

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA POLITÉCNICA
ENGENHARIA DE PRODUÇÃO**

ISAQUE MARQUES PASCOAL

**PREVISÃO DE DEMANDA EM UMA FINTECH POR MEIO DO
MÉTODO DA REGRESSÃO LINEAR MÚLTIPLA**

**GOIÂNIA
2021**

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA POLITÉCNICA
ENGENHARIA DE PRODUÇÃO**

ISAQUE MARQUES PASCOAL

**PREVISÃO DE DEMANDA EM UMA FINTECH POR MEIO DO
MÉTODO DA REGRESSÃO LINEAR MÚLTIPLA**

ÁREA DE CONCENTRAÇÃO: GESTÃO DA PRODUÇÃO
SUBÁREA: Planejamento e Controle da Produção

Trabalho apresentado à Coordenação do Curso de Graduação em Engenharia de Produção, da Pontifícia Universidade Católica de Goiás, como requisito final para aprovação na disciplina Projeto Final de Curso II.

Orientadora: Prof Me. Vitor Hugo Martins e Resende

**GOIÂNIA
2021**

ISAQUE MARQUES PASCOAL

**PREVISÃO DE DEMANDA EM UMA FINTECH POR MEIO DO
MÉTODO DA REGRESSÃO LINEAR MÚLTIPLA**

Este trabalho foi julgado adequado e aprovado para a obtenção do título de graduação em
Engenharia de Produção da Pontifícia Universidade Católica de Goiás

Goiânia, 03 de dezembro de 2021




Prof. Me. Rodrigo Martinez Castro
Coordenadora do Curso de Engenharia de Produção


BANCA EXAMINADORA:



Prof. Me. Vitor Hugo Martins e Resende
Pontifícia Universidade Católica de Goiás
Orientador



Prof. Dr. Ricardo Caetano Rezende
Pontifícia Universidade Católica de Goiás
Banca



Prof. Me. Santiago Meireles Rocha
Pontifícia Universidade Católica de Goiás
Banca

DEDICATÓRIA

“À minha tão amada e abençoada família, que é a base da minha vida.”

AGRADECIMENTOS

Agradeço primeiramente a Deus, pela minha vida, saúde e por ter me proporcionado todas as condições para a realização desta graduação.

A todos os professores que tive o prazer de conviver na universidade, conheci, aprendi e desenvolvi bastante sob a orientação, sabedoria e conhecimento de todos.

As amizades que conquistei durante esta árdua e longa caminhada, que foi recompensada com momentos inesquecíveis ao lado de amigos que levarei comigo para a vida.

Finalmente, quero destacar o contributo dos meus pais Elias e Fabiana, do meu irmão Gustavo e da minha namorada Micaely, pelo apoio, paciência, confiança e motivação transmitidos a mim com tanto carinho e amor.

“Muitas pessoas falham na vida não porque miram muito alto e acabam errando, mas porque elas miram muito baixo e acertam.”

(Les Brown)

RESUMO

PASCOAL, I. P.; **PREVISÃO DE DEMANDA EM UMA FINTECH POR MEIO DO MÉTODO DA REGRESSÃO LINEAR MÚLTIPLA**, 2021. 51p. TCC (Trabalho de Conclusão do Curso – Graduação em Engenharia de Produção). Pontifícia Universidade Católica de Goiás, Goiânia, Goiás, 2021.

O presente trabalho teve como objetivo verificar a adequação da Regressão Linear Múltipla como um modelo de previsão de demanda de um produto de uma *fintech*. Para a elaboração do modelo preditivo foram levantados os dados históricos de solicitações de crédito da empresa, compreendendo o período entre abril de 2020 até agosto de 2021 e, complementar a estes, foram obtidos também os dados históricos pertencentes ao mesmo período de outras variáveis que foram selecionadas para compor o modelo, sendo elas o histórico de parcerias ativas da empresa, o PIB mensal em dólar, a taxa de juros Overnight/SELIC e o índice da taxa de câmbio efetiva real. Foi notado que os períodos entre março e abril de 2021 foram impactados pela pandemia do COVID-19 e portanto foram excluídos do conjunto de dados. Após isso foram elencadas as variáveis que possuíam uma boa correlação com a demanda para compor o modelo, sendo elas o PIB e a quantidade de parceiros, utilizou-se então o GRETL para gerar o modelo preditivo que alcançou um R^2 de 0,76. Foi validado através dos indicadores de erro CFE, MAD e SME que a previsão calculada possuía uma baixa margem de erro, além disto, foi estimado o intervalo de confiança com 95% de confiança para a previsão de demanda e esta compreendeu por completo toda a demanda no período, confirmando assim a qualidade do modelo criado. Conclui-se que o modelo criado consegue prever a demanda de uma *fintech* e além disto ele conseguiu explicar como os fatores PIB e quantidade de parceiros impactam na demanda da empresa, sendo possível implantar com facilidade o modelo na empresa e através da metodologia exposta no estudo, melhorar o modelo preditivo e avaliar o impacto de diversos outros fatores, sejam eles internos ou externos, na demanda da empresa.

