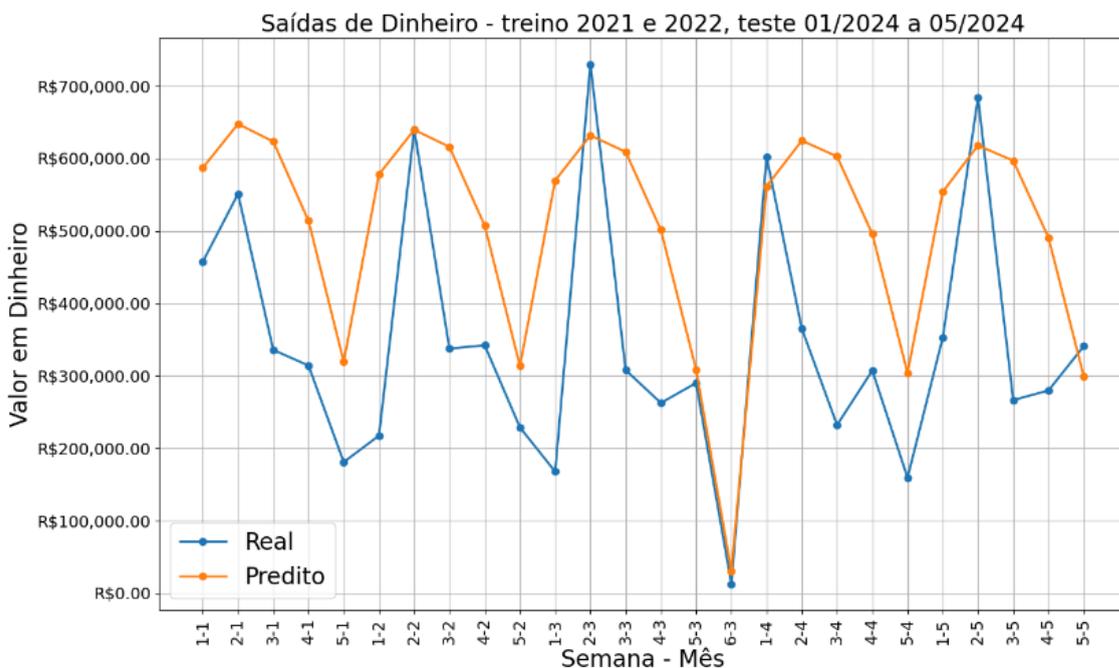


Figura 24 – Saídas de dinheiro real e predito teste



Após encontrar o valor de Entrada e Saída predito, foi gerado um gráfico projetando os valores de 01/2024 a 05/2024. O qual mostrou em sua maioria

que vai faltar dinheiro, consequentemente indicando que vai ser preciso realizar pedidos de suprimento para os caixas eletrônicos.

