

ATITUS EDUCAÇÃO
ESCOLA DE NEGÓCIOS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO
MESTRADO EM ADMINISTRAÇÃO

Jordenson Miguel Plentz

MODELOS DE PREVISÃO DE DEMANDA
NA CONSTRUÇÃO CIVIL

Passo Fundo

2024

CIP – Catalogação na Publicação

P725m PLENTZ, Jordenson Miguel

Modelos de previsão de demanda na construção civil / Jordenson Miguel Plentz. – 2024.

71 f., il.; 30 cm.

Dissertação (Mestrado em Administração) – ATITUS Educação, Passo Fundo, 2024.

Orientação: Prof. Dr. Vitor Francisco Dalla Corte.

1. Administração. 2. Construção civil. 3. Previsão de faturamento.
I. DALLA CORTE, Vitor Francisco, orientador. II. Título.

CDU: 65

Catalogação: Bibliotecária Angela Saadi Machado - CRB 10/1857

Jordenson Miguel Plentz

**Modelos de previsão de demanda
Na construção civil**

Projeto de Dissertação / Dissertação
apresentado(a) ao Programa de Pós-Graduação
em Administração da Escola de Administração
da ATITUS Educação , como requisito parcial
para a obtenção do grau de Mestre em
Administração sob a orientação do Prof. Dr.
Orientador. Vitor Dalla Corte

Passo Fundo

2024

Jordenson Miguel Plentz

**Modelos de previsão de demanda
Na construção civil**

Projeto de Dissertação / Dissertação
apresentado(a) ao Programa de Pós-Graduação
em Administração da Escola de Administração
da Faculdade Meridional – IMED, como
requisito parcial para a obtenção do grau de
Mestre em Administração sob a orientação do
Prof. Dr. Orientador. Vitor Dalla Corte

Aprovada em: _____ de _____ de _____

BANCA EXAMINADORA



Orientador: Dr. Vitor Dalla Corte



Examinador: Dr. Dieisson Pivoto



Examinador: Dr. Diego Alex Gazaro



Examinador: Dr. João Luis Zeni Montenegro

Passo Fundo

2024

RESUMO

A imensidão de dados presentes hoje e o desenvolvimento do poder computacional traz para a sociedade inúmeros benefícios. Tais artifícios ajudam a melhorar processos de tomada de decisões, os quais antes eram baseados somente em questões vividas pelo diretor ou informações recebidas de terceiros. O presente estudo busca prever vendas, em termos de faturamento da empresa, tomando como base tanto dados socioeconômicos que são externos a empresa, quanto dados internos como margem de lucro, custo de mercadoria, ativos, passivos, empréstimos, dentre outros. Assim, analisou-se os dados de 33 empresas listadas na bolsa de valores Bovespa e dados sociais e econômicos dos últimos 10 anos da realidade brasileira, a fim de criar um banco de dados. Os dados foram tratados a partir de métodos como, regressão linear, rede neural e Random Forest, sendo que a último apresentou menores erros. Já para as variáveis de entrada, destacou-se nos modelos o patrimônio líquido das empresas, assim como, comércio de mercadorias e importação de bens e serviços.

Palavras-chave: Previsão. Demanda. Faturamento.

ABSTRACT

The immensity of data presented nowadays, and the development of computational power brings considerable benefits to society. Such contributions helped to improve decision-making processes, which were previously based only on issues experienced by the manager or on information received from third parties. The present study seeks to forecast sales, in terms of the company's revenue, based on both socioeconomic data, that are external to the company, and internal data such as profit margin, cost of goods, assets, liabilities, loans, among others. Thus, data from 33 companies included in the Bovespa stock exchange and social and economic data from the last 10 years of the Brazilian reality were sought, to create an incorporated database to run analytical methods. The data was processed using methods such as linear regression, neural network and Random Forest, the latter of which presented smaller errors. As for the input variables, the companies' equity models stood out, as well as merchandise transactions and imports of goods and services.

Keywords: Forecast. Demand. Invoicing.

LISTA DE ILUSTRAÇÕES

<i>Figura 1.</i> Rede neural multicamadas.....	15
<i>Figura 2.</i> PIB e PIB per capita.	24
<i>Figura 3.</i> Comércio de mercadorias, Desemprego e importações de bens e serviços.	24
<i>Figura 4.</i> População Brasil.....	25
<i>Figura 5.</i> Dívida governo central.	25
<i>Figura 6.</i> IPCA x INCC-M.	26
<i>Figura 7.</i> Taxa Selic.	27
<i>Figura 8.</i> Unidades Financiadas CONSTRUÇÃO x AQUISIÇÃO.....	27
<i>Figura 9.</i> Teste 1.1- Regressão Linear.	31
<i>Figura 10.</i> Teste 1.1- Rede Neural.	32
<i>Figura 11.</i> Teste 1.1- Random Forest.	32
<i>Figura 12.</i> Teste 1.2- Regressão Linear.	34
<i>Figura 13.</i> Teste 1.2 - Rede Neural.	34
<i>Figura 14.</i> Teste 1.2 - Random Forest.	35
<i>Figura 15.</i> Teste 2.1 - Regressão Linear.	36
<i>Figura 16.</i> Teste 2.1 - Rede neural.	37
<i>Figura 17.</i> Teste 2.1 - Random Forest.	37
<i>Figura 18.</i> Teste 2.2 - Regressão Linear.	39
<i>Figura 19.</i> Teste 2.2 - Rede neural.	39
<i>Figura 20.</i> Teste 2.2 - Random Forest.	40
<i>Figura 21.</i> Teste 3.1 - Regressão Linear.	42
<i>Figura 22.</i> Teste 3.1 - Rede neural.	42
<i>Figura 23.</i> Teste 3.1 - Random Forest.	43
<i>Figura 24.</i> Teste 3.2 - Regressão Linear.	44
<i>Figura 25.</i> Teste 3.2 - Rede Neural.	45
<i>Figura 26.</i> Teste 3.2 - Random Forest.	45
<i>Figura 27.</i> Teste 4.1 - Regressão Linear.	47
<i>Figura 28.</i> Teste 4.1 - Rede Neural.	48
<i>Figura 29.</i> Teste 4.1 – Random Forest.....	48
<i>Figura 30:</i> SHAP, Rede Neural Teste 4.1.....	49
<i>Figura 31:</i> SHAP, Random Forest Teste 4.1.....	50
<i>Figura 32.</i> Teste 4.2 - Regressão Linear.	50
<i>Figura 33.</i> Teste 4.2 – Rede Neural.	51
<i>Figura 34.</i> Teste 4.2 – Random Forest.....	52
<i>Figura 35:</i> SHAP, Rede Neural Teste 4.2.....	53
<i>Figura 36:</i> SHAP, Random Forest Teste 4.2.....	53

LISTA DE TABELAS

Tabela 1	17
Tabela 2	28
Tabela 3	30
Tabela 4	30
Tabela 5	33
Tabela 6	33
Tabela 7	35
Tabela 8	36
Tabela 9	38
Tabela 10	38
Tabela 11	40
Tabela 12	41
Tabela 13	43
Tabela 14	44
Tabela 15	46
Tabela 16	46
Tabela 17	47
Tabela 18	49
Tabela 19	50
Tabela 21	52

LISTA DE SIGLAS

SKU - Stock Keeping Unit

ANNs - Redes Neurais Artificiais

IBGE - Instituto Brasileiro de Geografia e Estatística

PIB - Produto Interno Bruto

IPCA - Índice de Preços ao Consumidor Amplo

INCC-M - Índice Nacional de Custo de Construção — Mercado

ALSO3 - ALIANSCSONAE

BDLL3 - BARDELLA

BRAP3 - BRADESPAR

CALI3 - CONST A LIND

CCRO3 - CCR SA

CORR3 - COR RIBEIRO

CRDE - CR2

CSNA3 - SID NACIONAL

CYRE3 - CYRELA REALT

DXCO3 - DURATEX

ECOR3 - ECORODOVIAS

ETER3 - ETERNIT

EUCA3 - EUCATEX

EVEN3 - EVEN

EZTC3 - EZTEC

FESA3 - FERBASA

GFSA3 - GAFISA

GGBR3 - GERDAU

GOAU3 - METLURGICA GERDAU

GSHP3 - GENERALSHOPP

HBOR3 - HELBOR

HBTS3 - HABITASUL

IGTA3 - IGUATEMI

INEP3 - INEPAR

JFEN3 - JOAO FORTES

JHSF3 - JHSF PARTS

KEPL3 - KEPLER WEBER

MDNE3 - MOURA DUBEUX

MGEL3 - MANGELS

MRVE3 - MRV

MULT3 - MULTIPLAN

MWET3 - WETZEL

PATI3 - PANATLANTICA

PDGR3 - PDG REALT

PTBL3 - PORTOBELLO

RDNI3 - RNI

RSID3 - ROSI RESIDENCIAL

SOND3 - SONDOTECNICA

SYNE3 - SYN PROP TEC

TCSA3 - TECNISA

TEND3 - TENDA

TKNO3 - TEKNO

TOTS3 - TOTVS

TPIS3 - TRIUNFO PARTS

TRIS3 - TRISUL

USIM3 - USIMINAS

VALE3 - VALE

VIVR3 - VIVER

WEGE3 - WEG AS

CBIC - Câmara Brasileira da indústria de Construção

SHAP - Shapley additive exlanations

Sumário

1.INTRODUÇÃO.....	11
1.1 OBJETIVOS.....	12
1.1.1 Objetivos Gerais	12
1.1.2 Objetivos Específicos	12
2. PREVISÃO DE DEMANDA.....	12
2.1 Modelos Causais.....	13
2.2 Modelos Temporais	13
2.3 Redes neurais.....	14
3. CRITÉRIOS DE AVALIAÇÃO	15
4. PREVISÃO DE DEMANDA NA CONSTRUÇÃO CIVIL	16
5. INDICADORES	17
6. MÉTODO.....	20
7. RESULTADOS	23
8. CONCLUSÃO.....	53
REFERÊNCIAS	56

1.INTRODUÇÃO

Todo produto, transporte ou consumidor deixa uma enorme quantidade de informações para as empresas. Esse material, quando bem analisado, traz ao administrador facilidade na tomada de decisões, trazendo produtos e/ou serviços mais assertivos para o cliente. O mercado dinâmico e competitivo do século XXI, necessita de ferramentas que produzem *insights* rápidos e assertivos, nesse contexto, unir métodos analíticos com softwares de *Machine Learning* trazem inúmeros benefícios para a empresa. (Devenport, 2013)

O estudo de gerenciamento de demanda surgiu entre o final da década de 80 e início da década de 90, usando técnicas manuais e simples. O conceito teve um maior respaldo por parte das empresas nos últimos 15 anos, quando as técnicas ficaram mais assertivas e com um menor custo de implementação. (Chase , 2016)

A maioria dos gerentes têm nas técnicas quantitativas um maior apreço, principalmente quando se tem dados confiáveis para se gerenciar uma previsão. Essas técnicas são baseadas em modelos matemáticos e dentre os mais utilizados estão, técnicas de regressão linear, abordagem de suavização exponencial, média móvel, Box-Jenkins e linha de tendência. (Dharshini & Vijila, 2021)

Com o passar dos anos, a aquisição de dados vem sendo facilitada devido ao avanço da tecnologia, assim, com o uso de computadores mais potentes no mercado e softwares mais avançados, tem-se, em algoritmos de *deep learning*, por comparação a técnicas mais primitivas, resultados mais assertivos, quando se trata em previsão de demanda. (Eglite & Birzniece, 2022)

Algoritmos de *machine learning* são usadas por empresas ao redor do mundo, como é o caso da farmácia DM, localizada na Alemanha. A empresa usa a ferramenta para realizar compras mais assertivas e não faltar produtos em suas gondolas, criando demandas semanais, baseadas em *Stock Keeping Unit* (SKU). O artefato de previsão e demanda foi treinado com dados de 2,5 anos de um de seus centros de distribuição, obtendo uma precisão de 6 meses. (Wenzel, Smit, & Sardesai, 2019)

Uma lacuna visível em artigos é a falta de pesquisas que desenvolvam técnicas para aplicações reais em empresas (Wenzel, Smit, & Sardesai, 2019), ou seja, faltam insights que podem auxiliar o administrador a melhorar o processo de tomada de decisões. (Shrestha, Krishna, & von Krogh, 2021). Assim, a questão que norteia a pesquisa é: Quais fatores influenciam na demanda de empresas do setor da construção civil?

1.1 OBJETIVOS

1.1.1 Objetivos Gerais

- Avaliar o modelo de melhor ajuste para prever da demanda das empresas no setor da construção civil, adotando como variável dependente o faturamento, por meio da aplicação de métodos quantitativos de previsão.

1.1.2 Objetivos Específicos

- Coletar dados históricos internos de empresas, assim como, dados econômicos e sociais a fim de criar um banco de dados;
- Selecionar e implementar modelos de previsão, como regressão linear, machine learning e Random Forest, considerando especificidades do setor;
- Avaliar e comparar dados de teste com dados previstos.

2. PREVISÃO DE DEMANDA

O processo de previsão de demanda tem como metodologia básica o tratamento de dados para tentar antever acontecimentos futuros (Harrison & Stevens, 1976), ou seja, reconhecer padrões em informações históricas ou ainda identificar fatores que influenciam uma grandeza de interesse (Ackermann & Sellitto, 2022). Essa ferramenta auxilia gestores de empresa no processo de tomada de decisão, a fim de melhorar investimentos em estoques, melhorar experiência dos consumidores, aumentar lucros e minimizar riscos.

Em um problema de previsão pode-se adotar, tanto informações singulares, que são aquelas que pertencem ao problema, quanto informações distributivas, as quais pertencem a casos semelhantes, (Kahneman & Tversky, 1977) assim como, informações essenciais podem ser desconhecidas pelo analista (Harrison & Stevens, 1976). Em decisões cotidianas, pessoas tendem a prever situações usando informações cuja confiabilidade é baixa, assim usam a intuição para tomar decisões. O uso de técnicas, busca minimizar erros de previsão, tendo, portanto, resultados mais assertivos. (Kahneman & Tversky, 1977)

Existem diversos métodos podem ser usados em modelos de previsão, os quais, terão cunhos quantitativos ou qualitativos. Os métodos quantitativos, são produtos de equações matemáticas e não precisão de julgamento de um especialista, já os qualitativos requerem poucas informações e o especialista que faz o julgamento para realizar hipóteses futuras (Ackermann & Sellitto, 2022), geralmente são usadas em lançamento de produtos inovativos e tecnológicos. (Dharshini & Vijila, 2021)

A previsão de demanda qualitativa pode vir através da experiência de algum profissional da área, ou ainda, trazendo situações semelhantes, as quais podem trazer analogias importantes para o tratamento de informações. Outro método bastante utilizado são as surveys, que conseguem trazer significância para a pesquisa. (Ackermann & Sellitto, 2022)

2.1 Modelos Causais

São estruturas usadas quando determinadas variáveis afetam alguma situação, ou seja, quando variáveis dependentes apresentam alguma causa-efeito com variáveis independentes, geralmente são usados regressões, índices e segmentação. (Armstrong & Green, 2011). O modelo de regressão pode ser simples ou múltiplo, lineares ou não lineares. A regressão simples, analisam se uma variável dependente (Y) possui relação significativa com uma variável independente (X), a qual pode ser vista na Equação 1.

$$Y = f(X) \quad (1)$$

A regressão múltipla pode ser observada na Equação 2, onde um conjunto de variáveis independentes (X_1, X_2, \dots, X_n), possuem efeito sobre a variável dependente (Y).

$$Y = f(X_1, X_2, \dots, X_n) \quad (2)$$

O modelo de índice é usado quando existem poucos dados sobre a variável a qual deve ser prevista, onde um ou mais especialistas redigem uma lista de variáveis que influenciam na variável de saída, essas, são baseadas em estudos anteriores a fim de pontuá-las e gerar uma previsão. (Armstrong & Graefe, 2011)

Já na segmentação, divide-se o problema em várias partes, como por exemplo, pode-se adotar a previsão de demanda de uma empresa em segmentos de produtos, a fim de melhorar reduzir erros de previsibilidade. (Armstrong & Green, 2011)

2.2 Modelos Temporais

Esses modelos usam informações passadas para tentar prever comportamentos futuros. Espera-se com isso, que tais padrões sigam tendências do passado, acrescentando assim, a variável tempo nas equações (Ackermann & Sellitto, 2022). As series temporais são divididas em duas partes, aquela que forma os padrões e a que faz ajustes para o modelo de previsão. Esses modelos são muito utilizados na previsão da demanda de energia elétrica. (Deb, Zhang, Yang, & Lee, 2017)

As series temporais são decompostas em três componentes (Deb, Zhang, Yang, & Lee, 2017):

- Tendência: é a linha geral da demanda, quando retirada os efeitos de sazonalidade e resíduos, podendo essa, ser crescentes, decrescentes ou estacionaria;
- Sazonalidade: são tendências cíclicas que ocorrem em determinados períodos do tempo;
- Residual: é a componente inexplicável que pode ter diversas causas.

2.3 Redes neurais

As Redes Neurais Artificiais (ANNs) são baseadas no cérebro humano, onde neurônios ou nós, são as unidades de processamento de dados interconectadas umas às outras, essas recebem informações, denominadas Entradas, para processarem e gerar resultados, chamadas Saídas. (Zhang, Eddy Patuwo, & Y. Hu, 1998)

A expressão matemática que descreve a informação de saída no neurônio é descrito na Equação 3, onde A_i é a saída do neurônio, W_{ji} é o peso da conexão, que é ajustado para reduzir o erro entre a saída desejada e A_i , a_j é a entrada do neurônio.

$$A_i = g\left(\sum_{j=0}^n W_{ji} a_j\right) \quad (3)$$

Uma rede neural pode ter uma ou mais camadas de separação de neurônios que são denominadas camadas escondidas. As redes simples, possuem pouca capacidade de tratar informações complexas, assim, ANNs multicamadas são amplamente usadas nas mais diversas áreas das empresas e da ciência. (Raza & Khosravi, 2015)

A estrutura de uma rede neural pode conter uma ou mais entradas, ser simples ou multicamadas e uma ou mais saídas, como pode ser observado na Figura 1.

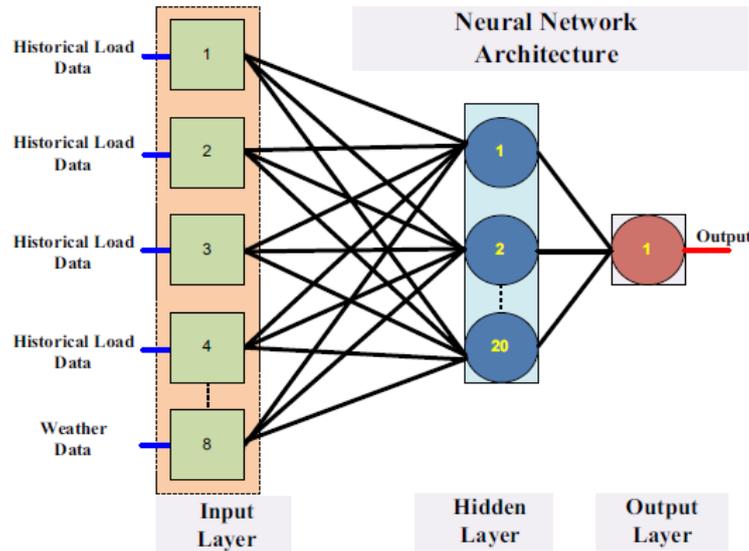


Figura 1. Rede neural multicamadas.

Existem duas fases para estruturação do modelo de uma ANN, a etapa de treino e a de teste, onde um pedaço dos dados de entrada são retirados do treinamento e ficam disponíveis para a verificação do erro do modelo. A fase de treino é quando o modelo calcula os pesos de cada neurônio a fim de chegar o mais próximo possível dos valores de saída presentes na base de dados. (Raza & Khosravi, 2015)

Uma rede neural pode ainda ser dividida em duas categorias, as supervisionadas e as não supervisionadas. As ANNs supervisionadas, o cientista de dados mostra pro modelo os dados de entrada e saída, já a não supervisionara, dados de saída não são apresentadas para o modelo e a própria ANN tenta achar padrões nos dados de entrada. (Raza & Khosravi, 2015)

3. CRITÉRIOS DE AVALIAÇÃO

Diversos métodos para se medir a precisão de um modelo de previsão de demanda são encontrados em artigos científicos, porém os que são mais utilizados são os baseados em valores absolutos e relativos, como podem ser vistos nas equações abaixo, onde A_t é o dado observado e Y_t é o dado previsto.