Palavras-chave: Previsão de demanda. Regressão linear múltipla. GRETL. *Fintech*. Mínimos Quadrados Ordinários.

ABSTRACT

PASCOAL, I. P.; **DEMAND FORECAST IN A FINTECH THROUGH THE MULTIPLE LINEAR REGRESSION METHOD**, 2021. 51p. TCC (Final Course Work - Graduation in Production Engineering). Pontifical Catholic University of Goiás, Goiânia, Goiás, 2021.

The present work aimed to verify the adequacy of Multiple Linear Regression as a model of demand forecasting of a product from a fintech. For the elaboration of the predictive model, the historical data of credit requests of the company were collected, comprising the period between April 2020 and August 2021, complementary to this, it was also obtained the historical data belonging to the same period of other variables that were selected to build the model, which are the history of active partnerships of the company, monthly GDP in dollars, Overnight/SELIC interest rate and the real effective exchange rate index. It was noticed that the periods between March and April 2021 were impacted by the COVID-19 pandemic and were therefore excluded from the data set. After that, the variables that had a good correlation with the demand were chosen to compose the model, and the GDP and the number of partners were the only listed, and GRETl was used to generate the predictive model that reached an R^2 of 0.76. It was validated through the indicators of error CFE, MAD and SME that the calculated forecast was erroneous on a small scale in relation to the actual demand, in addition, the confidence interval was estimated with 95% confidence for the demand forecast and it fully understood all the demand in the period, thus confirming the quality of the model created. It is concluded that the model created can predict the demand of a fintech and beyond that it was able to explain how some factors impact the company's demand, being possible to easily implement the model in the company and through the methodology exposed in the study, improve the predictive model, and evaluate the impact of several other factors, whether internal or external, in the company's demand.

Keywords: Demand forecast. Multiple linear regression. GRETl. Fintech. Ordinary Least Squares.

LISTA DE ILUSTRAÇÕES

Figura 1 – Crescimento das fintechs no Brasil.....	18
Figura 2 – Etapas do modelo de previsão de demanda	25
Figura 3 – Tela inicial do GRETL.....	27
Figura 4 – Relações e modelo de negócio da empresa.....	32
Figura 5 – Total de Solicitações de Crédito Mensais.....	35
Figura 6 – Histórico de parcerias ativas	36
Figura 7 – Matriz de coeficiente de correlação	38
Figura 8 – Comportamento das variáveis escolhidas	39
Figura 9 – Resultado do modelo.....	40
Figura 10 – Comportamento da Regressão	41
Figura 11 – Erros da regressão	42
Figura 12 – Comportamento do erro	43
Figura 13 – Intervalo de confiança da previsão	44

LISTA DE QUADROS

Quadro 1 - Relação entre o valor de r e a qualidade da sua correlação.....	22
Quadro 2 – Variáveis econômicas.....	36
Quadro 3 – Valores e variáveis selecionados.....	37
Quadro 4 – Coeficientes de correlação e determinação	38
Quadro 5 – Indicadores de Erro	43

LISTA DE ABREVIATURAS E SIGLAS

ARIMA	<i>Autoregressive Integrated Moving Average</i>
CFE	<i>Cumulative Forecast Error</i>
IC	Intervalo de Confiança
IF	Instituição Financeira
LGPD	Lei Geral de Proteção de Dados
MAD	<i>Mean Absolute Deviation</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MQO	Mínimos Quadrados Ordinários
MSE	<i>Mean Squared Error</i>
RLM	Regressão Linear Múltipla
RLS	Regressão Linear Simples