Figura 25 – Valores de predição Entradas, saídas e saldo por semana

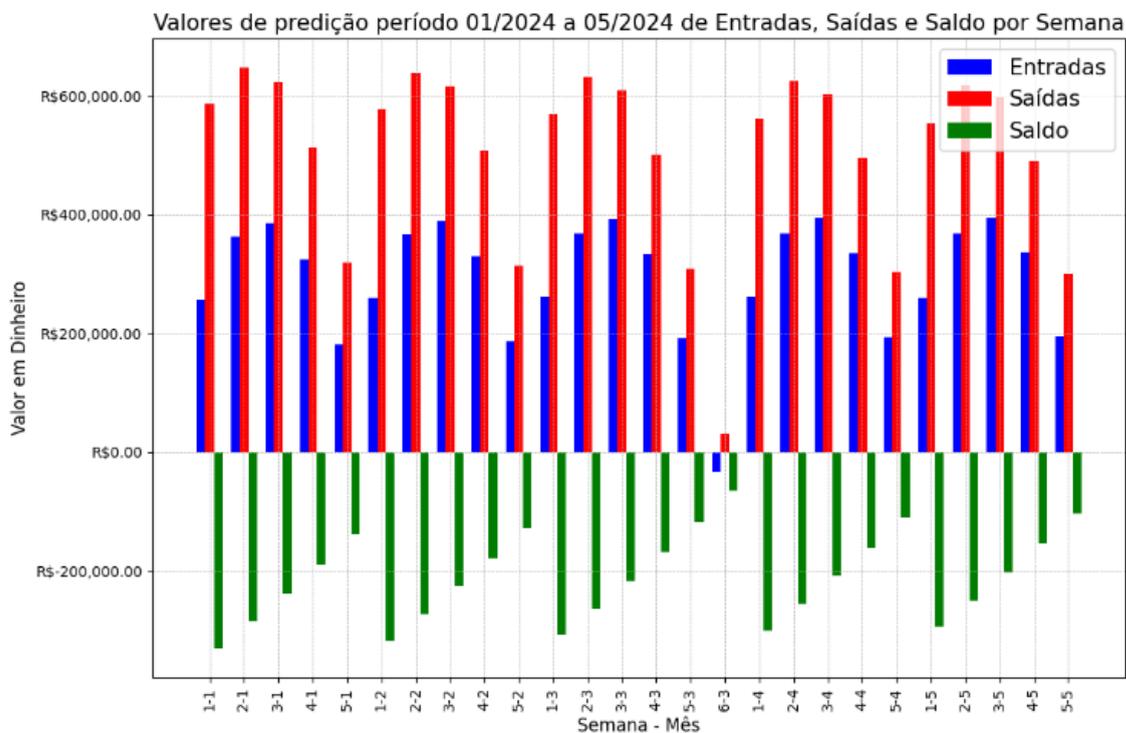
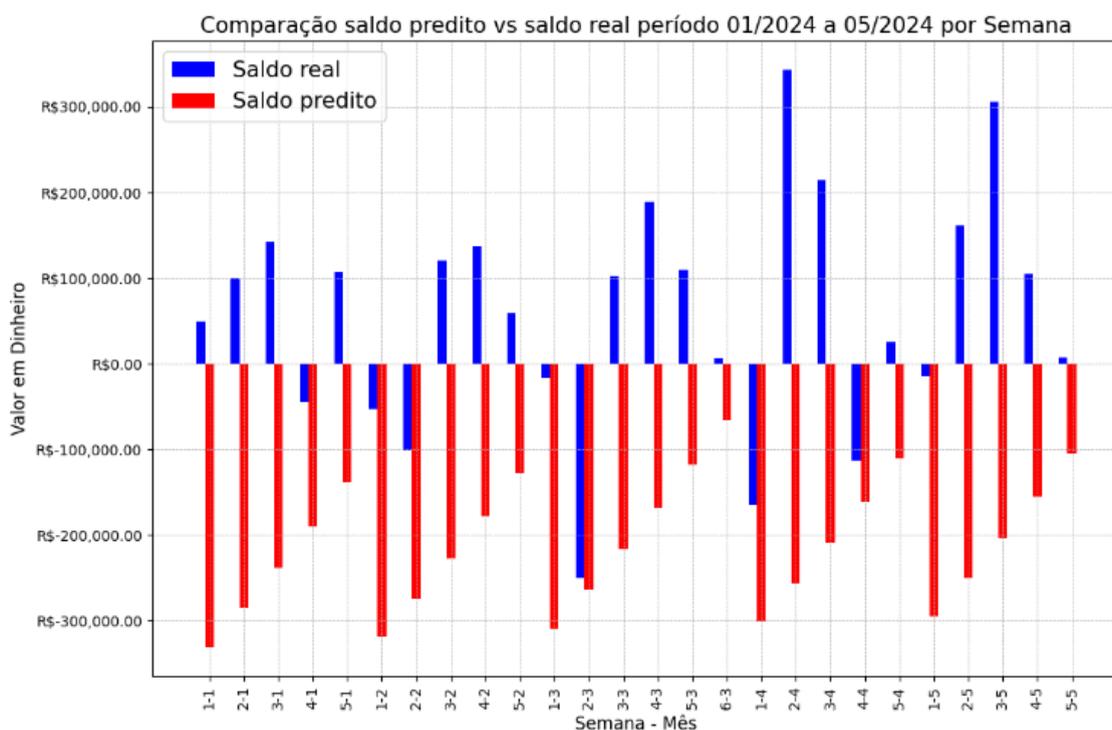


Figura 26 – Comparação de saldo real e saldo predito 01/2024 a 05/2024



## **6.4 RANDOM FOREST REGRESSOR**

O Random Forest Regressor, é um modelo de ensemble que constroi múltiplas árvores de decisão em amostras diferentes dos dados e as combina para melhorar a precisão das previsões. Ele é capaz de capturar relações não lineares e interações entre variáveis de forma mais eficaz, lidando melhor com a variabilidade dos dados e reduzindo a chance de overfitting em comparação com uma única árvore de decisão.