Erro quadrático médio ou Mean Square Error (MSE):

$$MSE = \frac{1}{N} \sum_{i=1}^N (A_t - Y_t)^2 \quad (4)$$

Desvio quadrático médio ou Root Mean Square Error (RMSE):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (A_t - Y_t)^2} \quad (5)$$

Erro médio absoluto ou Mean Absolute Error (MAE):

$$MAE = \frac{1}{N} \sum_{i=1}^N |A_t - Y_t| \quad (6)$$

Erro percentual médio absoluto ou Mean Absolute Percentage Error (MAPE):

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{A_t - Y_t}{A_t} \right| \quad (7)$$

O método MAPE, possui a desvantagem quando A_t for igual a zero ou ter um valor muito próximo a zero, pois a equação pode ser indefinida ou ter um valor em porcentagem muito grande. (Kim & Kim, 2016)

4. PREVISÃO DE DEMANDA NA CONSTRUÇÃO CIVIL

A indústria da construção civil no Brasil apresentou no ano de 2020 um faturamento bruto de 344,9 trilhões de reais, onde o sudeste é responsável por 54%, o sul representa 19,7%, nordeste com 14%, centro-oeste 8,4% e norte 3,9%. O custo total do segmento é de 273,3 bilhões de reais onde os três principais custos são: gastos com pessoal, materiais de construção e obras e/ou serviços contratados de terceiros, representando 85,8, 62,5 e 25,8 bilhões de reais respectivamente. (Instituto Brasileiro de Geografia e Estatística [IBGE], 2020)

O mercado da construção civil possui efeitos de sazonalidade que pode ser diferente em cada país ou região. Mach et al (2020) trouxeram em seu trabalho, a sazonalidade da construção civil em países da Europa, onde apresentou os ciclos podendo ser tanto anuais quanto semianuais, como por exemplo os ciclos da Hungria ocorrem principalmente a cada quatro meses e a cada ano, já a Eslovênia, apresentou basicamente uma sazonalidade anual.

Esse mercado produz infraestrutura, que pode ter âmbito privado, como a construção de residências e edifícios, ou público, incluindo a construção de estradas, hospitais e escolas. Ele também se relaciona com a indústria (fornecimento de matéria-prima e equipamentos), comércio (distribuição de produtos) e mão de obra (engenheiros e construtores). Assim, é um mercado muito amplo, com diversos fatores que influenciam o faturamento de cada empresa.

Estudos apontam que a previsão de demanda melhora a eficiência das empresas, melhorando as perdas nas cadeias de suprimentos, além de oferecer um estoque mais assertivo para futuras vendas. (Deb, Zhang, Yang, & Lee, 2017)

5. INDICADORES

A compreensão dos indicadores socioeconômicos associados a previsão de demanda no setor da construção civil residencial é identificada por vários autores, como: Goh (1996), Goh (1998), Akintoye & Skitmore (1994), Kim et al. (2021).

Geralmente os estudos publicados usam dados secundários, assim como, fatores econômicos e sociais. Goh (1996), trouxe quinze índices fundamentais para a demanda da construção civil, como pode ser visto a seguir., porém apenas treze deles são disponíveis para uso, como pode ser observado na Tabela 1.

Tabela 1

Indicadores teóricos e disponíveis

INDICADORES TEÓRICOS	INDICADORES DISPONÍVEIS
Renda nacional per capita	Renda per capita
Demanda geral da construção civil	Investimentos na construção civil e serviços
Tamanho da população	População
Taxa de construção de domicílios	Número de casamentos registrados
Taxa de juros	Taxa de juros
Preço dos imóveis	Índice de preços dos imóveis
Níveis de oferta de imóveis residenciais	Número de projetos aprovados
Renda disponível	Não disponível
Crescimento econômico	PIB
Taxa de desemprego	Taxa de desemprego
Casas existentes	Não disponível
Inflação	Índice de preços ao consumidor
Custo da construção	Índice de preços do material de construção
Disponibilidade de crédito para construção	Oferta monetária e saques da previdência social
Poupança	Poupança

Assim, após adequar os índices para dados disponíveis, reduziu-se ainda para doze indicadores econômicos, os quais foram utilizados como entradas para os modelos de previsão, são eles: renda per capita, investimentos na construção e serviços, PIB, Índice de preços do material de construção, oferta de dinheiro, poupança, saques da previdência social, taxa de juros, índice de preços ao consumidor, força de trabalho e taxa de desemprego.

Em outro estudo publicado dois anos depois, Goh reformula os indicadores disponíveis, os quais são descritos a seguir.

- PIB
- PIB per capita
- Produtividade
- Taxa de juros
- Formação familiar
- População
- Índice de preços de imóveis
- Renda disponível
- Salários e ganhos
- Desemprego
- Casas disponíveis
- Projetos aprovados
- Índice de preços ao consumidor
- Deflator implícito do PIB
- Índice de preços da construção
- Índice de preços dos materiais de construção
- Disponibilidade de dinheiro
- Reservas nacionais

A partir de tais indicadores apenas sete são utilizados no modelo, População, Desemprego, Incremento de casas disponíveis, Índices de preços da construção, Reservas nacionais (governo + privado), Crédito a habitação e Investimentos.

Para um modelo ter uma boa assertividade, é fundamental que as entradas sejam bem escolhidas, assim, Kim et al. (2021), em seu trabalho, usa diagrama de loop causal para identificar as influências entre os indicadores, os quais podem ser criadores de demanda e são listados a seguir.

- População
- População ativa
- Famílias
- Famílias com uma ou duas pessoas
- Índice de urbanização
- Disponibilidade de dinheiro
- PIB
- Taxa de juros
- Endividamento familiar
- Endividamento do governo
- Índice de preços ao consumidor
- Índice de preços de casas
- Índice de preços da construção
- Regularização do mercado
- Preço bruto do petróleo
- Casas disponíveis
- Vida útil
- Taxa de depreciação

Além de indicadores econômicos, políticos e socioculturais, o ambiente da indústria e internos da própria empresa podem afetar a demanda do setor. Fatores como, poder de compra e competidores pode influenciar preços e qualidade de produtos, assim como, marketing, processos e financeiro, que engloba a habilidade de ter liquidez, ser lucrativo ou obter financiamento. (Haslindah, Hamdat, Mora, & Hanafiah, 2021)

Por meio de ações e estratégias, gestores podem controlar a demanda de produtos. Por exemplo, ao reduzir o preço de um produto, obtém-se um aumento de demanda, ao reduzir esforços de marketing a tendencia é reduzir as vendas dos produtos. Assim, em um processo de tomada de decisão, pode-se antecipar problemas de oferta e gerenciar oportunidades. (Esper, Elinger, Stank, Flint, & Moon, 2009)

Diversas pesquisas afirmam que investimentos em Pesquisa e Desenvolvimento (P&D) possuem correlação direta e positiva com a receita de vendas e o aumento do lucro (Souza, Mendes, Silva, & Rodrigues, 2018) (Ramos & Zilber, 2015). Porém, tais resultados não são momentâneos e são refletidos nos anos seguintes. Em trabalho publicado por Souza et al. (2018), com um total de 2178 empresas verificou-se que 73,58% da receita de vendas é

explicada pelo P&D e Despesas de Capital (Capex), assim como, 63,67% do lucro é explicada pelos mesmos fatores.

Investimentos em marketing e P&D são importantes para a criação de demanda no ambiente da construção civil, enquanto um traz resultados analisando o cliente o outro cria soluções e produtos. Olhando sob perspectiva de empresas líderes de mercado e mercados dinâmicos, Vadakkepatt et al. (2021) explica que investimentos em P&D traz melhores resultados do que investimentos em marketing quando se analisa a permanência das empresas em posições consolidadas no mercado, assim, para grandes empresas, alavancagem financeira aumenta ainda mais a liderança em vendas, pois tem-se maior disponibilidade de recursos para fazer investimentos nessas duas áreas.

6. MÉTODO

A presente pesquisa adota uma abordagem quantitativa, que visa analisar dados econométricos e internos de empresas, a fim de prever a demanda futura de vendas. Por meio do uso de técnicas baseadas em fórmulas matemáticas, busca-se identificar padrões de consumo e comportamentos que possam influenciar a demanda.

Para realizar a previsão de demanda na construção civil, é imprescindível contar com dados de entrada confiáveis e relevantes. Nesse sentido, foram utilizados dados secundários, ou seja, Demonstrativo de Resultado (DRE) e Balanço de 45 empresas, as quais pertencem aos segmentos de artefatos de ferro e aço, engenharia consultiva, exploração de imóveis, exploração de rodovias, incorporação, madeira, minerais metálicos, produção para construção, programas e serviços, siderurgia, assim como, motores, compressores e outros, listadas na bolsa de valores Bovespa.

Inicialmente, realizou-se uma análise mais aprofundada das empresas com o objetivo de compreender melhor seus segmentos. Como resultado, identificaram-se três empresas em processo de recuperação judicial, outras quatro que não pertenciam ao setor da construção civil e três que apresentava lucro líquido e faturamento negativos, assim o cálculo relativo do lucro líquido não poderia ser analisado pela fórmula padrão, sendo estas excluídas do banco de dados.

Posteriormente, foi executado um algoritmo de correlação em Python, utilizando a biblioteca Pandas e o comando *dataframe.corr()*, para examinar as relações entre os dados secundários coletados, bem como as variáveis do Demonstrativo de Resultado do Exercício (DRE) e do balanço patrimonial, visando investigar possíveis correlações com o faturamento bruto de cada empresa. Em alguns casos, constatou-se a ausência de correlação significativa

entre os dados secundários e a receita da empresa, resultando na exclusão de mais três empresas do banco de dados, restando assim 33 empresas, listadas a seguir.

- ALSO3 - ALIANSCSONAE
- CCRO3 - CCR SA
- CRDE - CR2
- CSNA3 - SID NACIONAL
- CYRE3 - CYRELA REALT
- DXCO3 - DURATEX
- ECOR3 - ECORODOVIAS
- EUCA3 - EUCATEX
- EVEN3 - EVEN
- FESA3 - FERBASA
- GSHP3 – GENERAL SHOPP
- GGBR3 - GERDAU
- GOAU3 - METALURGICA GERDAU
- HBOR3 - HELBOR
- IGTA3 - IGUATEMI
- JHSF3 - JHSF PARTS
- MDNE3 - MOURA DUBEUX
- MRVE3 - MRV
- PATI3 - PANATLANTICA
- PDGR3 - PDG REALT
- PTBL3 - PORTOBELLO
- RDNI3 - RNI
- SOND3 - SONDOTECNICA
- SYNE3 - SYN PROP TEC
- TCSA3 - TECNISA
- TEND3 - TENDA
- TKNO3 - TEKNO
- TOTS3 - TOTVS
- TPIS3 - TRIUNFO PARTS

- TRIS3 - TRISUL
- USIM3 - USIMINAS
- VALE3 - VALE
- WEGE3 - WEG SA

Foram utilizados dados econômicos, do período compreendido entre 2012 a 2022, divulgados pelo Instituto Brasileiro de Geografia e Estatística (IBGE), Câmara Brasileira da indústria de Construção (CBIC) e Banco Mundial, como, Produto Interno Bruto (PIB) (US\$), Comércio de mercadorias (% PIB), População total, Desemprego total (% da força de trabalho total), PIB per capita (US\$), Importação de bens e serviços (% PIB), Dívida do governo central (% PIB), Índice de Preços ao Consumidor Amplo (IPCA), Índice Nacional de Custo de Construção — Mercado (INCC-M), Construção de casas financiadas, Aquisição de casas financiadas e taxa SELIC. Visando assim, obter-se uma visão abrangente e fundamentada das condições econômicas e do mercado que possam impactar a demanda na construção civil.

A normalização de dados é uma prática útil quando os dados das diferentes empresas estão dispersos. Isso ocorre porque, durante a aplicação dos modelos, pode haver uma tendência de os números das empresas com valores mais altos influenciarem desproporcionalmente os resultados, levando a uma falsa impressão de que o modelo atende a toda a indústria de maneira equitativa.

Portanto, utilizou-se o MinMaxScaler no algoritmo, que converte os dados em um intervalo de números que varia de 0 a 1. Essa técnica garante que todas as variáveis tenham o mesmo peso relativo durante a análise, independentemente de suas escalas originais, ajudando assim a evitar distorções causadas por diferenças nas magnitudes dos dados. O processo foi realizado de duas maneiras: inicialmente, os dados de cada empresa foram normalizados separadamente e, posteriormente, todos os conjuntos de dados das empresas foram normalizados em conjunto. (Singh & Singh, 2019)

Com o objetivo de desenvolver um modelo preciso e confiável para empresas do setor da construção civil no Brasil, é essencial realizar testes de várias técnicas de previsão, assim, foram avaliados modelos estatísticos e técnicas de inteligência artificial, como regressão linear, rede neural e *Random Forest*. Essa abordagem abrangente permitiu a comparação e avaliação de diferentes métodos, visando identificar aqueles que melhor se adequam ao contexto específico do setor e fornecem resultados mais precisos.

Na etapa de treinamento dos dados utilizou-se 80% dos dados disponíveis, já os 20% restantes foram reservados para avaliar a performance do modelo.

Para o código de rede neural, utilizou-se 30 épocas com duas camadas escondidas, a primeira tendo 64 neurônios e a segunda com 32. Já para o modelo *Random Forest* foi definido 100 árvores para a floresta.

Em regressões lineares, o uso do coeficiente de regressão (beta), é fundamental para entender como as variáveis independentes influenciam na dependente, este ajuda a compreender a magnitude e a direção dessa influência. Já para modelos de *machine learning* o uso da técnica de *SHapley Additive exPlanations* (SHAP), ajuda a compreender como as variáveis afetam no modelo.

Para a avaliação da eficácia dos modelos, critérios como Erro quadrático médio, Desvio quadrático médio, Erro médio absoluto e coeficiente de determinação, serão utilizados, a fim de se obter um resultado confiável na antecipação da demanda das empresas no setor da construção civil no Brasil, buscando minimizar discrepância entre valores de previsão e reais. Ao utilizar esse processo, tem-se uma base sólida para a tomada de decisão por parte dos gestores de empresa do setor.

7. RESULTADOS

Os dados secundários utilizados abrangeram indicadores de 10 anos, começando em 2012 e terminando em 2022. Estes incluem, o Produto Interno Bruto (PIB) e o PIB per capita, analisados em dólares, os quais exibiram uma tendência negativa ao longo dos anos, conforme pode ser observado na linha de tendência pontilhada ilustrada na Figura 2.

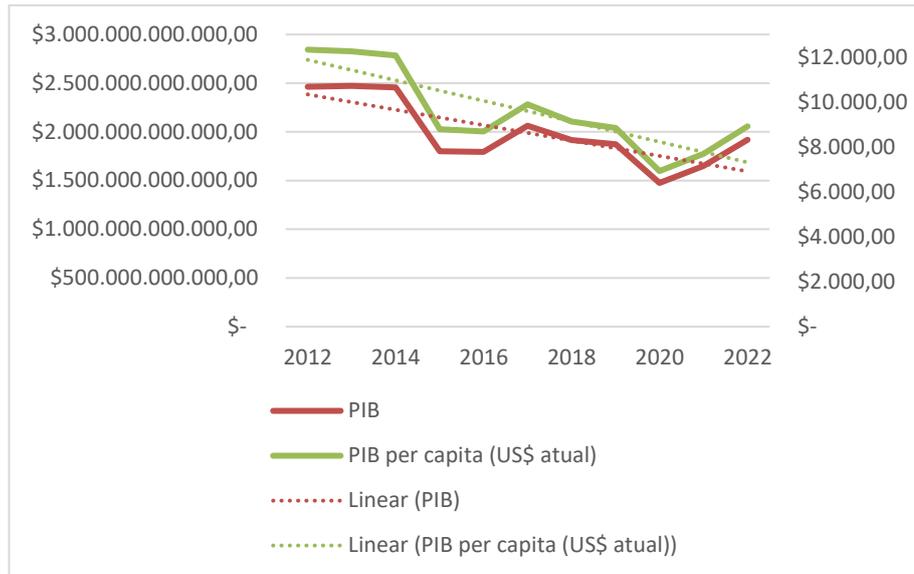


Figura 2. PIB e PIB per capita.

Além disso, foram considerados o comércio de mercadorias, a importação de bens e serviços, os quais apresentaram um comportamento semelhante ao longo do tempo. Por outro lado, o desemprego total aumentou progressivamente ao longo dos anos, registrando uma queda somente em 2022, como mostrado na Figura 3.

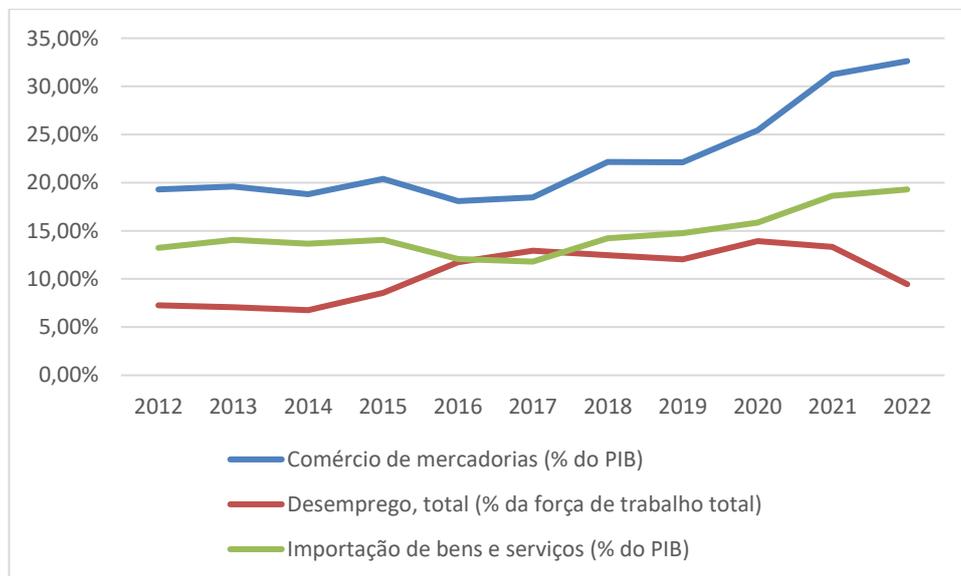


Figura 3. Comércio de mercadorias, Desemprego e importações de bens e serviços.

A população total também foi analisada, apresentando um crescimento bem próximo a linearidade, tendo ainda um aumento de aproximadamente 15 milhões de pessoas no período observado, conforme observado na Figura 4.

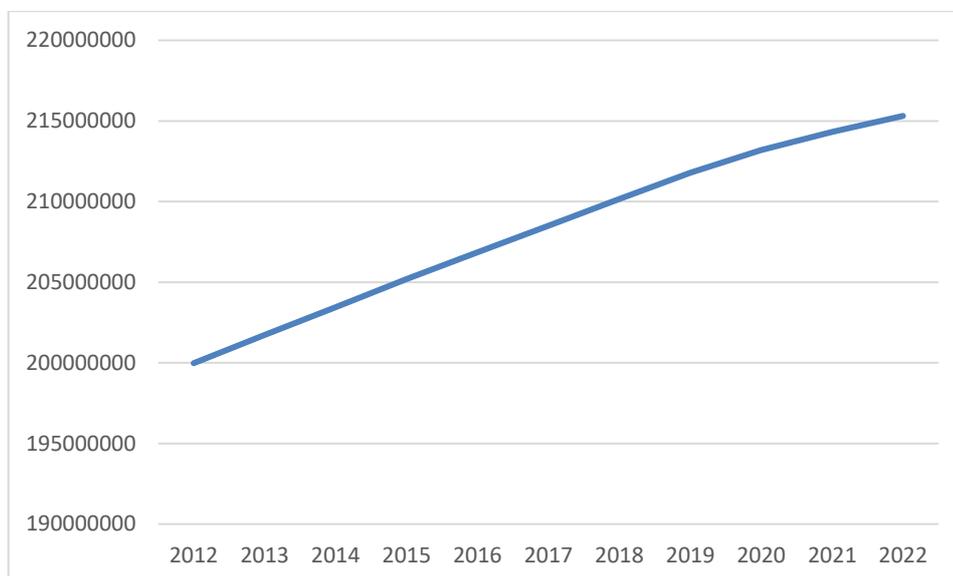


Figura 4. População Brasil.