LISTA DE SÍMBOLOS

R	Coeficiente de correlação
R^2	Coeficiente de determinação
β	Beta

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	15
CAPÍTULO 2 - REFERENCIAL TEÓRICO	17
2.1 FINTECHS DO SETOR DE CRÉDITO	17
2.1.1 Mercado de Crédito.....	19
2.2 PREVISÃO DE DEMANDA	20
2.2.1 Modelos de Previsão de Demanda	20
2.2.2 Regressão Linear Múltipla	21
2.2.3 Coeficientes de Correlação e Determinação	21
2.2.4 Intervalo de Confiança	22
2.2.5 Erros de Previsão de Demanda	23
2.2.6 Etapas do Modelo de Previsão de Demanda	24
2.2.7 Indicadores Econômicos	26
2.2.8 GRETL	26
2.3 TRABALHOS CORRELATOS	28
2.3.1 Fatores Que Impactam a Demanda de Bens de Consumo Duráveis: Um Estudo em uma Indústria de Utilidade Doméstica	28
2.3.2 Modelo de Previsão de Demanda de uma Autopeça Fornecedora para o Setor de Máquinas Agrícolas.....	28
2.3.3 Demand Forecast of New Retail Target Products Based on Multiple Linear Regression	29
2.3.4 Modelo de Previsão para uma Série Temporal de Dados de Cabotagem	29
CAPÍTULO 3 - METODOLOGIA DE PESQUISA.....	31
3.1 DESCRIÇÃO DA EMPRESA.....	31
3.2 ETAPAS DA PESQUISA.....	32
3.2.1 Coleta de Dados	32
3.2.2 Escolha das Variáveis	33
3.2.3 Modelagem Preditiva	33
3.2.4 Avaliação do Modelo	33
CAPÍTULO 4 - RESULTADOS E DISCUSSÕES	35
4.1 COLETA DE DADOS.....	35
4.2 ESCOLHA DAS VARIÁVEIS.....	38
4.3 MODELAGEM PREDITIVA.....	39
4.4 AVALIAÇÃO DO MODELO	41

CAPÍTULO 5 - CONCLUSÕES.....	46
REFERÊNCIAS	48

CAPÍTULO 1 - INTRODUÇÃO

A competitividade no sistema financeiro brasileiro, desde o Plano Real, é extremamente acirrada. Os principais bancos do Brasil concentram 82% dos recursos econômicos do país, dificultando o desenvolvimento financeiro nacional, o que ocasiona em falta de opções e competitividade, visto que estes bancos podem adquirir quaisquer novos modelos de negócios que poderiam apresentar mais competição no setor. Como exemplo destes novos modelos se encaixam as *fintechs*¹, empresas que inovam e otimizam serviços financeiros por meio da tecnologia (SZAJMAN; MARTINS, 2019).

De acordo com Carvalho et al. (2019), as *fintechs*, devido ao seu foco principal neste mercado volátil e competitivo, tendem a ter problemas de desempenho organizacional. Estas empresas entregam produtos financeiros de uma forma mais rápida, barata, segura e personalizada, e um produto com essas características tende a trazer uma ótima demanda de clientes que, adicionado com a rápida migração do *offline* para o *online* nos últimos anos, cria-se uma demanda crescente. Para atender esta demanda, estas empresas precisam lidar com contratações em massa, seguido disto, rapidamente implementam novas soluções digitais que aumentam a produtividade, sendo necessário realocar funcionários para outras áreas, enquanto lida com a evasão de seus funcionários para empresas maiores, gerando assim diversos problemas organizacionais e de capacidade produtiva (MOȘTEANU, 2020).

As empresas que usam como ferramenta de planejamento a previsão de demanda, têm como benefícios subsídios para a tomada de decisão: possibilidades de avaliar o potencial de mercado e expansões; apoio analítico para o desenvolvimento de estratégias, além de programar e planejar a capacidade produtiva (PRADO, 2020). Benefícios como estes podem ser úteis também para as *fintechs*, já que são empresas em expansão em um mercado com muito potencial, e elas podem planejar sua capacidade produtiva de acordo a sua previsão de demanda futura.