### **6.4.1 IMPLEMENTAÇÃO**

A implementação permaneceu com Python, aproveitando a mesma estrutura de gráficos utilizado no modelo anterior, com intuito de padronizar a visualização e facilitar a comparação dos resultados dos dois modelos.

Figura 27 – Código utilizado para o Random Forest Regressor

```

# Parâmetros para o modelo Random Forest Regressor com GridSearch
param_grid = {
    'n_estimators': [200, 300],
    'max_depth': [3, 4],
    'min_samples_split': [5, 10],
    'min_samples_leaf': [2, 5]}

# Configurando o GridSearchCV com RandomForestRegressor
grid_search = GridSearchCV(
    estimator=RandomForestRegressor(),
    param_grid=param_grid,
    scoring='neg_mean_squared_error',
    cv=5,
    n_jobs=-1,
    verbose=1
)

# Explora todas as combinações possíveis de hiperparâmetros
# Avalie o desempenho de cada combinação com validação cruzada
# Selecione o modelo com a melhor performance com base na métrica definida
grid_search.fit(X_train, y_train)

# Usando o melhor modelo encontrado pelo GridSearchCV
best_model = grid_search.best_estimator_

# Fazendo previsões para o ano de 2023 com o modelo otimizado
y_pred = best_model.predict(X_test)

```

#### 6.4.2 ANÁLISE DO PROGNÓSTICO GERADO PELO MODELO

Os resultados da análise demonstraram que o Random Forest Regressor obteve um resultado bem semelhante ao modelo anterior de Regressão Linear, pois o valor de entradas previstas permanece sendo menor que o valor real, enquanto o valor de saídas também permanece sendo maior que o real.