A dívida do governo central foi aumentando com o passar dos anos, até atingir quase 100% do PIB brasileiro em 2020, sendo que, após houve uma redução nos gastos públicos, conforme evidenciado na Figura 5.

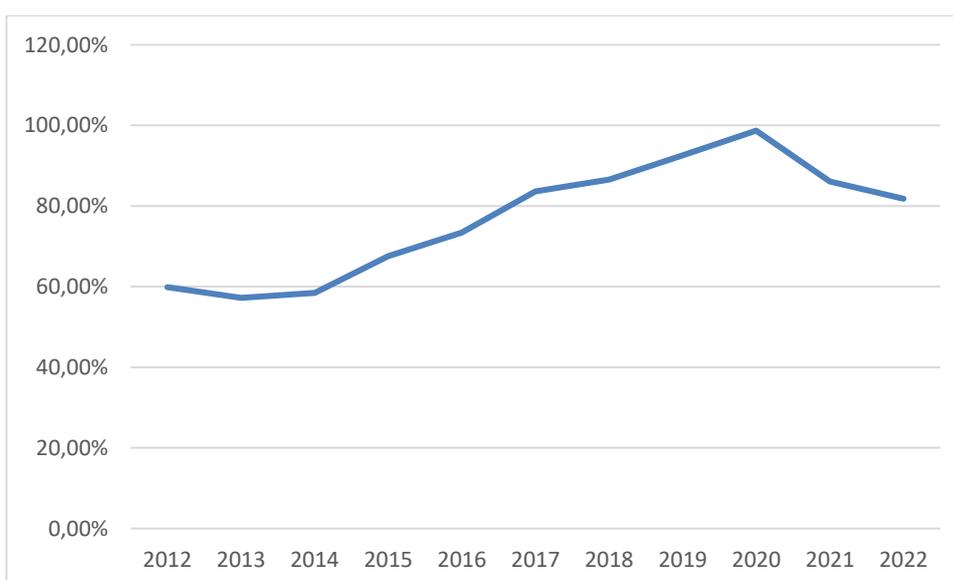


Figura 5. Dívida governo central.

Os índices de inflação, IPCA e INCC-M, são examinados para representar as variações em dois modelos de inflação, os quais apresentam comportamentos muito semelhantes, com os menores índices observados entre 2017 e 2020, atingindo seu ápice no período do Covid, conforme mostrado na Figura 6.

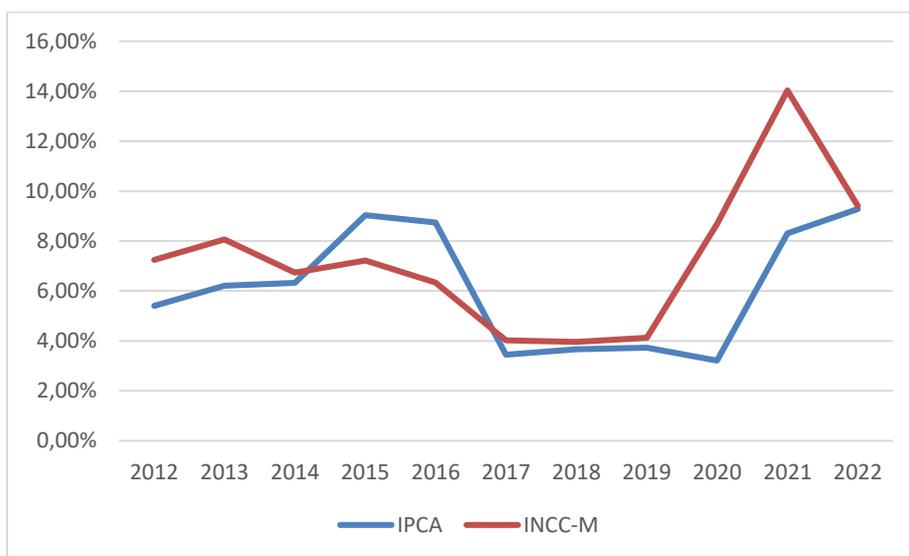


Figura 6. IPCA x INCC-M.

. A taxa Selic, observada na Figura 7, é estabelecida pelo Banco Central com o intuito de controlar avanços inflacionários. Esta taxa apresentou um comportamento similar aos índices inflacionários, porém com um desfasamento temporal perceptível.

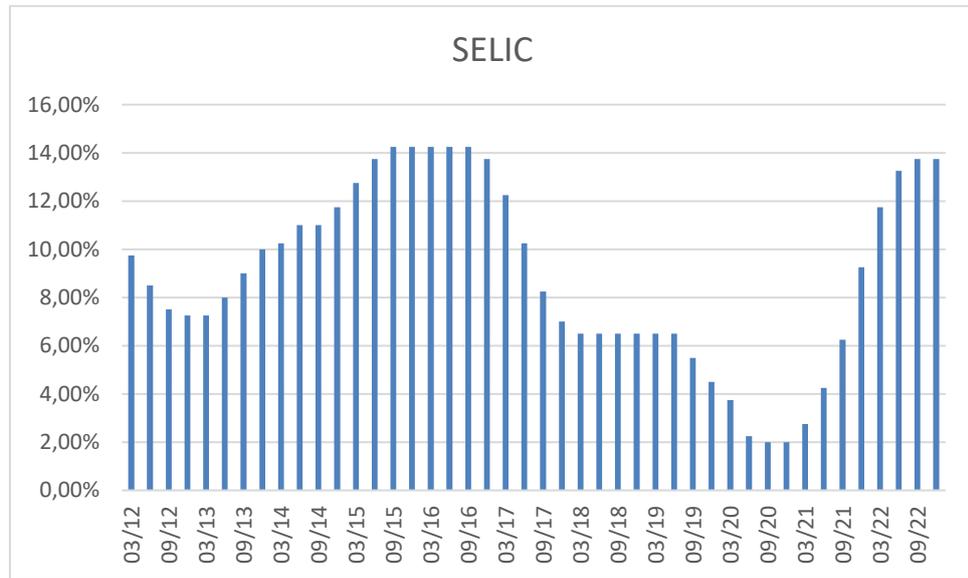


Figura 7. Taxa Selic.

Por fim, foi analisada a construção e a aquisição de casas financiadas para entender o comportamento dos consumidores em relação a financiamentos imobiliários. Os dados mostraram que a aquisição de casas financiadas teve consistentemente maior significância em comparação com os financiamentos para construção. A única exceção foi em 2015, quando houve uma inversão e mais financiamentos foram disponibilizados para construção, conforme indicado na Figura 8.

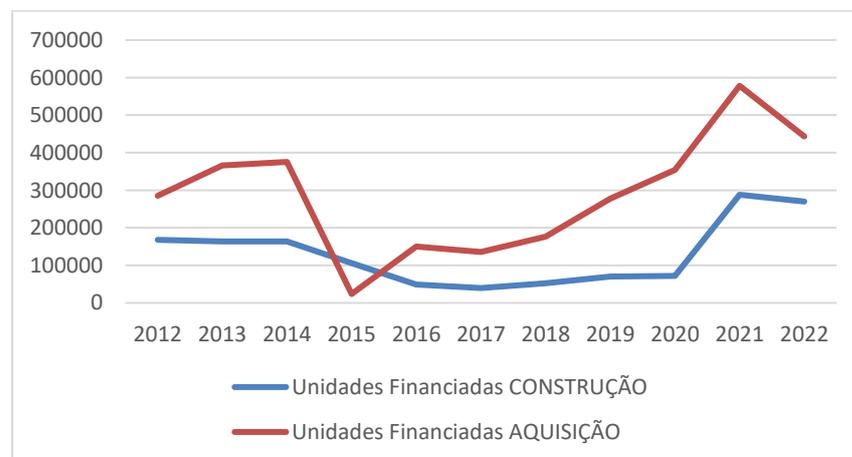


Figura 8. Unidades Financiadas CONSTRUÇÃO x AQUISIÇÃO.

Com esse estudo, notou-se dois grandes grupos com comportamentos distintos em relação a correlação de dados secundários externos e faturamento, o qual pode ser observado no Apêndice 3, portanto dividiu-se os dados em dois bancos, conforme Tabela 2. Para exemplificar, tomamos como exemplo o PIB, para um grupo a correlação veio a ser positiva e para outro negativa.

Tabela 2

Grupo 1 e Grupo 2

NOME	SEGMENTO	GRUPO
PANATLANTICA	Artefatos de Ferro e Aço	1
TEKNO	Artefatos de Ferro e Aço	1
SONDOTECNICA	Engenharia Consultiva	2
ALIANSCSONAE	Exploração de Imóveis	1
GENERALSHOPP	Exploração de Imóveis	2
HABITASUL	Exploração de Imóveis	1
IGUATEMI	Exploração de Imóveis	1
SYN PROP TEC	Exploração de Imóveis	1
CCR SA	Exploração de Rodovias	1
ECORODOVIAS	Exploração de Rodovias	1
TRIUNFO PART	Exploração de Rodovias	2
CR2	Incorporações	2
CYRELA REALT	Incorporações	2
EVEN	Incorporações	2
GAFISA	Incorporações	2
HELBOR	Incorporações	2
JHSF PART	Incorporações	1
MOURA DUBEUX	Incorporações	2
MRV	Incorporações	1
PDG REALT	Incorporações	2
RNI	Incorporações	2
TECNISA	Incorporações	2
TENDA	Incorporações	1
TRISUL	Incorporações	1

VIVER	Incorporações	2
DEXCO	Madeira	1
EUCATEX	Madeira	1
VALE	Minerais Metálicos	1
WEG	Motores . Compressores e Outros	1
PORTOBELLO	Produtos para Construção	1
TOTVS	Programas e Serviços	1
FERBASA	Siderurgia	1
GERDAU	Siderurgia	1
GERDAU MET	Siderurgia	1
SID NACIONAL	Siderurgia	1
USIMINAS	Siderurgia	1

Através da Tabela 2, pode-se observar que indústrias produtoras de matérias primas ou produtos para empresas da construção civil, que possuem outras empresas como clientes encontram-se em sua totalidade no grupo 1. Por outro lado, 66,67% das incorporadoras, encontram-se no grupo 2, enquanto 71,42% das empresas de exploração de imóveis e rodovias estão presentes no grupo 1.

Ao examinar as Tabelas 3 e 4, pode-se observar que no Grupo 1 são apresentadas 968 amostras de dados, enquanto o Grupo 2 possui 485. Ao analisar o ativo total das empresas, as que pertencem ao Grupo 1, exibem uma média notavelmente superior em comparação com as do Grupo 2, por outro lado, os ativos totais do Grupo 1 demonstram maior dispersão, indicando uma ampla variedade no porte das empresas dentro da amostra.

Da mesma forma, o patrimônio líquido das empresas do Grupo 2 é significativamente inferior ao do Grupo 1 em termos de média. Ambos apresentam dados dispersos em torno da média, o que sugere uma heterogeneidade geral nas empresas quando se trata de análise patrimonial.

Quando se analisa faturamento, em média, as empresas do Grupo 1 faturam aproximadamente 11 vezes mais do que aquelas do Grupo 2. Entretanto, a amostra é quatro vezes mais dispersa quando comparada com o Grupo 1.

No que diz respeito ao lucro líquido, as empresas do Grupo 1 demonstram maior estabilidade e lucratividade em comparação com o Grupo 2.

Tabela 3

Estatísticas descritivas Grupo 1

VARIÁVEL	ATIVO TOTAL (MIL R\$)	PATRIMÔNIO LÍQUIDO (MIL R\$)	FATURAM. (MIL R\$)	LUCRO LÍQUIDO
MÉDIA	30822,82	13692,37	16805,52	13,01%
DESVIO PADRÃO	75698,51	34375,17	44860,38	24,12%
MÍNIMO	195,38	56,18	0,00	-180,72%
25%	2147,93	1167,26	760,28	3,22%
50%	5971,96	2806,87	2341,08	10,30%
75%	25992,39	8093,91	10856,93	17,41%
MÁXIMO	499128,00	211926,53	509045,75	162,35%

Tabela 4

Estatísticas descritivas Grupo 2

VARIÁVEL	ATIVO TOTAL (R\$)	PATRIMÔNIO LÍQUIDO (R\$)	FATURAMENTO (R\$)	LUCRO LÍQUIDO
MÉDIA	4015,09	1265,74	1415,72	-79,93%
DESVIO PADRÃO	4022,35	2279,96	1892,87	379,22%
MÍNIMO	73,73	-5606,37	0,00	-4976,37%
25%	1598,14	242,87	208,19	-41,70%
50%	2805,35	912,64	769,32	1,00%
75%	4902,55	1811,97	1832,24	11,88%
MÁXIMO	17976,74	7699,33	15654,53	363,57%

O tratamento de dados foi realizado para cada um dos grupos discutidos anteriormente, utilizando três métodos, regressão linear, redes neurais e *Random Forest*.

Inicialmente, selecionamos como variáveis de entrada para o modelo aquelas que demonstraram uma maior correlação com o faturamento, o qual pode ser visualizado no Apêndice 3. Foi incluído duas variáveis do balanço patrimonial, duas do Demonstrativo de Resultado do Exercício (DRE) e três provenientes de dados externos, sendo elas, para o Grupo 1: ativo total, ativo circulante, custo, lucro bruto, comércio de produtos, importação de bens e serviços, e população total.

Assim, foi aplicado algoritmos de Regressão linear, Rede Neural e Random Forest Os resultados de cada abordagem podem ser observados nas Figuras 9, 10 e 11 respectivamente. É notável que as saídas dos três métodos estão dispostas na diagonal do gráfico, surgindo baixo erro do modelo, como observado na Tabela 5, onde os erros dos três métodos foram bem próximos a zero. Além disso, destaca-se que a técnica Random Forest apresentou um desempenho superior em comparação com as outras abordagens, por se tratar de um modelo mais complexo de aprendizagem.

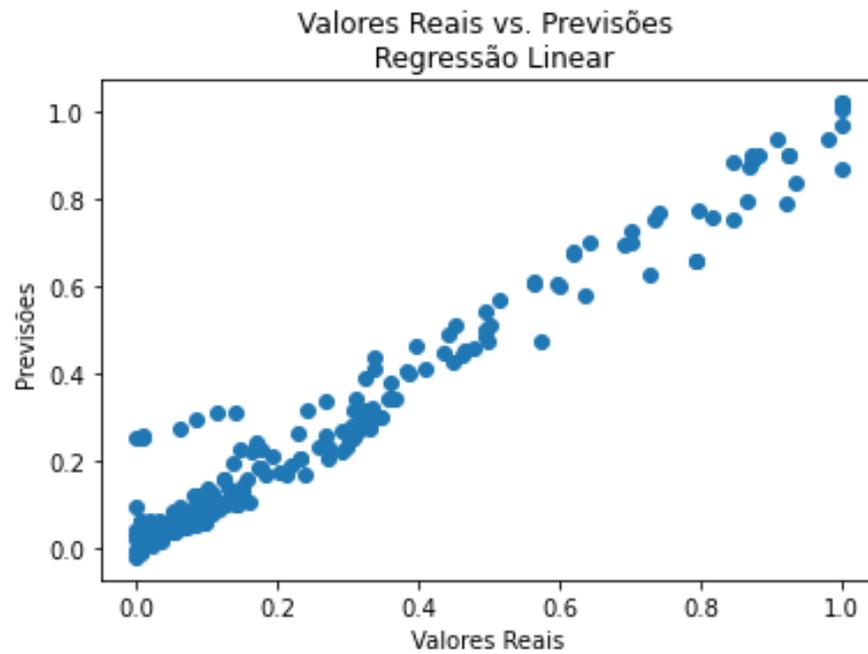


Figura 9. Teste 1.1- Regressão Linear.

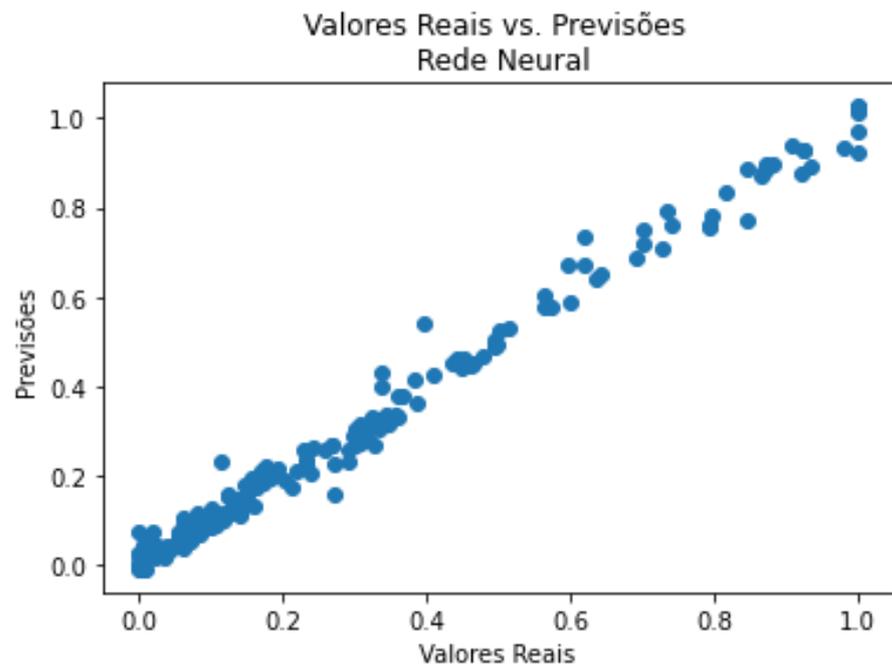


Figura 10. Teste 1.1- Rede Neural.

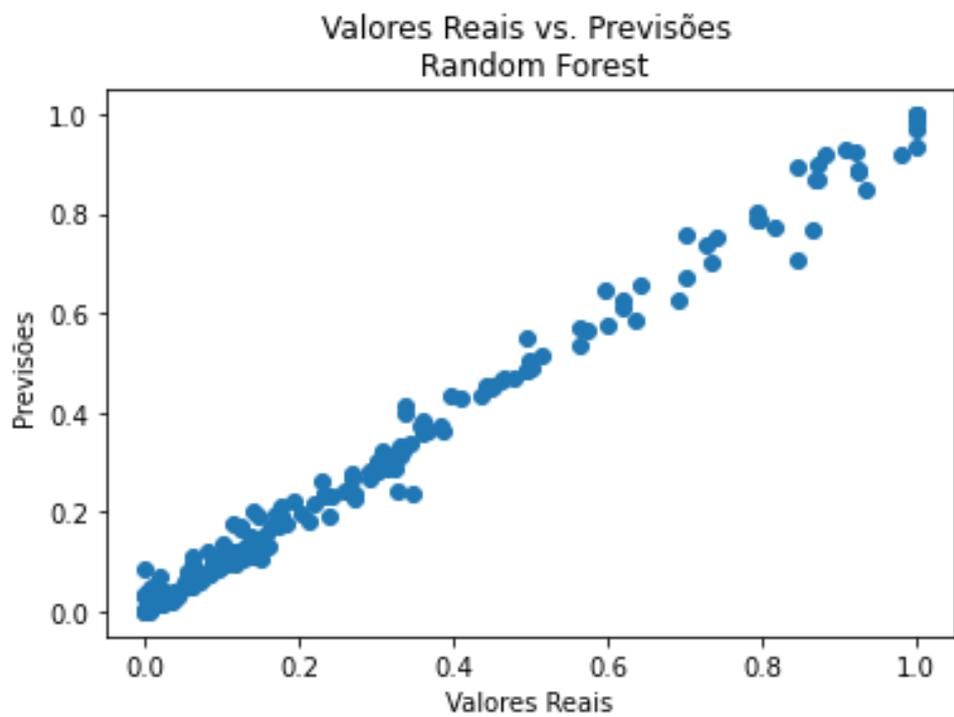


Figura 11. Teste 1.1- Random Forest.