Visualizando as empresas que utilizam a previsão de demanda, elas podem utilizar as técnicas em dois momentos distintos, seja para planejar seu sistema ou para planejar seu uso. Sendo assim, é um ótimo fundamento para a elaboração de estratégia tanto de longo prazo quanto de curto prazo para a empresa. Pensando em longo prazo é possível focar nos tipos de

¹ De acordo com Redação Nubank (2020) o termo *fintech* surgiu da combinação entre *financial* (financeiro) e *technology* (tecnologia). Ele se refere a empresas ou startups que desenvolvem e entregam produtos financeiros por meio exclusivamente digital, tendo a tecnologia como o diferencial principal em relação às empresas mais tradicionais do setor.

produtos ou a qualificação da mão de obra, e em curto prazo focar nos planos de trabalho ou planos de contratação (TUBINO, 2000).

Para qualquer empresa evoluir no mercado é necessário planejamento e a base de qualquer planejamento é a estimativa do futuro da empresa, seja avaliando sua capacidade interna ou seu alcance externo, a previsão de demanda pode ser extremamente útil para este planejamento. A demanda de um produto ou serviço pode estar relacionada a uma ou mais variáveis internas ou externas da empresa, e para estes casos é possível realizar uma previsão de demanda através do método de Regressão Linear Múltipla (MOREIRA, 2015).

Sabendo que empresas com foco em planejamento podem utilizar da previsão de demanda para desenvolver suas estratégias, existe a necessidade de verificar também se empresas como *fintechs*, que com pouco tempo de existência crescem rapidamente e consistentemente (MOȘTEANU, 2020), podem se beneficiar da previsão de demanda visto que possuem poucos dados históricos disponíveis mas que geralmente são explicados por vários parâmetros, sendo assim a Regressão Linear Múltipla torna-se uma possível ferramenta para a realização da previsão de demanda.

Nesse sentido, questiona-se: A Regressão Linear Múltipla (RLM) consegue se adequar corretamente como um método de previsão de demanda para uma *fintech* de crédito?

Desta forma, tem-se como objetivo geral deste estudo verificar a adequação da RLM como modelo de previsão de demanda de um produto de uma *fintech*. Para alcançar este objetivo, foram elencados os seguintes objetivos específicos: obter o histórico de solicitações de crédito de uma *fintech*; elencar as variáveis regressoras do modelo preditivo; obter o modelo preditivo; constatar a adequação do modelo preditivo.

CAPÍTULO 2 - REFERENCIAL TEÓRICO

2.1 FINTECHS DO SETOR DE CRÉDITO

As *fintechs* são *startups* que participam do setor financeiro e no Brasil, elas possuem um foco especial no setor de crédito, meios de pagamentos, gestão financeira, bancos digitais e tecnologia financeiras. As *fintechs* do setor de crédito costumam operar de forma similar entre si, geralmente através de serviços exclusivos de canais digitais, buscando oferecer créditos, financiamentos e negociação de dívidas, na maior parte dos casos através de contratos que colocam como garantia algum bem pessoal do cliente (SCHMOLLER et al., 2020).

A maneira como as pessoas acessam e utilizam o mercado financeiro mundialmente tem sido revolucionado constantemente pelas *fintechs* e não tem sido diferente no Brasil: somente em 2019 já existiam 550 *fintechs* no país. Estas empresas, em todo o mundo, têm tomado o espaço que antes eram dos grandes bancos: cerca de 75% dos consumidores no mundo todo utilizam seus serviços para realizar suas transferências ou pagamentos, e cerca de 58% das pequenas e médias empresas as usam para seus serviços bancários. Entretanto, aqui no Brasil as *fintechs* têm encontrado diversas barreiras para sua expansão (MENEZES, 2020).

De acordo com Menezes (2020), cerca de 30% das pessoas no país não possuíam acesso à internet de forma regular em 2018, e das várias pessoas que possuíam acesso grande parte era constituída da classe C e D, tornando a aquisição de novas tecnologias para esta parcela da população bastante cara e inacessível. Além disto, tem-se as diversas obrigações e normas regulatórias que regem todo o mercado, dentro das mais recentes se destacam as normas e procedimentos de Proteção à Lavagem de Dinheiro, a Resolução nº 4.753, de 26 de setembro de 2019 e a Lei 13.709 – Lei Geral de Proteção de Dados (LGPD)², e para estar sempre enquadrado dentro das leis são necessárias equipes internas de *compliance*³, este conjunto de regulamentações e leis acaba se tornando barreiras para a entrada destas empresas no mercado.