Figura 28 – Entradas de dinheiro real e predito validação

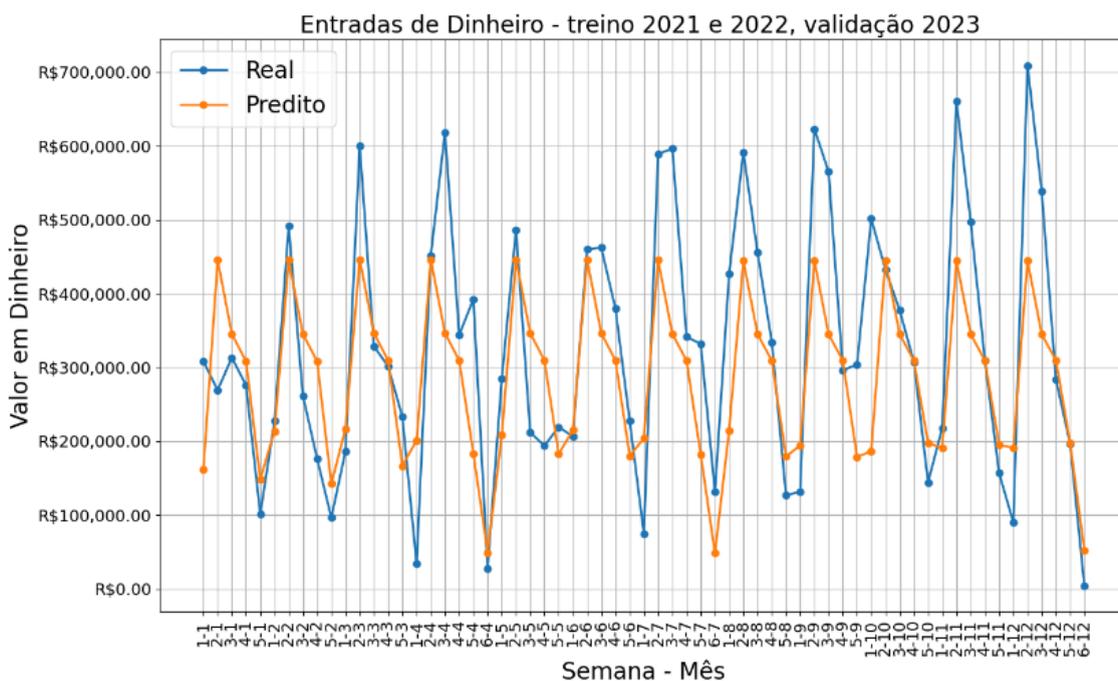
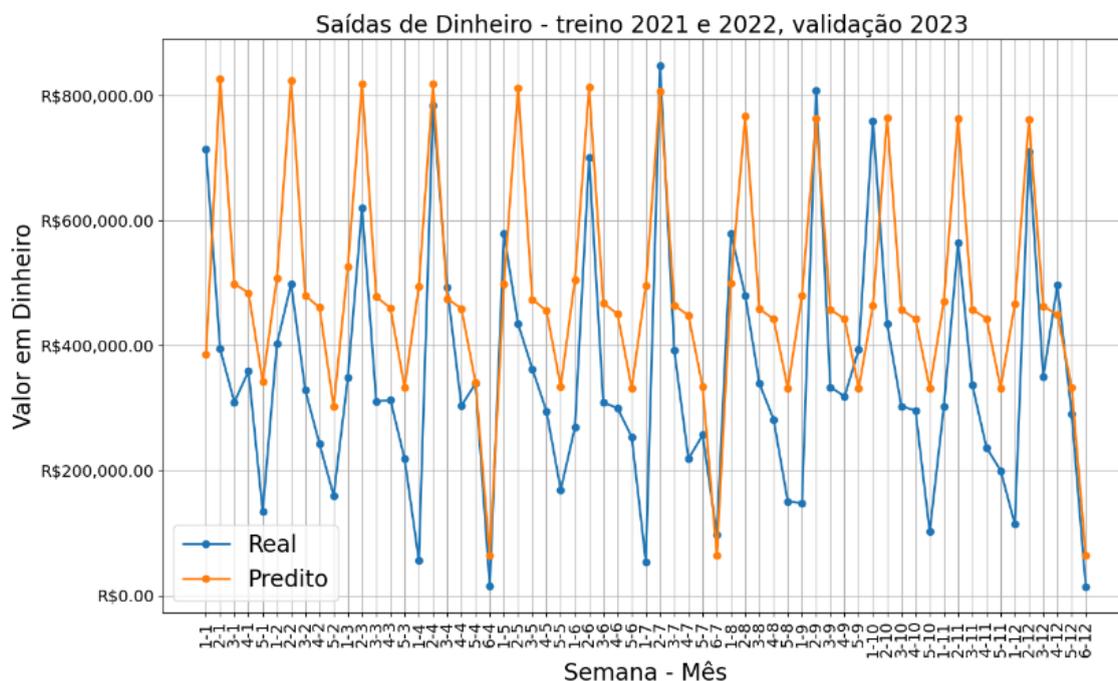


Figura 29 – Saídas de dinheiro real e predito validação



Após encontrar o hiperparâmetro mais adequado, foi configurado, usando 2021 a 2022 como treino e para teste 01/2024 a 05/2024. Permanecendo assim como na etapa de validação com o valor predito de entradas abaixo do valor real e o valor de saídas previsto acima do valor real.