Tabela 5

Teste 1.1 - Resultados

	MSE	RMSE	MAE	R ²
REGRESSÃO LINEAR	0,0034	0,0584	0,0382	0,9595
REDE NEURAL	0,0009	0,0307	0,0208	0,9888
RANDOM FOREST	0,0008	0,0295	0,0190	0,9896

Para a regressão linear são mostrados os Betas de cada variável de entrada, como observado na Tabela 6. Pode-se observar que os maiores pesos do modelo se encontram em variáveis endógenas como custo e lucro bruto, os quais são positivos. Portanto, é possível afirmar que à medida que o Custo e Lucro bruto em espécie aumenta, o Faturamento também cresce.

Tabela 6

Beta Regressão linear 1.1

VÁRIAVEL	PESO (BETA)
ATIVO TOTAL	0,03693
ATIVO CIRCULANTE	0,01866
CUSTO	0,47065
LUCRO BRUTO VALOR	0,47961
POPULAÇÃO TOTAL	-0,00414
COMÉRCIO DE MERCADORIAS	0,07067
IMPORTAÇÃO DE BENS E SERVIÇOS	-0,02597

Já para o Grupo 2, foi adotado uma abordagem semelhante, identificando as variáveis de maior correlação e selecionando duas do balanço patrimonial, duas do Demonstrativo de Resultado do Exercício (DRE) e três provenientes de dados externos. Essas variáveis incluem: ativo total, ativo circulante, custo, lucro bruto, população total, desemprego e dívida do governo central.

Ao analisar as Figuras 12, 13 e 14, nota-se que os dados de saída do modelo encontram-se um pouco mais dispersos do que quando aplicado os dados de entrada do Grupo 1, porém como pode-se visualizar na Tabela 7, os erros ainda permanecem muito baixos, principalmente devido aos dados endógenos das empresas, inseridas no modelo.

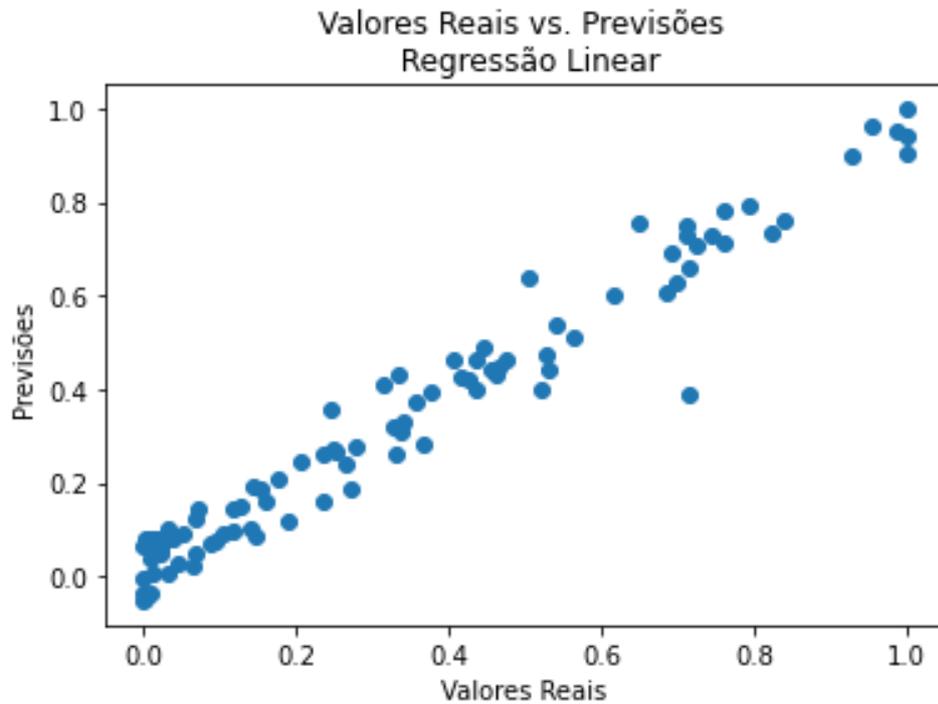


Figura 12. Teste 1.2- Regressão Linear.

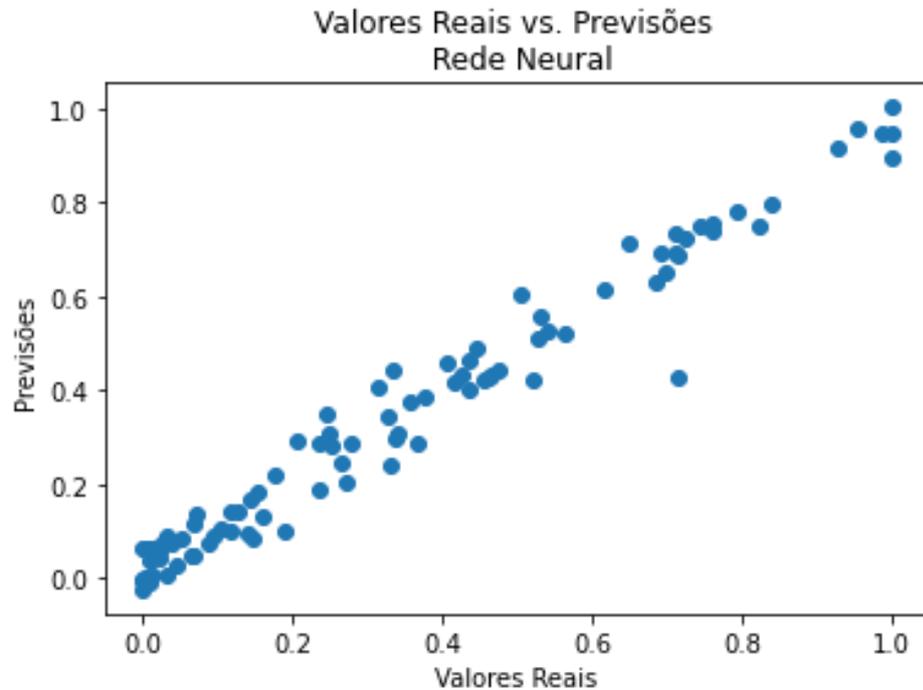


Figura 13. Teste 1.2 - Rede Neural.

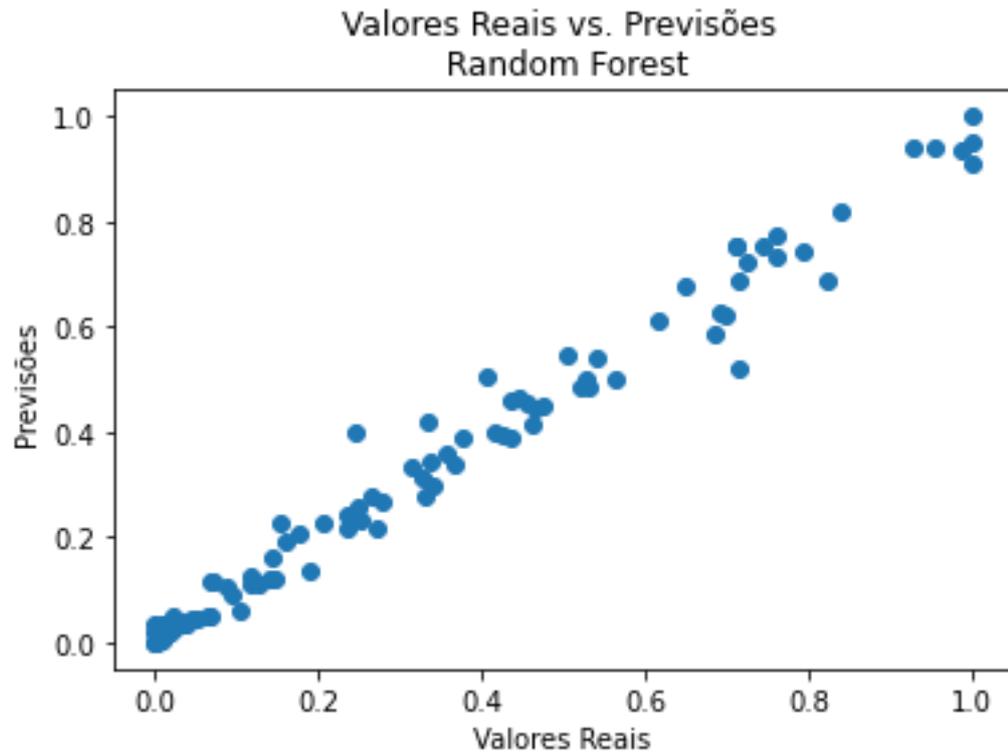


Figura 14. Teste 1.2 - Random Forest.

Tabela 7

Teste 1.2 - Resultados

	MSE	RMSE	MAE	R ²
REGRESSÃO				
LINEAR	0,0038	0,0617	0,0457	0,9575
REDE				
NEURAL	0,0029	0,0543	0,0397	0,9671
RANDOM				
FOREST	0,0019	0,0442	0,0297	0,9781

Os Betas da Regressão linear apresentadas a seguir na Tabela 8, as variáveis custo e lucro bruto também apresentaram pesos maiores, sendo que o custo possui um valor maior quando comparado ao resultado anterior do Grupo 1.

Tabela 8

Beta Regressão linear 1.2

VÁRIAVEL	PESO (BETA)
ATIVO TOTAL	0,07749
ATIVO CIRCULANTE	-0,01986
CUSTO	0,56682
LUCRO BRUTO VALOR	0,44243
POPULAÇÃO TOTAL	-0,06372
DESEMPREGO TOTAL	0,03097
DÍVIDA DO GOVERNO CENTRAL	0,03143

Outro teste conduzido envolveu a inclusão exclusiva de variáveis externas aos modelos. Neste caso, utilizando as mesmas variáveis de entrada para ambos os grupos, sendo elas: Produto Interno Bruto, Comércio de mercadorias, População total, Desemprego total, Importação de bens e serviços, Dívida do governo central, IPCA, INCC-M, Construção de casas financiadas, Aquisição de casas financiadas e SELIC.

Os resultados para os três modelos são vistos nas Figuras 15,16 e 17. Como esperado, observa-se a dispersão dos pontos pelo gráfico, uma vez que foram retirados os dados internos das empresas. Isto, resultou em erros maiores nos modelos quando comparados aos observados no Teste 1, como observado na Tabela 9.

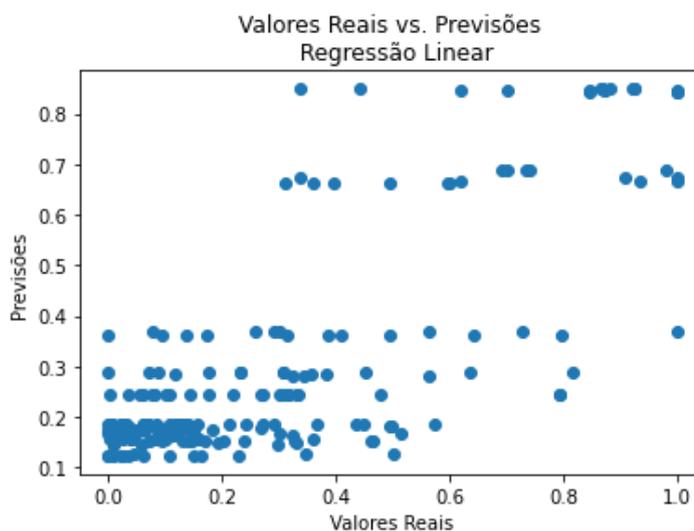


Figura 15. Teste 2.1 - Regressão Linear.

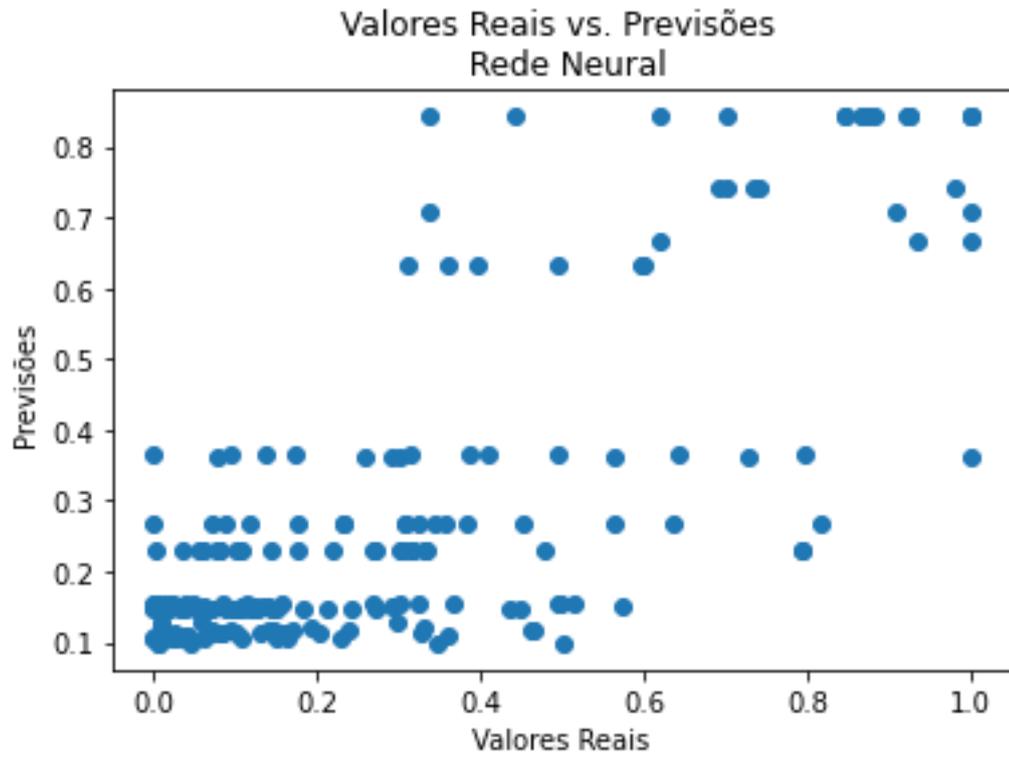


Figura 16. Teste 2.1 - Rede neural.

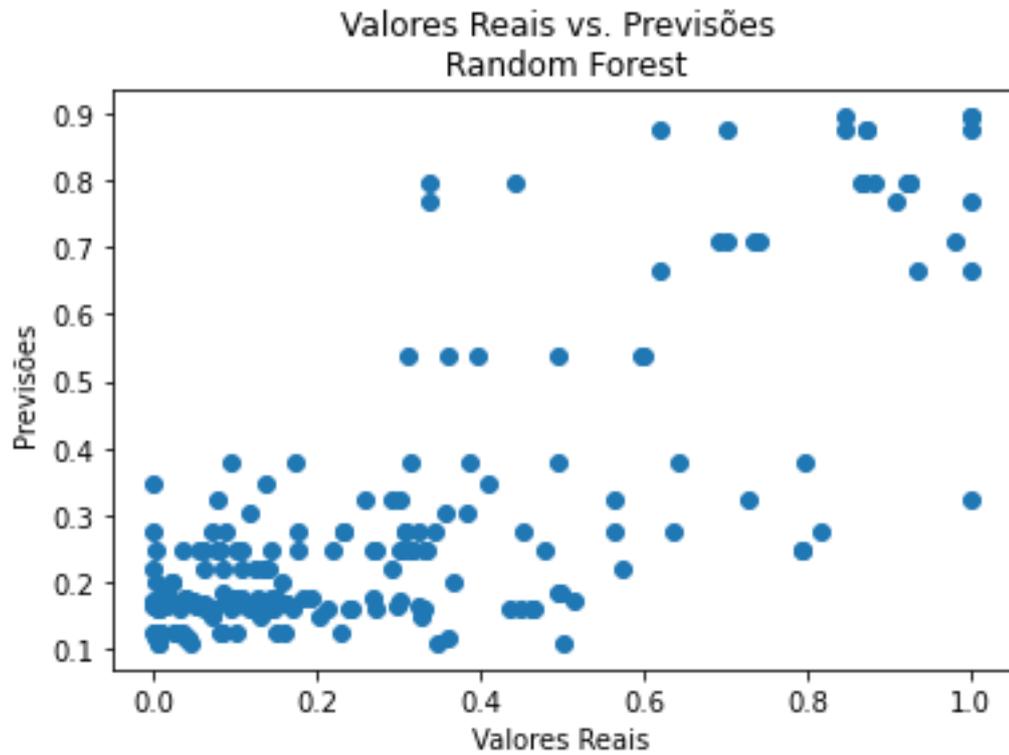


Figura 17. Teste 2.1 - Random Forest.

Tabela 9

Teste 2.1 - Resultados

	MSE	RMSE	MAE	R ²
REGRESSÃO LINEAR	0,0342	0,1849	0,1433	0,5949
REDE NEURAL RANDOM FOREST	0,0341	0,1846	0,1433	0,5962
	0,0331	0,1819	0,1405	0,6079

Quando analisado os Betas da regressão linear para dados exógenos, mostrados na Tabela 10, observa-se que o comércio de mercadorias exerce maior influência no modelo, seguido da importação de bens e serviços, assim como população total e dívida do governo central.

Tabela 10

Beta Regressão linear 2.1

VÁRIAVEL	PESO (BETA)
COMÉRCIO DE MERCADORIAS	0,8056
POPULAÇÃO TOTAL	0,1866
DESEMPREGO TOTAL	-0,1517
PIB PER CAPITA	0,3295
PRODUTO INTERNO BRUTO	-0,4133
IMPORTAÇÃO DE BENS E SERVIÇOS	0,3851
DÍVIDA DO GOVERNO CENTRAL	0,1837
IPCA	0,1627
INCC-M	-0,0999
CONSTRUÇÃO DE CASAS FINANCIADAS	0,0254
AQUISIÇÃO DE CASAS FINANCIADAS	0,0463
SELIC	

Para o Grupo 2, os pontos encontram-se mais dispersos em comparação com o Grupo 1, como pode-se observar nas Figuras 18, 19 e 20. Nesta etapa as saídas do modelo estão distantes de uma distribuição ideal em diagonal, o que seria desejável. Além disso, os erros também são consideravelmente altos, conforme visualizado na Tabela 11.

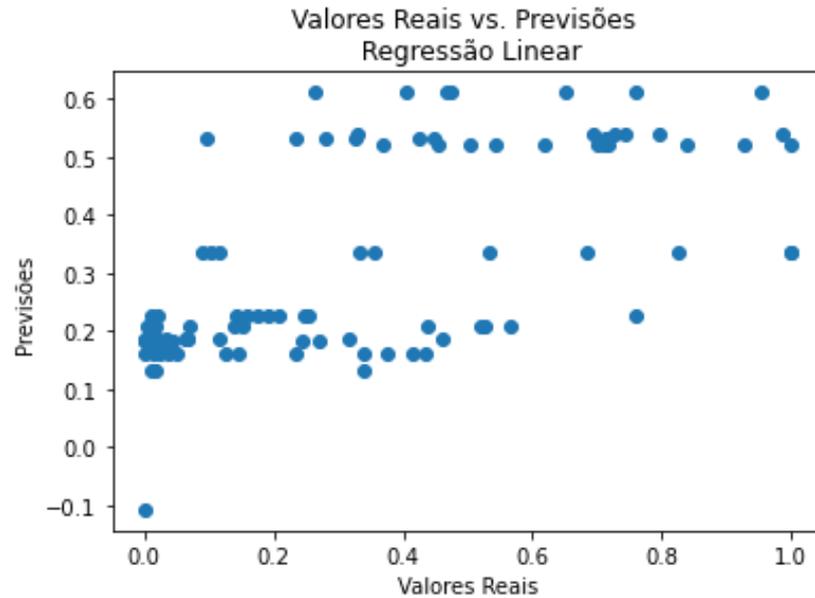


Figura 18. Teste 2.2 - Regressão Linear.