Figura 30 – Entradas de dinheiro real e predito teste

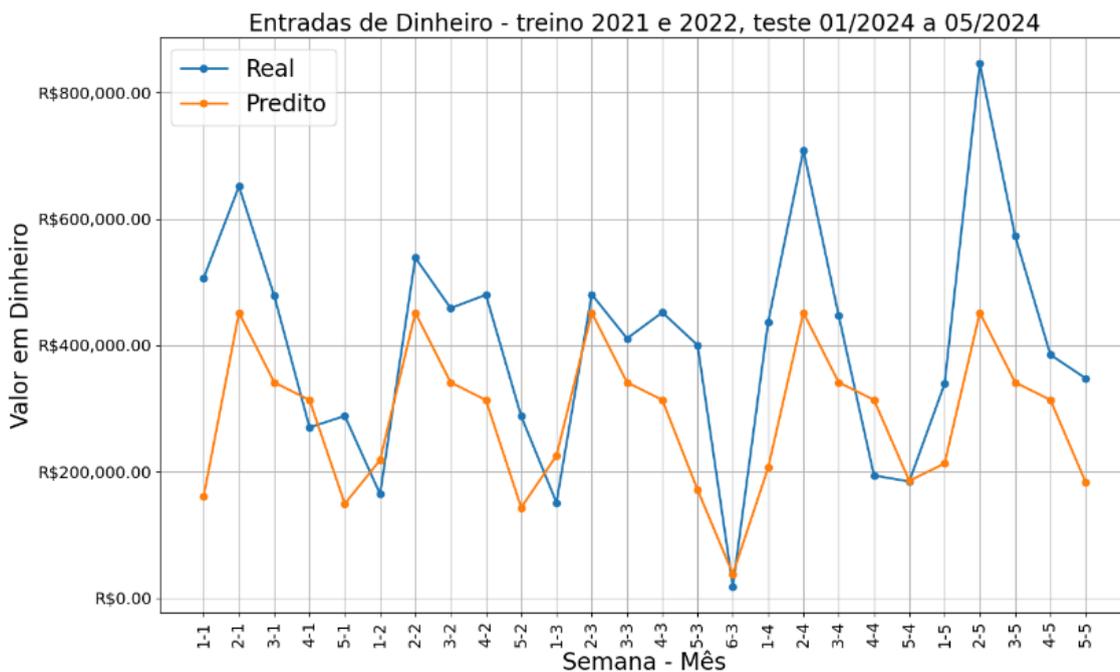
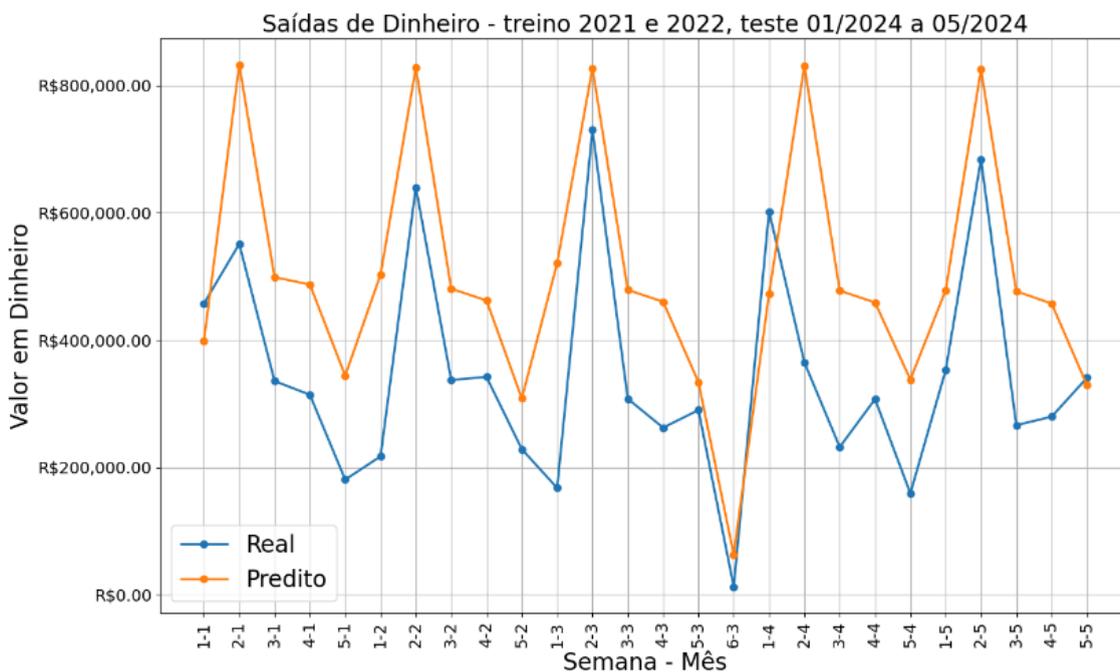


Figura 31 –Saídas de dinheiro real e predito teste



Após encontrar o valor de Entrada e Saída predito, foi gerado um gráfico projetando os valores de 01/2024 a 05/2024. O qual mostrou em sua maioria que vai faltar dinheiro, com isso uma projeto para ser realizado pedidos de suprimento para os caixas eletrônicos.

Figura 32 – Valores de predição Entradas, saídas e saldo por semana

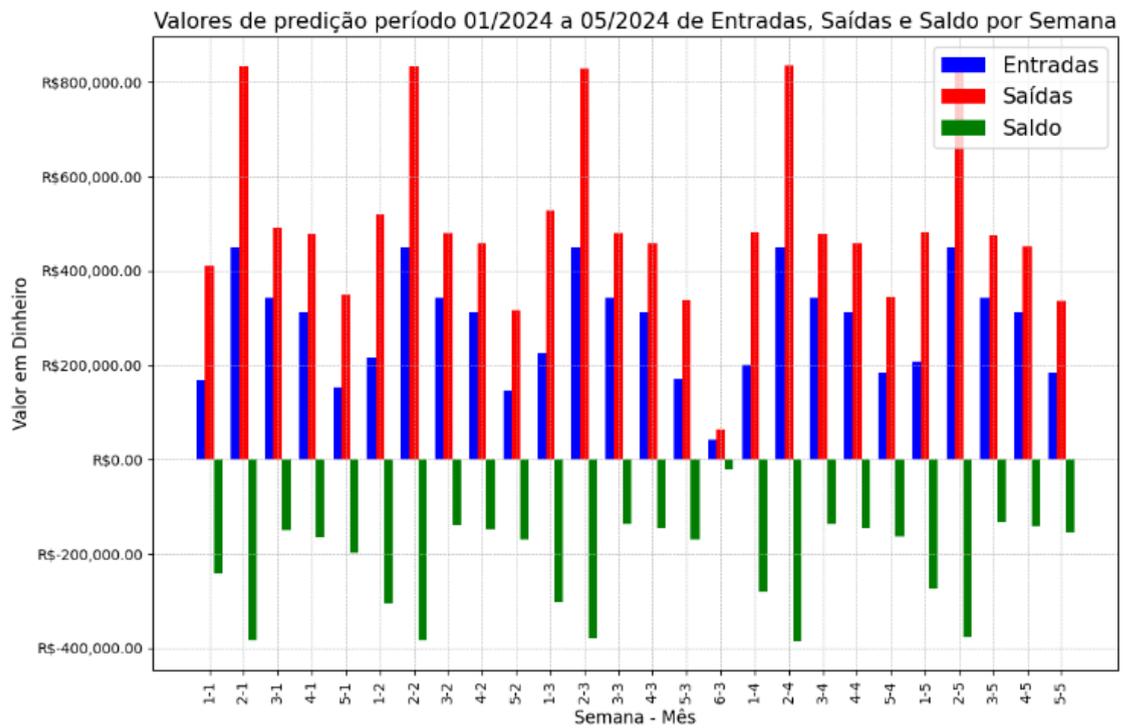
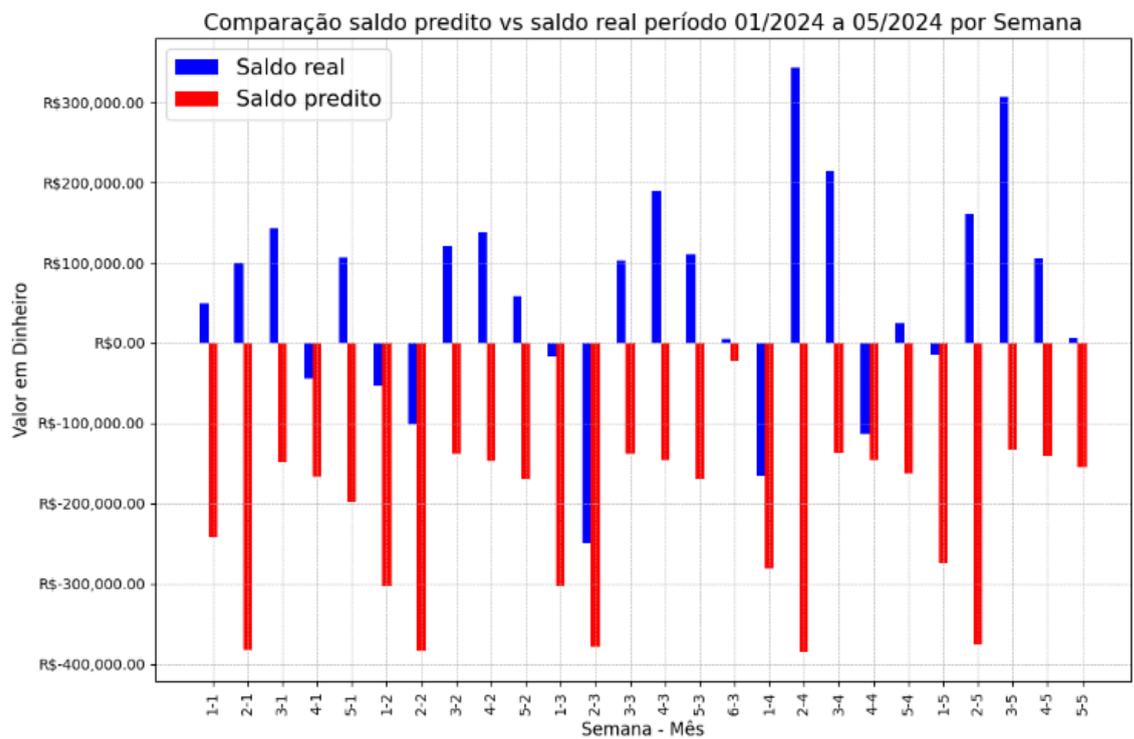