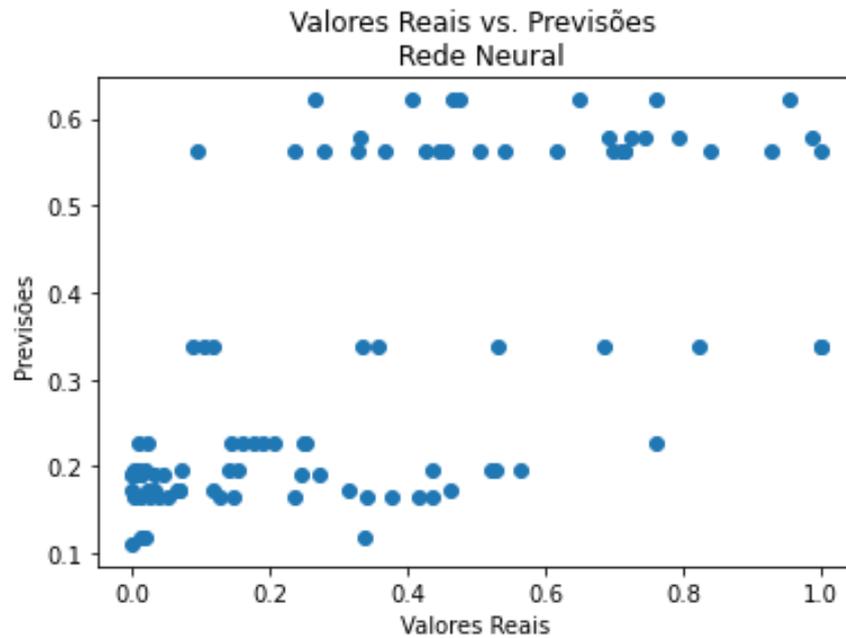


Figura 19. Teste 2.2 - Rede neural.

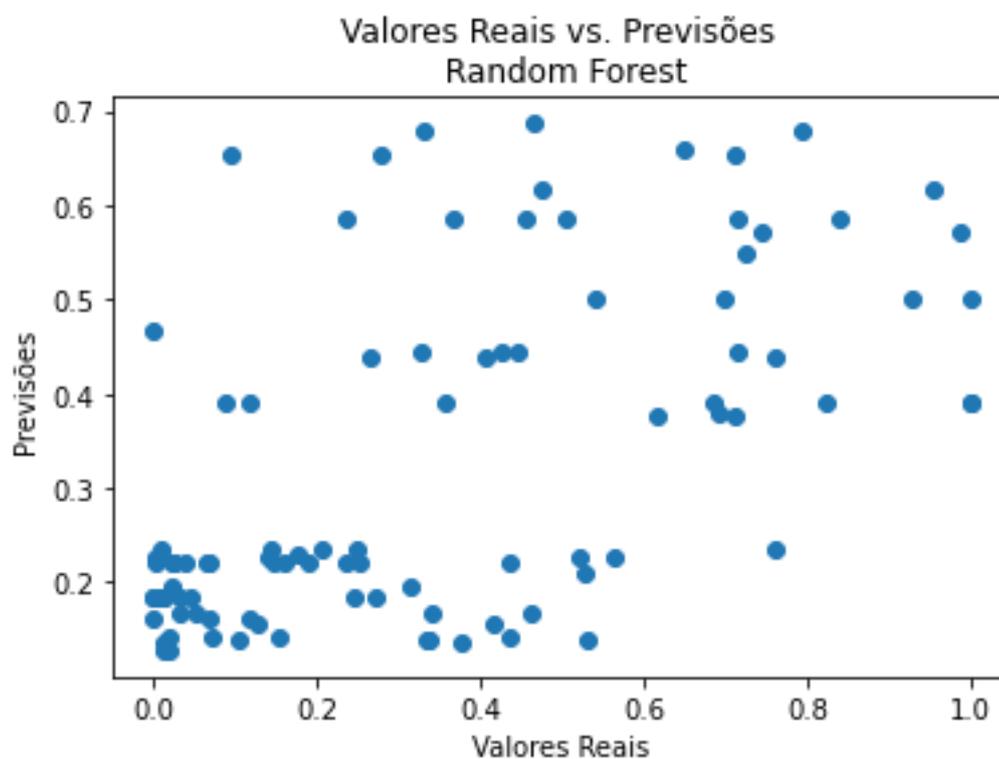


Figura 20. Teste 2.2 - Random Forest.

Tabela 11

Teste 2.2 - Resultados

	MSE	RMSE	MAE	R ²
REGRESSÃO				
LINEAR	0,0525	0,2291	0,1877	0,4144
REDE				
NEURAL	0,0535	0,2313	0,1933	0,4032
RANDOM				
FOREST	0,05800	0,2408	0,1965	0,3532

Como no Grupo 1, a importação de bens e consumo e o comércio de mercadorias possuem um peso maior no modelo. Contudo, o comércio atua de forma negativa, ou seja, inversamente proporcional ao faturamento das empresas. Tais variáveis são seguidas do PIB e da dívida do governo central, como é destacado na Tabela 12.

Tabela 12

Beta Regressão linear 2.2

VÁRIAVEL	PESO (BETA)
COMÉRCIO DE MERCADORIAS	-0,7350
POPULAÇÃO TOTAL	-0,2391
DESEMPREGO TOTAL	-0,1899
PRODUTO INTERNO BRUTO	0,5556
IMPORTAÇÃO DE BENS E SERVIÇOS	0,8520
DÍVIDA DO GOVERNO CENTRAL	0,4591
IPCA	0,2303
INCC-M	0,5614
CONSTRUÇÃO DE CASAS FINANCIADAS	-0,3735
AQUISIÇÃO DE CASAS FINANCIADAS	-0,2761
SELIC	-0,0119

Em um terceiro momento, buscou-se como entradas nos modelos, variáveis endógenas que mostram o porte da empresa, como Patrimônio Líquido. Além disso, foi considerado variáveis gerenciáveis pelos administradores, como Lucro Bruto e Lucro Líquido. Também foi incorporado variáveis econômicas e sociais de alta correlação, como População total, PIB per capita, Desemprego total, Importação de bens e serviços, Dívida do governo central.

Os resultados para o Grupo 1, mostrados nas Figuras 21, 22 e 23, encontram-se dispersos na diagonal, o que caracteriza um bom desempenho, tratando-se de variáveis relativas, usadas nas entradas do modelo, como lucro bruto e líquido. Os erros quadráticos médios encontram-se abaixo dos 3%, enquanto o desvio quadrático médio está abaixo de 17% e o erro médio absoluto é inferior a 13%. Nesse contexto, o algoritmo Forest Random se destacou como o que obteve o melhor desempenho, como observado na Tabela 13.

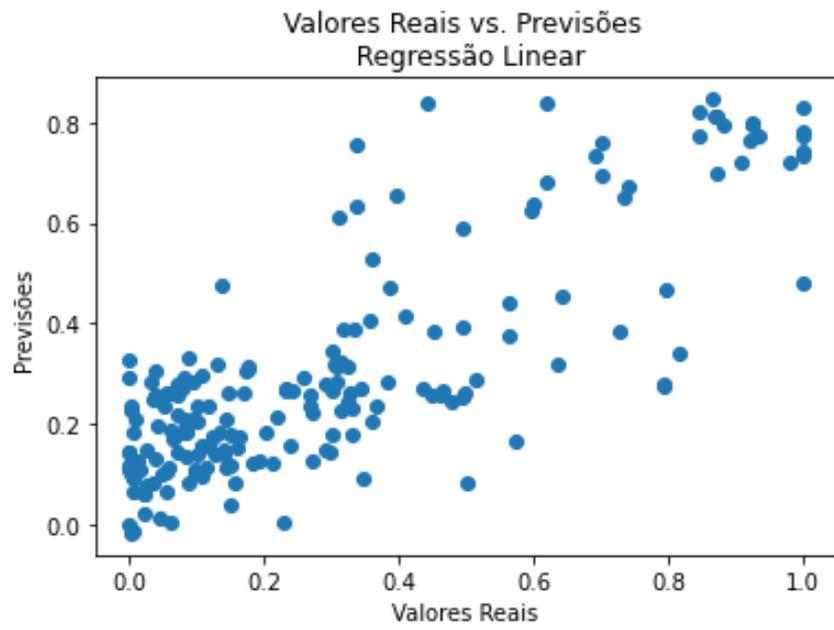


Figura 21. Teste 3.1 - Regressão Linear.

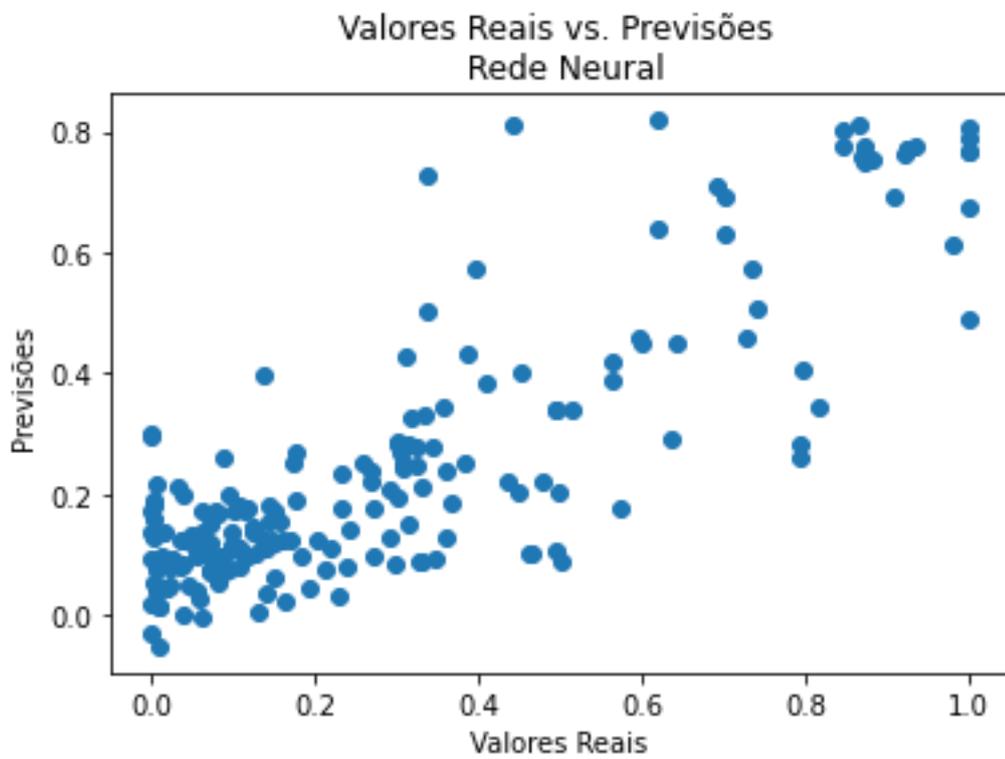


Figura 22. Teste 3.1 - Rede neural.

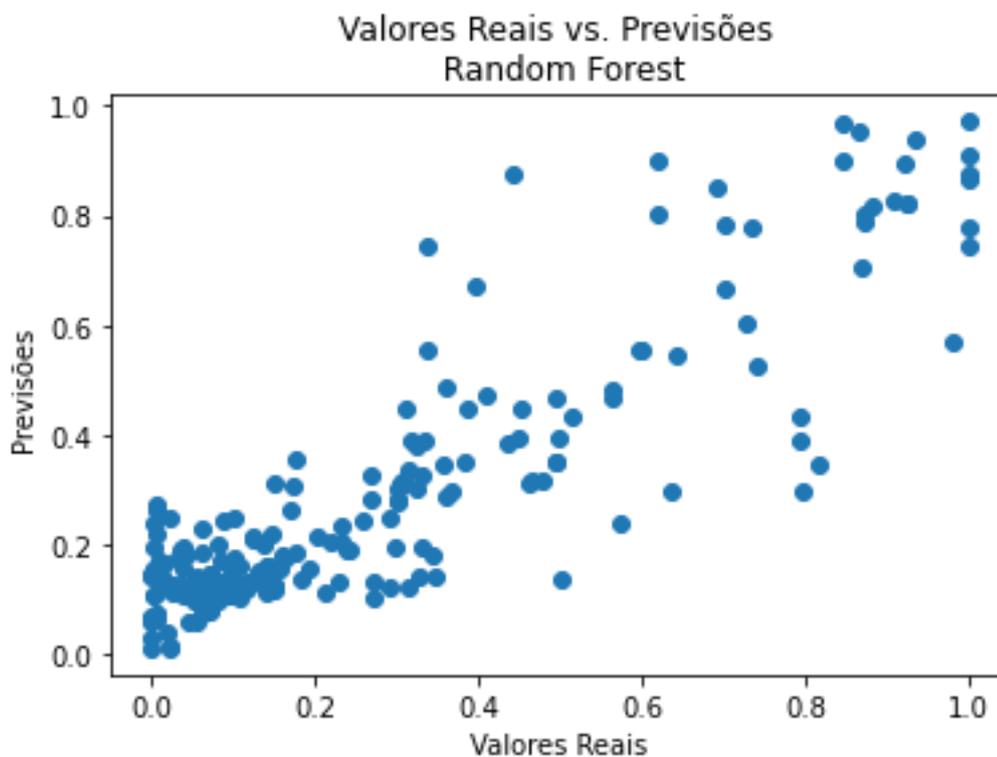


Figura 23. Teste 3.1 - Random Forest.

Tabela 13

Teste 3.1 - Resultados

	MSE	RMSE	MAE	R ²
REGRESSÃO				
LINEAR	0,0278	0,1670	0,1272	0,6698
REDE				
NEURAL	0,0265	0,1628	0,1175	0,6859
RANDOM				
FOREST	0,0190	0,1380	0,0984	0,7743

Ao empregar no modelo o lucro bruto e lucro líquido de forma percentual ao faturamento, as variáveis internas da empresa mostraram um peso pequeno quando analisado a regressão linear. Por outro lado, observou-se que as variáveis que mais exerceram influência foram a população total e a dívida do governo central, conforme evidenciado na Tabela 14.

Tabela 14

Beta Regressão linear 3.1

VÁRIAVEL	PESO (BETA)
PATRIMÔNIO LÍQUIDO	0,16114
LUCRO BRUTO	0,13534
LUCRO LÍQUIDO	0,00637
POPULAÇÃO TOTAL	0,57337
PIB PER CAPITA	0,06568
DESEMPREGO TOTAL	0,07373
IMPORTAÇÃO DE BENS E SERVIÇOS	0,27201
DÍVIDA DO GOVERNO CENTRAL	-0,34309

Os resultados para o Grupo 2, utilizando as mesmas variáveis de entradas do modelo anterior, foi um pouco abaixo quando comparado aos do Grupo 1. Como observado nas Figuras 24, 25 e 26 os dados encontram-se mais dispersos, o que sugere maior incerteza, como visto na Tabela 10.

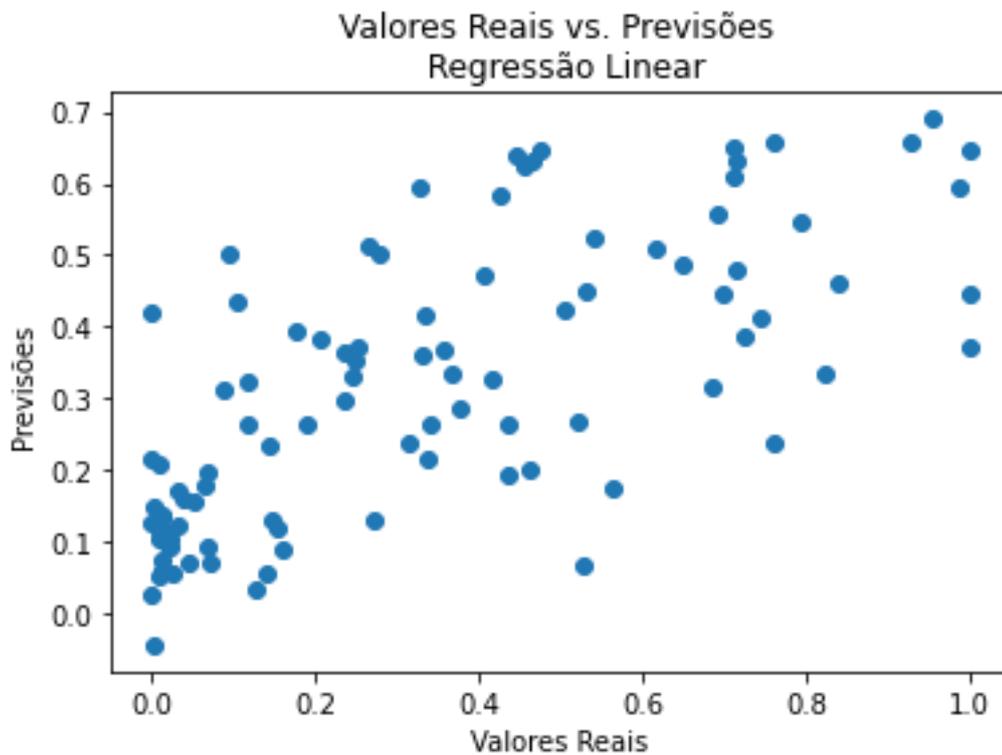


Figura 24. Teste 3.2 - Regressão Linear.

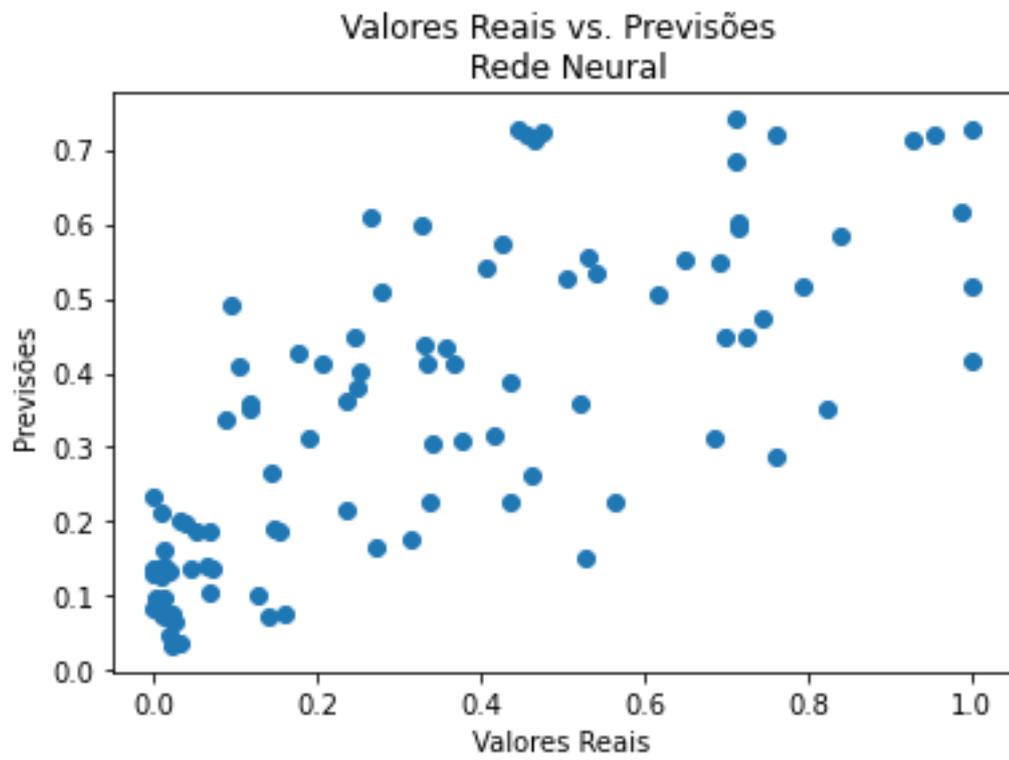


Figura 25. Teste 3.2 - Rede Neural.