Figura 33 – Comparação de saldo real e saldo predito 01/2024 a 05/2024



## 7. CONCLUSÃO

Este trabalho de conclusão é a aplicação dos conhecimentos adquiridos durante o curso de Sistemas de Informação, juntamente com a experiência profissional na área de Instituição financeira, proporcionou aprimorar os conhecimentos em Inteligência Artificial, por meio de estudos sobre algoritmos e dados.

A proposta desse modelo de inteligência artificial apresenta uma promissora solução para a previsão mais precisa do valor de abastecimentos dos caixas eletrônicos. Ao utilizar algoritmos avançados e técnicas de aprendizado de máquina, é possível obter estimativas mais próximas do ideal, resultando em uma gestão mais eficiente dos recursos financeiros envolvidos nesse processo.

Com essa abordagem inovadora, as instituições financeiras poderão otimizar o planejamento de abastecimento, evitando situações de falta ou excesso de dinheiro nos caixas eletrônicos, o que, por sua vez, trará benefícios tanto para os usuários quanto para as próprias instituições. Além disso, a aplicação dessa tecnologia pode ajudar a reduzir custos operacionais e aprimorar a segurança do sistema de caixas eletrônicos, tornando-o mais resiliente às demandas do mercado.

No entanto, durante o desenvolvimento do projeto, após verificar o resultado do primeiro modelo de Regressão Linear, foi identificado que o dataset é insuficiente, os anos disponíveis para treino foram 2021 e 2022, entretanto em 2021 ocorreu a pandemia, ocasionando um comportamento de maior valor de saques, o que fez comprometer o dataset por ter poucos anos, e a metade dele sendo com comportamento adverso. Diante disso, foi realizado teste em outro modelo para verificar se o comportamento permanece, foi usado o modelo Random Forest Regressor o qual teve as mesmas tendências do modelo de Regressão Linear, os modelos realizaram a predições que teria mais valores de saídas e menos de entradas, ocasionando em uma solicitação de pedido de suprimento de dinheiro para a transportadora de valores, o que na prática não ocorreu, pois não estamos na pandemia e não está sendo realizado uma grande quantidade de saques de dinheiro, isso inviabilizou os modelos de inteligência artificial.

Portanto, é necessário ter disponível uma base histórica maior para o dataset, a fim de dissolver o comportamento atípico no período da pandemia, sendo mais eficiente para esse problema e disponibilizando a solução para a instituição bancária, além da experiência do cliente e proporcionar mais negócios e lucros para o banco.

Para os trabalhos futuros, é recomendável expandir a base histórica de treinamento ao incorporar um conjunto de dados mais amplo e diversificado, incluindo informações adicionais, tais como os detalhes dos pedidos de numerários feitos às transportadoras de valores, explorar mais tipos de codificação, trocando o valor por semana por dia útil, usar o modelo de Séries Temporais. Essa abordagem enriquecerá a análise, permitindo um modelo mais robusto e previsões mais precisas.

## 8. REFERÊNCIAS BIBLIOGRÁFICAS

Financial Stability Board. (2017). Artificial Intelligence and Machine Learning in Financial Services - Market Developments and Financial Stability Implications. Financial Stability Board, November.

Disponível em: <http://www.fsb.org/2017/11/artificial-intelligence-and-machinelearning-in-financial-service/>. Acesso em: 2 de abril de 2023.

Belanche, D., Casalo, L. V., & Flavián, C. (2019). Artificial Intelligence in FinTech: understanding robo-advisors adoption among customers. *Industrial Management and Data Systems*, 119(7), 1411–1430.

Disponível em: <https://doi.org/10.1108/IMDS-08-2018-0368>. Acesso em: 24 de março de 2023.

APPINVENTIV. "Coleta e análise de dados."

Disponível em: <https://appinventiv.com/blog/what-is-data-integration>. Acesso em: 3 de abril de 2023.

Cao, L. (2020). AI in Finance: A Review. *SSRN Electronic Journal*, 00, 1–47.

Disponível em: <https://doi.org/10.2139/ssrn.3647625>. Acesso em: 3 de abril de 2023

Financial Stability Board. (2017). Artificial Intelligence and Machine Learning in Financial Services - Market Developments and Financial Stability Implications. Financial Stability Board, November.

Disponível em: <http://www.fsb.org/2017/11/artificial-intelligence-and-machinelearning-in-financial-service/>. Acesso em: 3 de abril de 2023.

Güngör, H. (2020). Creating Value with Artificial Intelligence: A Multi-stakeholder Perspective. *Journal of Creating Value*, 6(1), 72–85.

Disponível em: <https://doi.org/10.1177/2394964320921071>. Acesso em: 7 de fevereiro de 2023.

Iansiti, M., & Lakhani, K. R. (2020). Competing in the Age of AI. *Harvard Business Review*, January-February.

Disponível em: <https://hbr.org/2020/01/competing-in-the-age-of-ai>. Acesso em: 7 de fevereiro de 2023.

Shaikh, N. (2017). The Financial Industry Needs to Start Planning for the Next 50 Years, Not the Next Five. Harvard Business Review.

Disponível

em:

<[https://hbr.org/2017/07/the-financial-industryneeds-to-start-planning-for-the-next-50-years-not-t  
he-next-five](https://hbr.org/2017/07/the-financial-industryneeds-to-start-planning-for-the-next-50-years-not-t<br/>he-next-five)>. Acesso em: 8 de fevereiro de 2023.

CERRI, R.; CARVALHO, A.C. Aprendizado de máquina: breve introdução e aplicações. Cadernos de Ciência & Tecnologia, Brasília, 2017.

NETO, E.P.F. Visão computacional para identificação de cores em tempo real com opencv e Python. UniCEUB, 2020.

SWIECH, E., O Planejamento no nível de agência bancária como diferencial para o resultado econômico. Universidade Federal do Rio Grande do Sul, 2009.

LEMOS, B.V.; COSTA, G.; LEITE, K.M.; SILVA, M.R.; PEREZ, G.; PIRES, M.G. Um Estudo sobre o Uso da Inteligência Artificial pelos Bancos Brasileiros. Editora: Convibra.

PEREIRA, S.L. Processamento de Linguagem Natural. IME - USP

Disponível em: <<https://www.ime.usp.br/~slago/IA-introducao.pdf>>. Acesso em: 11 de fevereiro de 2023.

PAIXA, R.C.; MESQUITA, M.A. Previsão de demanda e reposição de numerário em uma rede de caixas eletrônicos. XXVII Encontro Nacional de Engenharia de Produção, 2007.