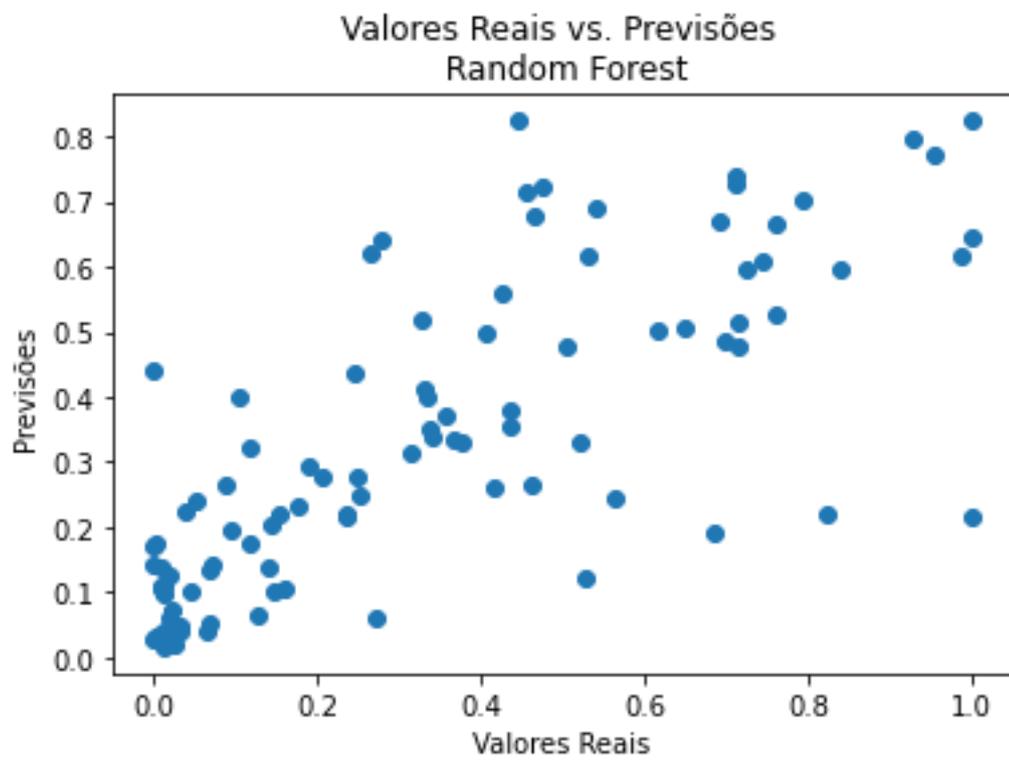


Figura 26. Teste 3.2 - Random Forest.

Tabela 15

Teste 3.2 - Resultados

	MSE	RMSE	MAE	R ²
REGRESSÃO				
LINEAR	0,0457	0,2139	0,1682	0,4895
REDE				
NEURAL	0,0407	0,2017	0,1625	0,5461
RANDOM				
FOREST	0,0380	0,1950	0,1379	0,5760

Por outro lado, ao analisar o beta da regressão linear do Grupo 2, notou-se que o lucro bruto desempenhou um papel significativo no modelo, porém ainda atrás da população total, que age de forma inversa no faturamento, como observado na Tabela 16

Tabela 16

Beta Regressão linear 3.2

VÁRIAVEL	PESO (BETA)
PATRIMÔNIO LÍQUIDO	0,13899
LUCRO BRUTO	0,30618
LUCRO LÍQUIDO	-0,01453
POPULAÇÃO TOTAL	-0,34791
PIB PER CAPITA	-0,11327
DESEMPREGO TOTAL	-0,15289
IMPORTAÇÃO DE BENS E SERVIÇOS	0,04158
DÍVIDA DO GOVERNO CENTRAL	-0,03623

Em todos os cenários avaliados, o modelo de Random Forest demonstrou resultados superiores. Notavelmente, o Grupo 1, composto principalmente por fornecedores B2B, bem como empresas envolvidas na exploração de imóveis e rodovias, exibiu uma previsibilidade significativamente maior em comparação com as empresas do Grupo 2.

Neste momento, o banco de dados foi reformulado, seguindo com os Grupos 1 e 2, porém normalizados todos juntos, em vez de considerar cada empresa individualmente. Foi mantida nos modelos como dados internos o patrimônio líquido, lucro bruto e lucro líquido,

contudo para variáveis externas foi considerado somente comércio de mercadorias e importação de bens e serviços.

No modelo de regressão linear, para o Grupo 1, que é mostrado o resultado na Figura 27, pode-se verificar que até o faturamento normalizado de 0,5, o modelo apresenta muito próximo da diagonal. O *outlier* observado nos gráficos, manteve-se presente, pois ao retirar, teve um aumento nos erros dos modelos. Já os betas, mostrados na Tabela 17, fica evidente que o patrimônio líquido das empresas se destaca como um fator de grande influência. Isso indica que, no setor em questão, a saúde financeira e a solidez influenciam no faturamento.

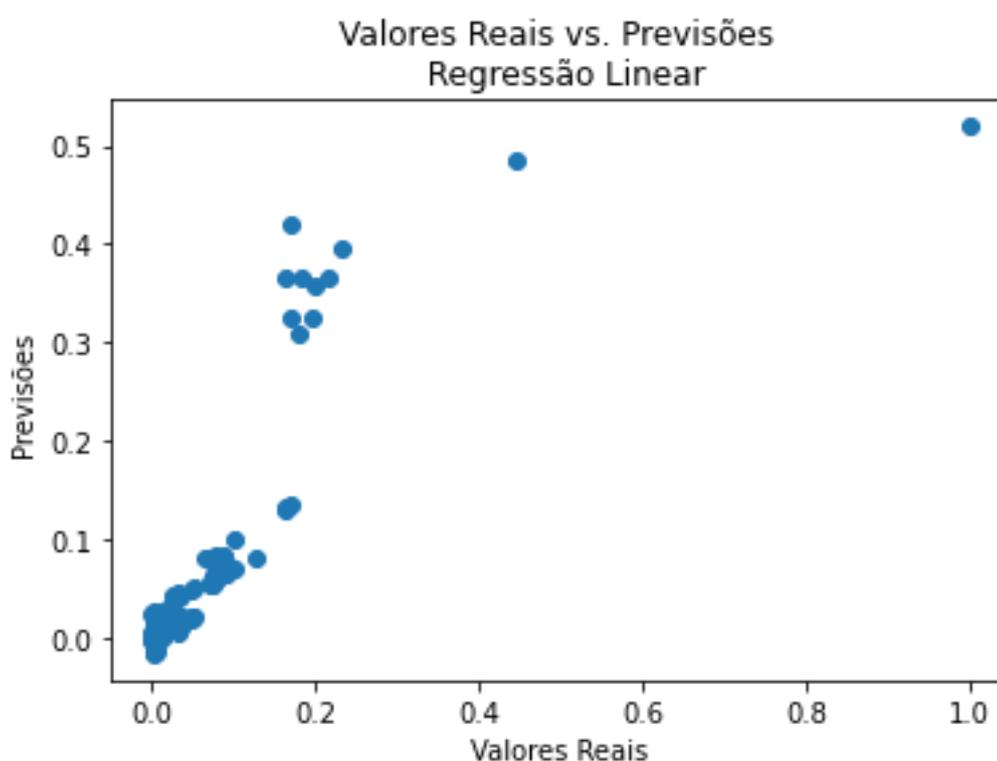


Figura 27. Teste 4.1 - Regressão Linear.

Tabela 17

Beta Regressão linear 4.1

VÁRIAVEL	PESO (BETA)
PATRIMÔNIO LÍQUIDO	0,5077
LUCRO BRUTO	-0,0429
LUCRO LÍQUIDO	0,0581
COMÉRCIO DE MERCADORIAS	0,0195
IMPORTAÇÃO DE BENS E SERVIÇOS	0,0019

Os modelos de rede neural e Random Forest, quando comparados com modelos anteriores de previsão para o Grupo 1, obteve resultados superiores, como pode ser observado na Figura 28 e 29 onde os dados reais ficam bem próximos aos previstos. Além disso, ao avaliar o aprimoramento dos dados de saída do modelo, na Tabela 18, pode-se observar que os erros ficaram muito próximos de 0 e o R^2 bem próximo a 1. Especial destaque é para o modelo Random Forest, que alcançou um valor de R^2 de 0,9032, evidenciando sua capacidade de realizar previsões com alta precisão.

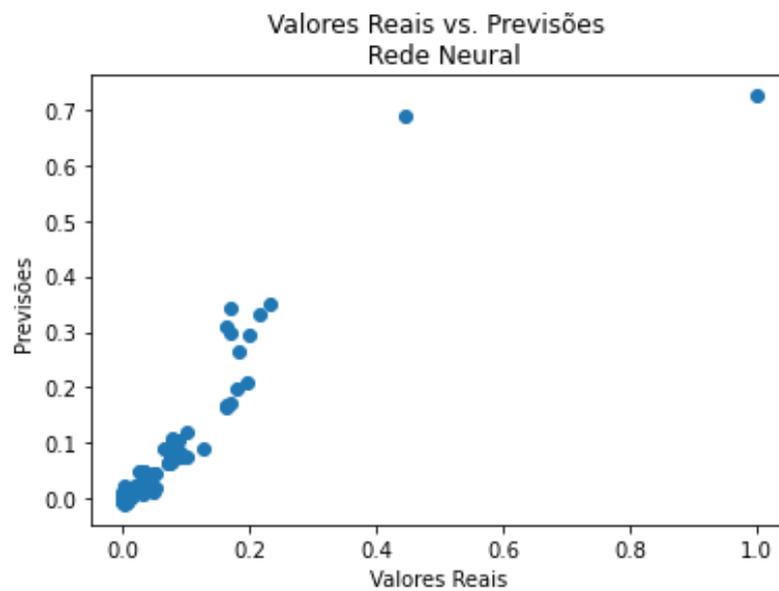


Figura 28. Teste 4.1 - Rede Neural.

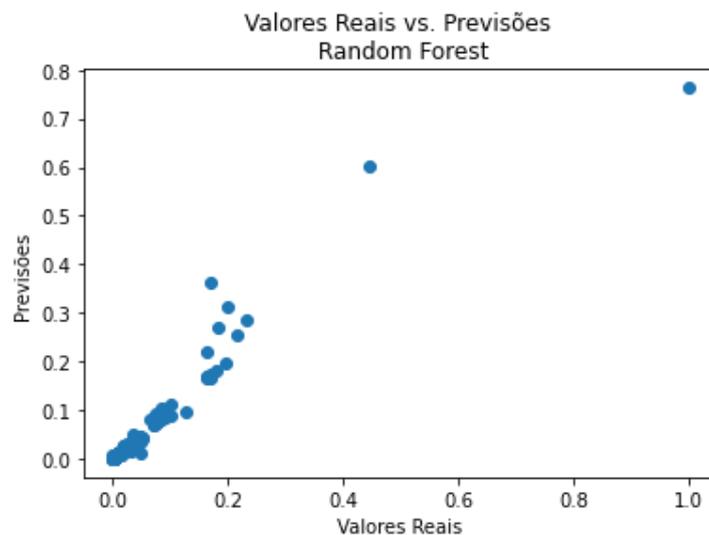


Figura 29. Teste 4.1 – Random Forest.

Tabela 18

Teste 4.1 - Resultados

	MSE	RMSE	MAE	R ²
REGRESSÃO				
LINEAR	0,0027	0,05216	0,01894	0,6603
REDE				
NEURAL	0,00136	0,03696	0,01294	0,8294
RANDOM				
FOREST	0,00077	0,02783	0,007025	0,9032

Observando a Figura 30 e 31, representando o gráfico para SHAP Value para rede neural e Random Forest, respectivamente, temos que, para ambos os modelos, o patrimônio líquido das empresas é uma característica importante para prever faturamento e com valores maiores aumenta a precisão. Os dados externos de Importação de bens e serviços, assim como, lucro bruto, tem impactos, porém menores quando comparados com o Patrimônio Líquido. Já O Lucro Líquido e o comércio de mercadorias têm impacto muito pequeno na maioria dos casos.

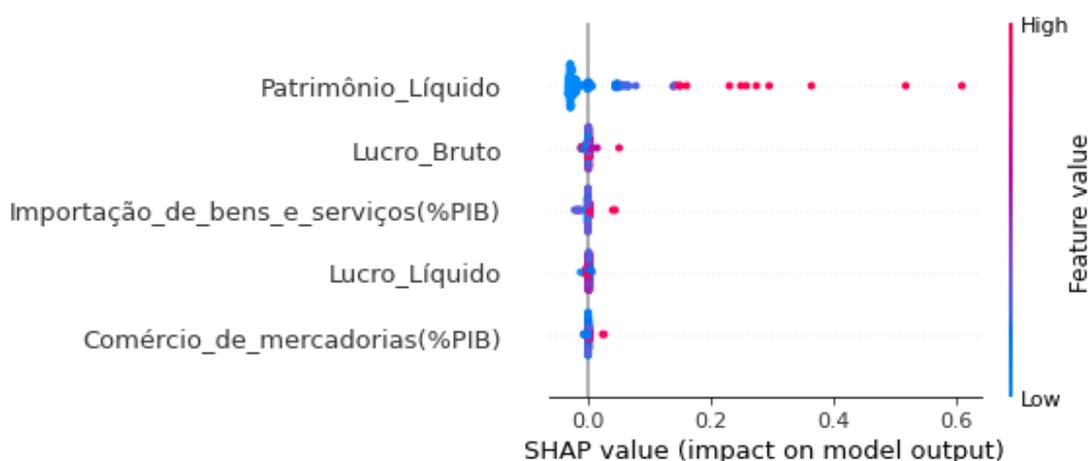


Figura 30: SHAP, Rede Neural Teste 4.1

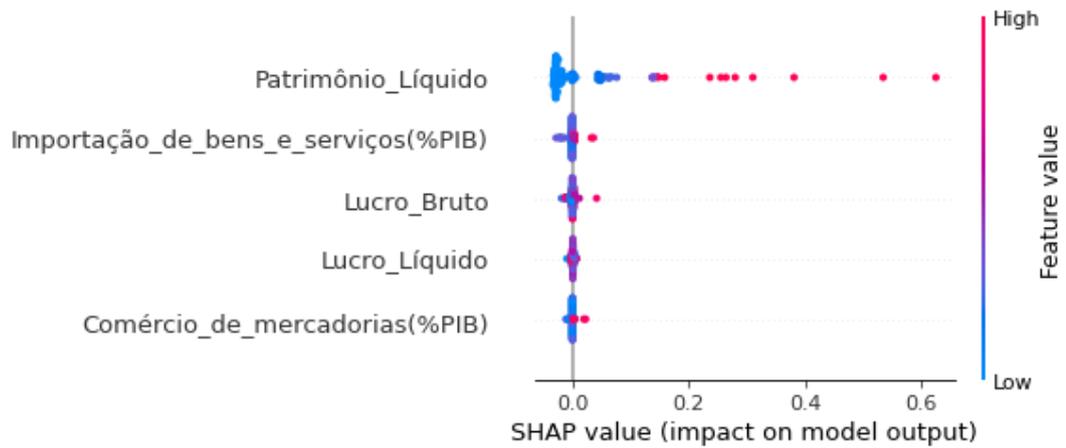


Figura 31: SHAP, Random Forest Teste 4.1

Para o modelo de Regressão aplicado aos dados do Grupo 2, destacado na Figura 32, observa-se um comportamento que não havia aparecido nos métodos anteriormente, que é o aparecimento de faturamento negativo. Nos Betas, observados na Tabela 19, ainda fica evidenciado a importância do Patrimônio líquido nesta etapa dos treinos, mostrando também a relevância do comércio de mercadorias e da importação de bens e serviços

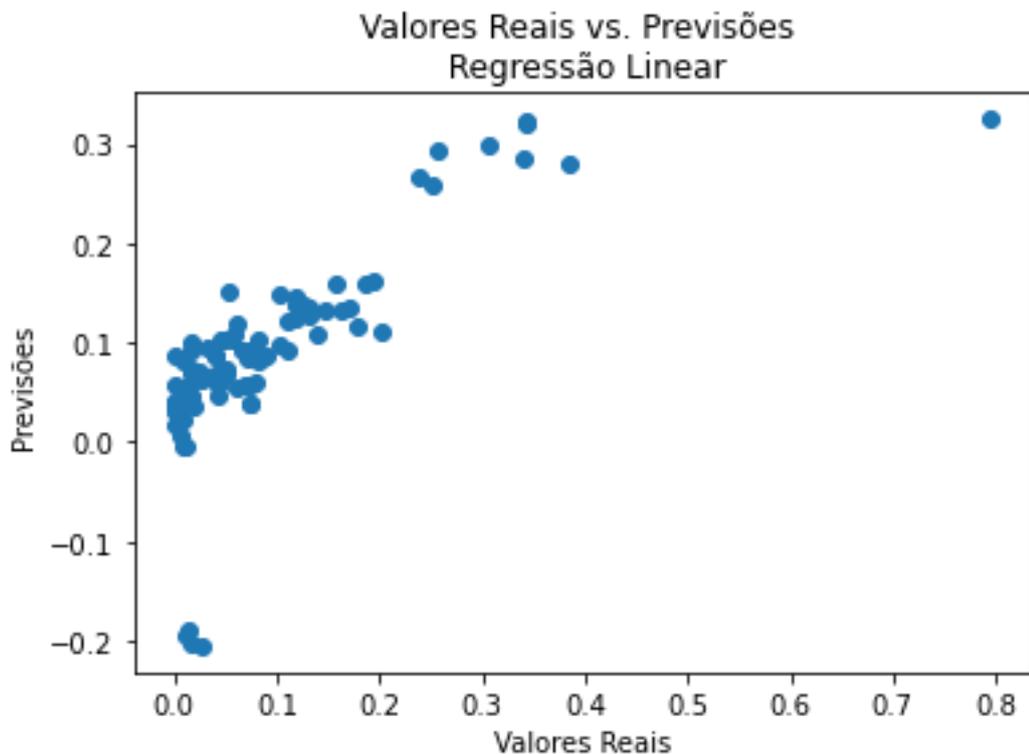


Figura 32. Teste 4.2 - Regressão Linear.

Tabela 19

Beta Regressão linear 4.2

VÁRIAVEL	PESO (BETA)
PATRIMÔNIO LÍQUIDO	0,5480
LUCRO BRUTO	0,0182
LUCRO LÍQUIDO	-0,1786
COMÉRCIO DE MERCADORIAS	-0,2511
IMPORTAÇÃO DE BENS E SERVIÇOS	0,2570

Como nos resultados anteriores, os modelos de rede neural e Random Forest apresentaram valores de previsões muito próximos aos reais, como pode-se observar nas Figuras 33 e 34. Os erros permaneceram baixos e o modelo de Random Forest apresentou um R^2 de 0,9366, como mostrado na Tabela 21.

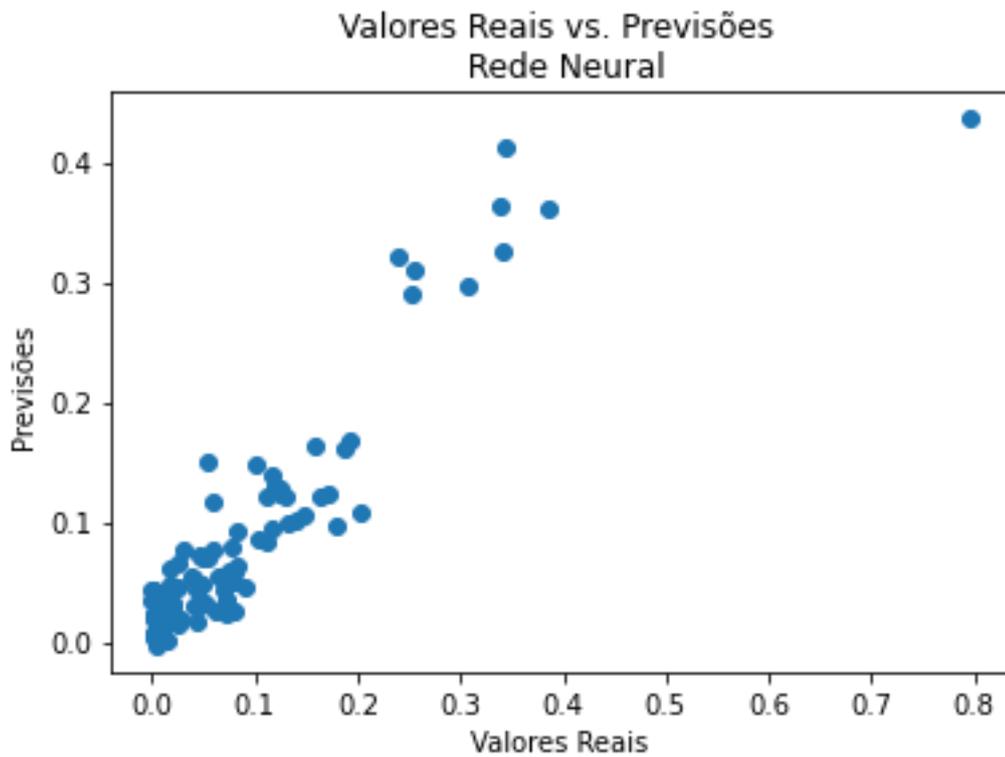


Figura 33. Teste 4.2 – Rede Neural.

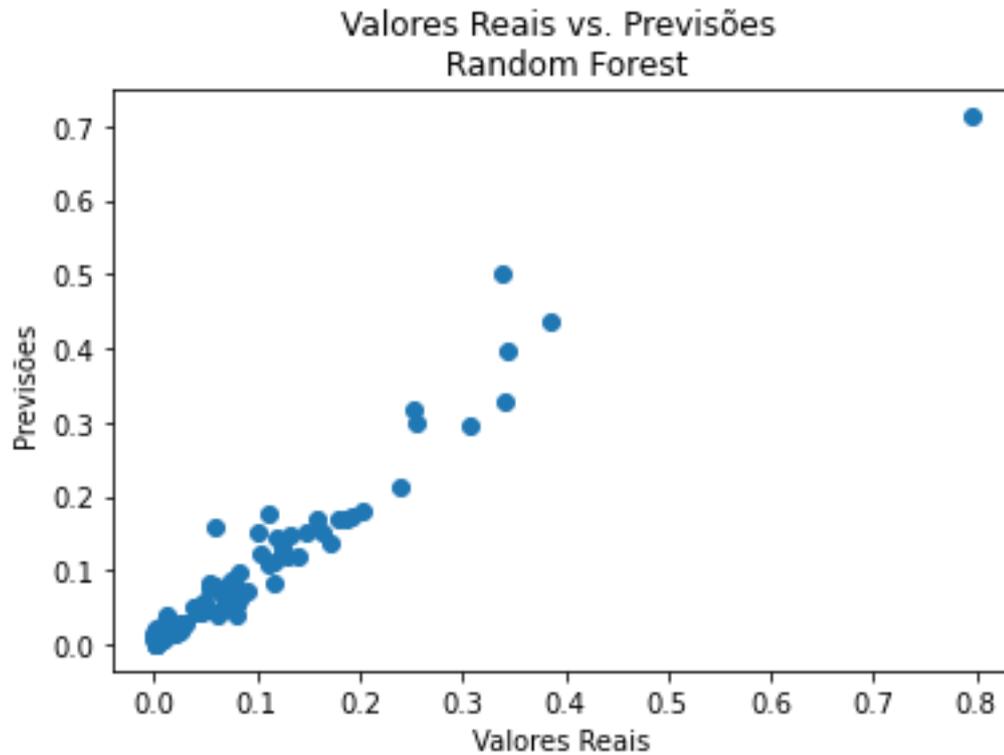


Figura 34. Teste 4.2 – Random Forest

Tabela 20

Teste 4.2 - Resultados

	MSE	RMSE	MAE	R ²
REGRESSÃO				
LINEAR	0,00567	0,0753	0,04424	0,5533
REDE				
NEURAL	0,00231	0,0481	0,02729	0,8176
RANDOM				
FOREST	0,00080	0,02838	0,01628	0,9366

As Figuras 35 e 36 apresentam o método SHAP para a rede neural e *Random Forest*, respectivamente. Esses gráficos sugerem que para ambos os casos, o patrimônio líquido apresenta ligações fortes com a variável dependente, especialmente em valores mais altos. Para a importação de bens e serviços, lucro bruto e lucro líquido, os coeficientes estão majoritariamente próximos a zero, sugerindo que essas variáveis podem não ter uma relação

forte com a variável dependente. O comércio de mercadorias mostra uma dispersão em torno de zero, mas com alguns coeficientes positivos, indicando que pode haver uma relação positiva em alguns casos.

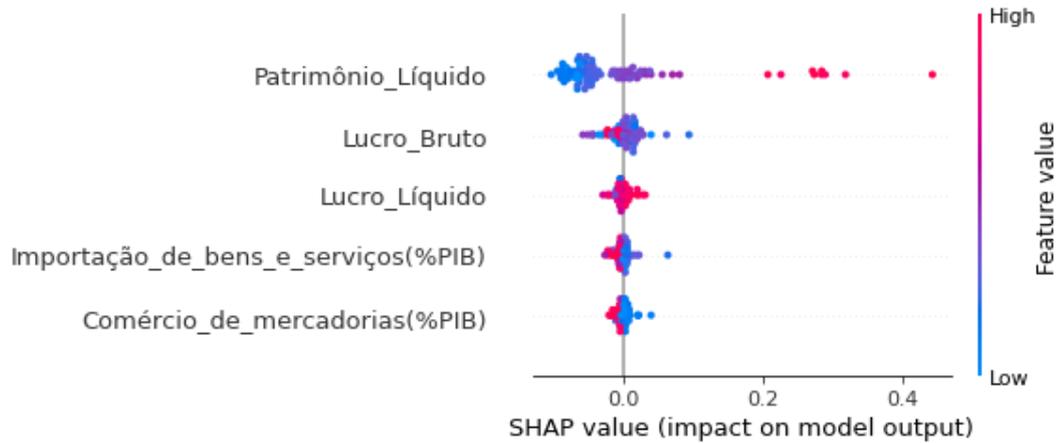


Figura 35: SHAP, Rede Neural Teste 4.2

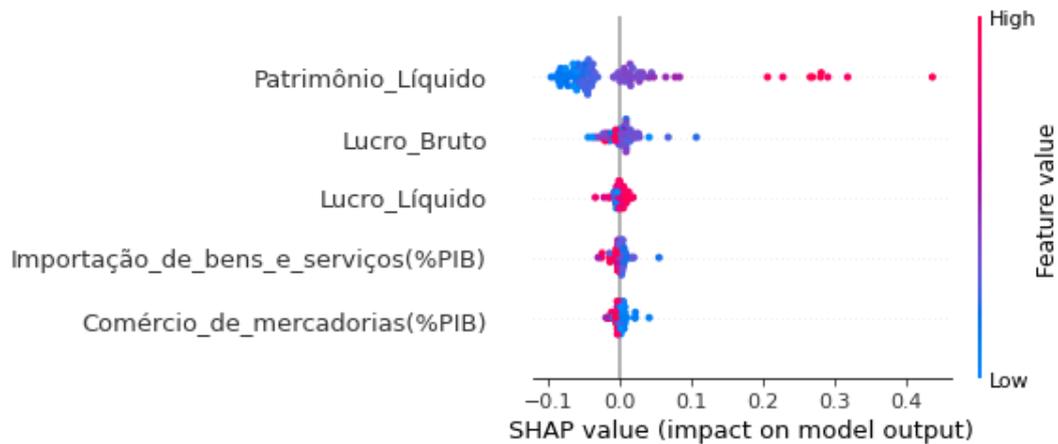


Figura 36: SHAP, Random Forest Teste 4.2

8. CONCLUSÃO

A indústria da construção civil é caracterizada por uma cadeia extensa, o que resulta em empresas que podem exibir comportamentos diversos quando expostas a indicadores socioeconômicos. Neste estudo, identificaram-se dois comportamentos distintos, categorizados como Grupo 1 e Grupo 2. No Grupo 1, estão empresas responsáveis pela produção de matérias-primas, fabricação de equipamentos e exploração de imóveis e rodovias. Por outro lado, o Grupo 2 é composto, em sua maioria, por incorporadoras e construtoras.

O banco de dados foi normalizado primeiramente de forma individual para cada empresa e posteriormente com todo o conjunto de dados juntos, percebeu-se com isso o peso do Patrimônio líquido para empresas ligadas a construção civil, sendo que para o segundo caso os resultados foram mais assertivos.

A taxa SELIC e a Inflação (IPCA) são indicadores macroeconômicos importantes, porém, possuem pouca relação direta com o faturamento das empresas da construção civil nos modelos observados. No contexto das empresas do Grupo 1, variáveis como comércio de mercadorias, importações de bens e serviços, e financiamento de residências tendem a ter maior influência na explicação do faturamento. Por outro lado, o Grupo 2 direciona sua atenção para fatores mais ligados aos clientes, tais como taxa de desemprego, PIB per capita, além da dívida do governo central.

Como esperado, técnicas avançadas de previsão demonstraram uma precisão superior ao buscar prever o faturamento das empresas da construção civil. Esse resultado ressalta a importância crucial de adotar métodos de *machine learning* para antecipar o comportamento das empresas desse setor.

O estudo revelou uma série de indicadores cruciais para os gestores empresariais, proporcionando-lhes uma visão privilegiada para antecipar os movimentos do mercado. Esses insights são fundamentais na formulação de estratégias voltadas para a maximização de lucros e a minimização de perdas, especialmente durante períodos de recessão econômica. Além disso, destacou-se dois comportamentos entre as empresas do setor da construção civil. Essa variação oferece oportunidades de investimento pontual, permitindo que os gestores identifiquem e direcionem recursos para empresas onde o mercado está mais favorável, consolidando, assim, uma abordagem mais eficaz e personalizada para o sucesso nos negócios.

Para o meio acadêmico o estudo trouxe a integração de dados interno de empresas com dados exógenos para a previsão do faturamento. Além disso, explorou-se o emprego de modelos estatísticos avançados, como regressão linear, redes neurais e Random Forest, para a análise e predição dos dados. Essa combinação de métodos permitiu uma compreensão mais profunda e abrangente dos fatores que influenciam o desempenho financeiro das organizações, proporcionando insights valiosos para a pesquisa e prática em áreas como economia, gestão empresarial e ciência de dados.

Algumas limitações foram observadas durante a condução do estudo. Primeiramente, a inclusão de variáveis endógenas e exógenas apresentou desafios, pois as variáveis internas têm grande influência no faturamento das empresas e, conseqüentemente, um peso elevado no

modelo em comparação com as variáveis externas. Além disso, o tamanho da amostra foi uma limitação, já que o estudo utilizou apenas empresas listadas na bolsa de valores, que podem não representar adequadamente a realidade das pequenas empresas do setor. Por fim, a heterogeneidade das empresas analisadas também foi um fator limitante, pois, apesar do foco em empresas do segmento de construção civil, muitas dessas empresas têm atividades relevantes em outros segmentos, o que pode influenciar os resultados.

Em estudos subsequentes, é possível explorar outras abordagens de previsão para comparar os resultados alcançados. Além disso, pode-se analisar o comportamento dos indicadores ao longo do tempo, buscando determinar se o impacto sobre o faturamento é imediato ou se manifesta em períodos futuros.

REFERÊNCIAS

- Ackermann, A., & Sellitto, M. (2022). Métodos de previsão de demanda: uma revisão da literatura. *Innovar*, 32(85). doi:<https://doi.org/10.15446/innovar.v32n85.100979>
- Akintoye, A., & Skitmore, M. (1994). Models of UK private sector quarterly construction demand. *Construction Management and Economics*, 12(1), pp. 3-13. doi:<http://dx.doi.org/10.1080/01446199400000002>
- Armstrong, J., & Graefe, A. (2011). Predicting elections from biographical information about candidates: A test of the index method. *Journal of Business Research*, 7, pp. 699-706. doi:<https://doi.org/10.1016/j.jbusres.2010.08.005>
- Armstrong, J., & Green, K. (2011). *Armstrong, Jon Scott, and Kesten C. Green. Demand forecasting: evidence-based methods*. Monash University, Department of Econometrics and Business Statistics.
- Brito, E., Brito, L., & Morganti, F. (2009). Inovação e o desempenho empresarial: lucro ou crescimento? *RAE Eletrônica*, 8(1). doi:<https://doi.org/10.1590/S1676-56482009000100007>
- Câmara Brasileira da indústria de Construção . (28 de agosto de 2023). *Dados CBIC*. Fonte: CBIC: <http://www.cbicdados.com.br/home/>
- Chase , C. (2016). *Next generation demand management: people, process, analytics, and technology*. Hoboken: Wiley.
- Deb, C., Zhang, F., Yang, J., & Lee, S. (2017). A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, pp. 902-924. doi:<https://doi.org/10.1016/j.rser.2017.02.085>
- Devenport, T. (2013). Analytics 3.0. *Harvard business review*, 64-72.
- Dharshini, P. A., & Vijila, S. (2021). Comparative Study of Product Sales Forecasting Methods. *International Research Journal on Advanced Science Hub (IRJASH)*, 117-124.
- Dharshini, P., & Vijila, A. (2021). Comparative Study of Product Sales Forecasting Methods. *International Research Journal on Advanced Science Hub*, 3(Special Issue 7S), pp. 117-124. doi:<https://doi.org/10.47392/irjash.2021.220>
- Eglite, L., & Birzniece, I. (2022). Retail Sales Forecasting Using Deep Learning: Systematic Literature Review. *Complex Systems Informatics and Modeling Quarterly (CSIMQ)*, 53-62.
- Esper, T., Elinger, A., Stank, T., Flint, D., & Moon, M. (2009). Demand and supply integration: a conceptual framework of value creation through knowledge management. *Journal of the Academy of Marketing Science*, 38(1), pp. 5-18. doi:<https://doi.org/10.1007/s11747-009-0135-3>

- Goh, B. (1996). Residential construction demand forecasting using economic indicators: a comparative study of artificial neural networks and multiple regression. *Construction Management and Economics*, 14(1), pp. 25-34. doi:<http://dx.doi.org/10.1080/01446199600000004>
- Goh, B. (1998). Forecasting residential construction demand in Singapore: a comparative study of the accuracy of. *Engineering, Construction and Architectural Management*, 5(3), pp. 261-275. doi:<https://doi.org/10.1108/eb021080>
- Harrison, P. J., & Stevens, C. F. (1976). Bayesian Forecasting. *Journal of the Royal Statistical Society: Series B (Methodological)*, pp. 205-228. doi:<https://doi.org/10.1111/j.2517-6161.1976.tb01586.x>
- Haslindah, A., Hamdat, A., Mora, & Hanafiah, H. (2021). Implementation Of Marketing Strategies In Increasing Sales Volume. *International Journal of Science, Technology & Management*, 5, pp. 1449-1459. doi:<https://doi.org/10.46729/ijstm.v2i5.299>
- Instituto Brasileiro de Geografia e Estatística [IBGE]. (2020). Pesquisa Anual da Indústria da Construção. Rio de Janeiro, RJ, Brasil. Fonte: <https://www.ibge.gov.br/estatisticas/economicas/industria/9018-pesquisa-anual-da-industria-da-construcao.html?edicao=34074&t=destaques>
- Kahneman, D., & Tversky, A. (1977). Intuitive prediction: Biases and corrective procedures. *Decisions and Designs Inc Mclean Va*.
- Kim, K., Cho, J., & Kim, S. (2021). Model-Based Dynamic Forecasting for Residential Construction Market Demand: A Systemic Approach. *Applied Sciences*, 11(8). doi:<https://doi.org/10.3390/app11083681>
- Kim, S., & Kim, H. (2016). A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, 3, pp. 669-679. doi:<https://doi.org/10.1016/j.ijforecast.2015.12.003>
- Mach, L., Zmarzly, D., Dabrowski, I., & Fracz, P. (2020). Comparison on Subannual Seasonality of Building Construction in European Countries. *EUROPEAN RESEARCH STUDIES JOURNAL*, 23(4), pp. 241-257. doi:<https://doi.org/10.35808/ersj/1682>
- Ramos, A., & Zilber, S. (2015). O impacto do investimento na capacidade inovadora da empresa. *RAI Revista de Administração E Inovação*, 12(1), pp. 303-325. doi:<https://doi.org/10.11606/rai.v12i1.100326>
- Raza, M., & Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, 50, pp. 1352-1372. doi:<https://doi.org/10.1016/j.rser.2015.04.065>
- Shrestha, Y. R., Krishna, V., & von Krogh, G. (2021). Augmenting organizational decision-making with deep learning algorithms: Principles, promises, and challenges. *Journal of Business Research*, 588-603.

- Singh, D., & Singh, B. (2019). , Investigating the impact of data normalization on classification performance . *Applied Soft Computing*. doi:<https://doi.org/10.1016/j.asoc.2019.105524>
- Souza, L., Mendes, A., Silva, M., & Rodrigues, O. (2018). A INFLUÊNCIA DOS INVESTIMENTOS EM PESQUISA E DESENVOLVIMENTO (P&D) E EM CAPEX NAS VENDAS E NO LUCRO DAS EMPRESAS. *Congresso Internacional de Administração* . Sucre.
- Vadakkepatt, G., Shankar, V., & Varadarajan, R. (2021). Should firms invest more in marketing or R&D to maintain sales leadership? An empirical analysis of sales leader firms. *Journal of the Academy of Marketing Science*. doi:<https://doi.org/10.1007/s11747-021-00774-2>
- Wenzel, H., Smit, D., & Sardesai, S. (2019). A literature review on machine learning in supply chain management. *Encostor*, 413-441.
- World Bank Group. (29 de agosto de 2023). Fonte: Banco Mundial: <https://data.worldbank.org/country/brazil?locale=pt>
- Zhang, G., Eddy Patuwo, B., & Y. Hu, M. (1998). Forecasting with artificial neural networks. *International Journal of Forecasting*, 14(1), pp. 36-62. doi:[https://doi.org/10.1016/s0169-2070\(97\)00044-7](https://doi.org/10.1016/s0169-2070(97)00044-7)

APÊNDICE 2 – Dados estatísticos descritivos Grupo 1

VARIÁVEL	OBSERVAÇÕES	MÉDIA	DESVIO PADÃO	MÍNIMO	25%	50%	75%	MÁXIMO
ATIVO TOTAL	968,00	30822,82	75698,51	195,38	2147,93	5971,96	25992,39	499128,00
ATIVO CIRCULANTE	968,00	8363,27	16353,97	80,22	707,04	1753,11	8825,12	132024,16
DISPONIBILIDADES	968,00	2983,98	7192,50	6,89	244,18	825,23	2866,34	73398,53
ESTOQUES	968,00	2723,52	4611,01	0,00	38,41	462,00	3596,26	28480,00
ATIVO NÃO CIRCULANTE	968,00	22459,55	60200,11	72,62	1118,24	4473,47	17986,79	374327,00
REALIZÁVEL A LONGO PRAZO	968,00	3895,11	10963,75	3,44	204,84	576,37	4102,96	89113,08
INVESTIMENTO	968,00	1836,21	3043,93	-0,03	1,04	384,94	2616,04	16601,31
IMOBILIZADO	968,00	12885,18	41503,19	0,38	80,60	562,62	3756,03	245736,63
INTANGÍVEL	968,00	3843,05	7792,72	0,00	5,15	114,37	3973,87	55009,56
PASSIVO TOTAL	968,00	30822,82	75698,51	195,38	2147,93	5971,96	25992,39	499128,00
PASSIVO CIRCULANTE	968,00	4554,66	10090,86	13,97	374,41	823,10	4774,68	87442,21
EMPRÉSTIMOS E FINANCIAMENTOS	968,00	1216,08	1799,83	0,00	122,11	324,54	1647,13	12037,01

FORNECEDORES	968,00	1374,92	3209,16	0,00	37,89	127,14	840,65	25600,00
OBRIGAÇÕES								
FISCAIS	968,00	343,12	1070,63	0,00	13,10	41,80	192,02	15905,84
PASSIVO NÃO								
CIRCULANTE	968,00	12575,79	32536,13	6,76	530,07	2220,22	8544,33	226287,84
EMPRÉSTIMOS E								
FINANCIAMENTOS²	968,00	7562,34	15805,71	0,00	308,93	1573,51	6009,75	102878,30
FORNECEDORES²	968,00	4,81	27,25	0,00	0,00	0,00	0,00	543,53
PATRIMÔNIO								
LÍQUIDO	968,00	13692,37	34375,17	56,18	1167,26	2806,87	8093,91	211926,53
CAPITAL SOCIAL								
REALIZADO	968,00	6720,55	15982,85	40,80	526,59	1351,53	4610,86	77300,00
RESERVA DE								
LUCROS	968,00	2992,83	9831,68	-2930,99	132,50	517,73	1587,32	108214,00
FATURAMENTO	968,00	16805,52	44860,38	0,00	760,28	2341,08	10856,93	509045,75
(-)CUSTO	968,00	10880,99	23468,98	-310,00	443,54	1299,99	8348,29	194522,57
LUCRO BRUTO								
VALOR	968,00	5924,53	23263,15	-325,11	291,17	1008,89	3263,08	314523,18
LUCRO BRUTO	968,00	0,36	0,21	-0,77	0,23	0,32	0,47	1,28
(-)DESPESAS								
OPERACIONAIS	968,00	2262,82	8517,26	-1267,87	76,14	354,75	1131,83	88110,42

LUCRO OPERACIONAL(EBIT) VALOR	968,00	3665,33	17577,86	-27445,36	144,40	446,27	1458,84	247851,98
LUCRO OPERACIONAL(EBIT)	968,00	0,24	0,32	-1,70	0,08	0,15	0,32	2,05
(+)RECEITA FINANCEIRA	968,00	611,72	2741,94	-708,97	21,54	70,68	250,41	39898,96
(-)DESPESA FINANCEIRA	968,00	1581,35	6231,60	-28026,10	31,06	147,74	785,80	66444,05
LUCRO APÓS EFEITO FINANCEIRO	968,00	2526,04	17600,42	-63369,12	15,01	205,08	798,76	245023,26
(+)RES EQUIVALÊNCIA PATRIMONIAL	968,00	-34,59	837,27	-10690,46	0,00	0,00	10,23	1846,85
RESULTADO ANTES DO IRECSLL	968,00	2599,32	17189,11	-64875,57	68,23	292,16	918,35	238143,19
(-)TRIBUTOS SOBRE O LUCRO	968,00	620,21	4321,86	-20389,41	10,08	50,00	187,27	60831,29
LUCRO LÍQUIDO VALOR	968,00	1979,11	13464,31	-45996,62	42,61	221,79	765,64	177311,91
LUCRO LÍQUIDO	968,00	0,13	0,24	-1,81	0,03	0,10	0,17	1,62

VARIAÇÃO DO CAIXA	968,00	-88,48	3949,53	-48626,44	-135,39	1,37	205,82	36712,92
(+)FLUXO CAIXA DAS OPERAÇÕES	968,00	4064,88	17300,25	-1008,42	90,52	377,25	1935,68	244031,19
(+)FLUXO CAIXA DOS INVESTIMENTOS	968,00	-1987,21	7071,10	-79163,81	-1050,16	-262,60	-30,82	2926,65
(+)FLUXO CAIXA DOS FINANCIAMENTOS	968,00	-2166,18	13085,26	-178593,14	-743,30	-88,38	60,60	10528,60
COMÉRCIO DE MERCADORIAS (%PIB)	968,00	22,56	4,87	18,09	18,80	20,38	25,44	32,62
POPULAÇÃO TOTAL DESEMPREGO TOTAL (% DA FORÇA DE TRABALHO TOTAL)	968,00	208227033	4982508,01	199977707	203459650	208504960	213196304	215313498
PIB PER CAPITA (US\$)	968,00	0,11	0,03	0,07	0,07	0,12	0,13	0,14
PIB(US\$)	968,00	9592,97	1765,83	6923,70	8680,74	8917,67	12071,40	12327,52
	968,00	1,9901E+12	3,2468E+11	1,4761E+12	1,7957E+12	1,9169E+12	2,456E+12	2,4728E+12

IMPORTAÇÃO DE BENS E SERVIÇOS (%PIB)	968,00	0,15	0,02	0,12	0,13	0,14	0,16	0,19
DÍVIDA DO GOVERNO CENTRAL (%PIB)	968,00	0,77	0,14	0,57	0,60	0,82	0,87	0,99
IPCA	968,00	0,06	0,02	0,03	0,04	0,06	0,09	0,09
INCC-M	968,00	0,07	0,03	0,04	0,04	0,07	0,09	0,14
UNIDADES FINANCIADAS CONSTRUÇÃO	968,00	131099,64	83406,14	39556,00	52244,00	105785,00	168145,00	288046,00
UNIDADES FINANCIADAS AQUISIÇÃO	968,00	287861,45	151115,98	23723,00	150484,00	285064,00	375031,00	578204,00
SELIC	968,00	0,09	0,04	0,02	0,07	0,09	0,12	0,14

APÊNDICE 2 – Dados estatísticos descritivos Grupo 2

VARIÁVEL	AMOSTRAS	MÉDIA	DESVIO PADÃO	MÍNIMO	25%	50%	75%	MÁXIMO
ATIVO TOTAL	485,00	4015,10	4022,35	73,74	1598,14	2805,36	4902,55	17976,74
ATIVO CIRCULANTE	485,00	2217,32	2627,77	14,23	336,17	1183,88	3300,95	13924,46
DISPONIBILIDADES	485,00	398,02	538,75	8,29	67,99	186,19	406,95	2856,74
ESTOQUES	485,00	1327,18	1563,65	0,00	0,05	737,96	2342,12	5552,86
ATIVO NÃO CIRCULANTE	485,00	1797,77	1795,48	13,09	562,68	1224,38	2295,83	8442,33
REALIZÁVEL A LONGO PRAZO	485,00	1062,73	1310,46	8,98	211,19	634,12	1264,49	6814,77
INVESTIMENTO	485,00	416,99	646,09	0,00	8,00	75,40	683,73	3162,05
IMOBILIZADO	485,00	53,16	128,46	0,02	6,91	20,57	60,90	1522,44
INTANGÍVEL	485,00	264,90	776,42	0,00	0,88	8,99	36,67	3727,07
PASSIVO TOTAL	485,00	4015,10	4022,35	73,74	1598,14	2805,36	4902,55	17976,74
PASSIVO CIRCULANTE	485,00	1251,62	1420,63	5,56	287,48	765,04	1710,01	6927,98
EMPRÉSTIMOS E FINANCIAMENTOS	485,00	558,70	637,46	0,00	54,55	316,45	798,22	3258,80

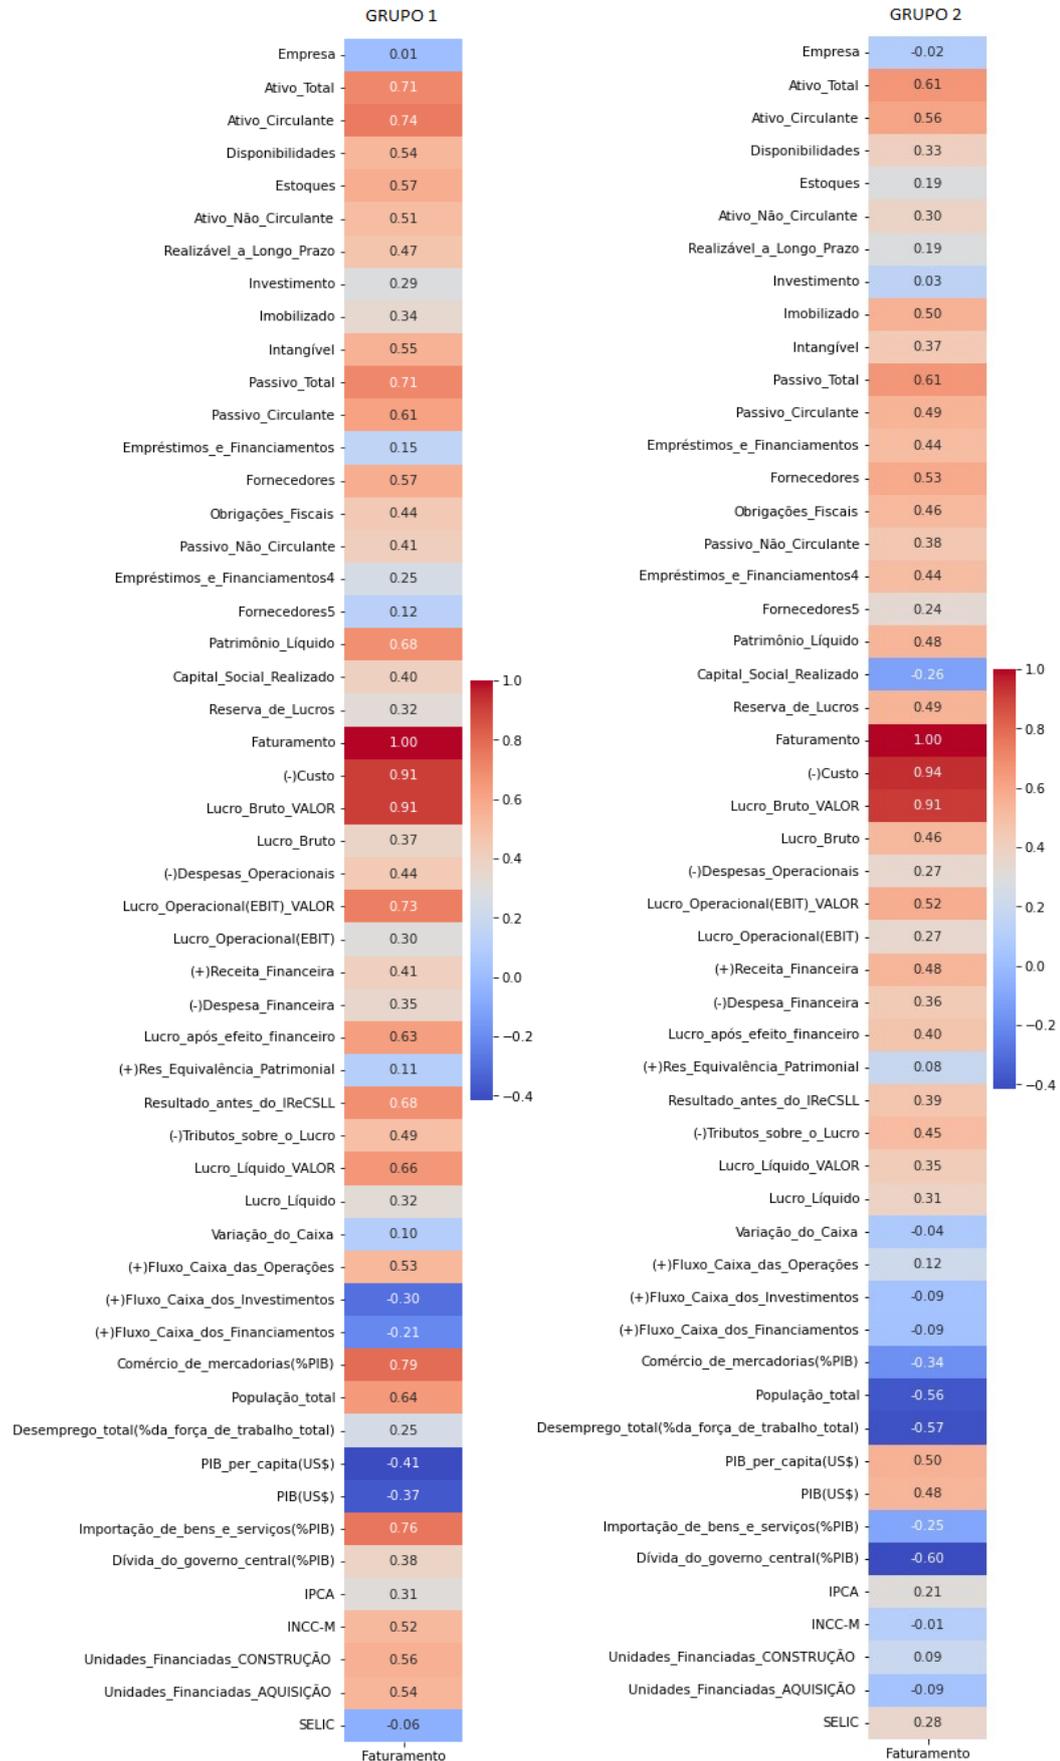
FORNECEDORES	485,00	74,75	85,16	0,40	13,28	43,36	88,96	365,10
OBRIGAÇÕES	485,00	69,33	106,48	0,00	4,77	23,51	80,31	479,48
FISCAIS								
PASSIVO NÃO	485,00	1497,73	1321,85	1,39	530,29	1346,81	2003,93	6701,79
CIRCULANTE								
EMPRÉSTIMOS E	485,00	856,20	870,66	0,00	86,24	676,03	1204,71	3895,46
FINANCIAMENTOS2								
FORNECEDORES2	485,00	2,16	12,07	0,00	0,00	0,00	0,00	90,77
PATRIMÔNIO	485,00	1265,75	2279,96	-5606,37	242,87	912,64	1811,97	7699,33
LÍQUIDO								
CAPITAL SOCIAL	485,00	1332,51	1448,45	16,55	317,81	842,98	1667,49	5703,54
REALIZADO								
RESERVA DE	485,00	364,15	694,43	-698,55	0,00	47,45	365,86	3389,23
LUCROS								
FATURAMENTO	485,00	1415,73	1892,88	0,00	208,19	769,33	1832,25	15654,53
(-)CUSTO	485,00	1063,93	1447,77	-260,81	100,43	605,54	1361,15	11853,34
LUCRO BRUTO	485,00	351,79	531,45	-1117,96	28,78	200,18	470,34	3801,18
VALOR								
LUCRO BRUTO	485,00	0,26	0,84	-7,92	0,19	0,28	0,32	13,35
(-)DESPESAS	485,00	337,51	599,63	-595,75	39,92	158,85	400,62	5297,88
OPERACIONAIS								

LUCRO	485,00	12,84	719,54	-6244,04	-36,85	38,05	198,45	2030,57
OPERACIONAL(EBIT)								
VALOR								
LUCRO	485,00	-0,46	2,80	-42,98	-0,16	0,06	0,17	1,70
OPERACIONAL(EBIT)								
(+)RECEITA	485,00	162,78	334,59	-12,94	25,46	68,88	178,22	3145,79
FINANCEIRA								
(-)DESPESA	485,00	233,23	304,93	0,00	35,31	83,24	327,23	1588,15
FINANCEIRA								
LUCRO APÓS EFEITO	485,00	-56,05	829,99	-7714,62	-107,43	3,41	169,11	2125,50
FINANCEIRO								
(+)RES	485,00	20,25	60,27	-143,71	0,00	0,00	11,81	526,98
EQUIVALÊNCIA								
PATRIMONIAL								
RESULTADO ANTES	485,00	-34,62	845,13	-7721,60	-94,99	8,52	173,59	2652,48
DO IRECSLL								
(-)TRIBUTOS SOBRE	485,00	44,82	127,08	-428,79	1,68	21,38	62,08	1180,77
O LUCRO								
LUCRO LÍQUIDO	485,00	-79,44	814,42	-7337,58	-117,81	4,44	131,22	2186,88
VALOR								
LUCRO LÍQUIDO	485,00	-0,80	3,79	-49,76	-0,42	0,01	0,12	3,64

VARIAÇÃO DO CAIXA	485,00	-26,01	223,57	-1553,88	-75,28	-3,32	19,54	1111,29
(+)FLUXO CAIXA DAS OPERAÇÕES	485,00	88,69	481,52	-3668,83	-41,50	39,84	238,65	2247,98
(+)FLUXO CAIXA DOS INVESTIMENTOS	485,00	-15,90	371,31	-1806,13	-85,22	-1,35	50,74	1286,32
(+)FLUXO CAIXA DOS FINANCIAMENTOS	485,00	-99,00	534,25	-2121,89	-260,68	-47,42	47,00	3813,88
COMÉRCIO DE MERCADORIAS (%PIB)	485,00	22,55	4,87	18,09	18,80	20,38	25,44	32,62
POPULAÇÃO TOTAL	485,00	208227606	4979949,72	199977707	203459650	208504960	213196304	215313498
DESEMPREGO TOTAL (% DA FORÇA DE TRABALHO TOTAL)	485,00	0,11	0,03	0,07	0,07	0,12	0,13	0,14
PIB PER CAPITA (US\$)	485,00	9593,60	1764,97	6923,70	8680,74	8917,67	12071,40	12327,52
PIB(US\$)	485,00	1,9903E+12	3,2453E+11	1,4761E+12	1,7957E+12	1,9169E+12	2,456E+12	2,4728E+12

IMPORTAÇÃO DE BENS E SERVIÇOS (%PIB)	485,00	0,15	0,02	0,12	0,13	0,14	0,16	0,19
DÍVIDA DO GOVERNO CENTRAL (%PIB)	485,00	0,77	0,14	0,57	0,60	0,82	0,87	0,99
IPCA	485,00	0,06	0,02	0,03	0,04	0,06	0,09	0,09
INCC-M	485,00	0,07	0,03	0,04	0,04	0,07	0,09	0,14
UNIDADES FINANCIADAS CONSTRUÇÃO	485,00	130910,89	83466,62	39556,00	52244,00	105785,00	168145,00	288046,00
UNIDADES FINANCIADAS AQUISIÇÃO	485,00	287548,47	151195,10	23723AZ5	150484,00	285064,00	375031,00	578204,00
SELIC	485,00	0,09	0,04	0,02	0,07	0,09	0,12	0,14

APÊNDICE 3 – Correlações



Página de assinaturas



VITOR CORTE
977.518.120-87
Signatário



Dieisson Pivoto
019.334.280-40
Signatário



Joao Montenegro
031.096.850-00
Signatário



Diego Santos
015.916.960-70
Signatário

HISTÓRICO

- | | | |
|-------------------------|---|--|
| 06 jun 2024
15:54:49 |  | VITOR CORTE criou este documento. (Email: vitor.corte@atitus.edu.br, CPF: 977.518.120-87) |
| 06 jun 2024
15:54:50 |  | VITOR CORTE (Email: vitor.corte@atitus.edu.br, CPF: 977.518.120-87) visualizou este documento por meio do IP 131.221.12.98 localizado em Passo Fundo - Rio Grande do Sul - Brazil |
| 06 jun 2024
15:54:53 |  | VITOR CORTE (Email: vitor.corte@atitus.edu.br, CPF: 977.518.120-87) assinou este documento por meio do IP 131.221.12.98 localizado em Passo Fundo - Rio Grande do Sul - Brazil |
| 06 jun 2024
15:57:45 |  | Dieisson Pivoto (Email: dieissonpivoto@gmail.com, CPF: 019.334.280-40) visualizou este documento por meio do IP 189.6.255.174 localizado em Porto Alegre - Rio Grande do Sul - Brazil |
| 06 jun 2024
16:28:03 |  | Dieisson Pivoto (Email: dieissonpivoto@gmail.com, CPF: 019.334.280-40) assinou este documento por meio do IP 189.6.255.174 localizado em Porto Alegre - Rio Grande do Sul - Brazil |
| 02 ago 2024
10:41:52 |  | Diego Alex Gazaro dos Santos (Email: diego.santos@atitus.edu.br, CPF: 015.916.960-70) visualizou este documento por meio do IP 177.34.252.92 localizado em Passo Fundo - Rio Grande do Sul - Brazil |
| 02 ago 2024
10:41:52 |  | Diego Alex Gazaro dos Santos (Email: diego.santos@atitus.edu.br, CPF: 015.916.960-70) assinou este documento por meio do IP 177.34.252.92 localizado em Passo Fundo - Rio Grande do Sul - Brazil |
| 06 jun 2024
20:14:23 |  | Joao Luis Zeni Montenegro (Email: joaoluismontenegro@gmail.com, CPF: 031.096.850-00) visualizou este documento por meio do IP 131.221.13.111 localizado em Passo Fundo - Rio Grande do Sul - Brazil |



06 jun 2024
20:14:28



Joao Luis Zeni Montenegro (Email: joaoluismontenegro@gmail.com, CPF: 031.096.850-00) assinou este documento por meio do IP 131.221.13.111 localizado em Passo Fundo - Rio Grande do Sul - Brazil