Mesmo com todas estas dificuldades, o mercado financeiro tem recebido muitas novas empresas classificadas como *fintechs* nos últimos anos. Assim como é mostrado na Figura 1, essas empresas têm se beneficiado das fraquezas do sistema atual para montar soluções cada

² Esta Lei dispõe sobre o tratamento de dados pessoais, inclusive nos meios digitais, por pessoa natural ou por pessoa jurídica de direito público ou privado, com o objetivo de proteger os direitos fundamentais de liberdade e de privacidade e o livre desenvolvimento da personalidade da pessoa natural.

³ Segundo Kalay (2018), *compliance* é o conjunto de disciplinas e práticas que tem como objetivo o cumprimento de normas de uma empresa, geralmente os profissionais desta área buscam investigar, evitar e solucionar qualquer tipo de desvio, risco ou inconformidade.

vez melhores para se consolidarem no mercado (JONES, 2020).

Figura 1 – Crescimento das fintechs no Brasil



Fonte: BENELI *apud* JONES (2020)

Hoje em dia cerca de 35 milhões de pessoas têm acesso ao sistema financeiro nacional (que possuem conta em banco e cartão de crédito); isso não chega a nem 17% da população nacional, e mesmo esta parcela da população frequentemente enfrenta dificuldades para conseguir crédito (JONES, 2020). Enxergando todo este potencial, diversas *fintechs* têm sido

criadas para atender este público, principalmente em serviços mais básicos, como pagamentos e crédito, e aproveitam da digitalização para poder expandir sua base de clientes, desbravando o mercado que os grandes bancos não consideravam lucrativos.

2.1.1 Mercado de Crédito

De acordo com Reis (2017), o mercado de crédito aborda todas as instituições financeiras (IFs) que participam do sistema de empréstimos no país, cedendo crédito para pessoas físicas e/ou jurídicas. As IFs são intermediárias nesse mercado, de forma que elas buscam pegar o dinheiro de entidades que querem emprestar um recurso corrigido por uma taxa de juros, e entregar esse recurso para entidades que precisam de um recurso emprestado, de forma que elas ganham uma comissão para esta intermediação e às vezes também, são os mesmos que querem emprestar o recurso.

O número de empresas classificadas como *fintechs* disparou de 56 em 2015 para 553 em 2019, com destaque para o setor de crédito, que reunia 87 destas empresas, setor este onde 70% do seu volume está resumido às cinco maiores instituições financeiras do país, como informa o estudo apresentado por Jones (2020). Uma das vantagens das *fintechs* sobre estas instituições é que elas nascem para atender às necessidades dos consumidores, mesmo aqueles mal atendidos ou excluídos pelas instituições tradicionais, enquanto isto estas grandes instituições aproveitam deste domínio no mercado para lucrar utilizando sistemas antigos e metodologias engessadas.

De acordo com estudo feito pela Baltazar (2019), os principais problemas que as *fintechs* pretendem resolver neste mercado são: Aprovações de crédito mais rápidas e menos burocráticas, melhorias na experiência do cliente e a adoção de tecnologias. Além de resolver estes problemas, somado a isto, a crise financeira no país, tem feito pessoas e empresas a buscarem cada vez mais crédito: de 2017 para 2018 o número de pedidos de empréstimo feitos para pessoa física, saiu de 3,2 para 6,4 milhões, e entre as empresas este número disparou ainda mais, saindo de 42 mil para 276 mil pedidos de empréstimos.

Com a demanda crescente estas empresas precisam aprimorar seus serviços com mudanças tecnológicas constantes, aumentando assim a sua capacidade e qualidade de atendimento e prestação de serviços, para que consigam implantar estas melhorias elas necessitam de mão de obra altamente qualificada e encontrar estes talentos requer tempo e investimento e muitas vezes só é possível descobrir que precisa de mais funcionários quando o sistema já está com gargalos, complicando ainda mais a busca por profissionais de qualidade e

perdendo oportunidades no mercado (BALTAZAR, 2019).

De acordo com Mello (2021), a procura por crédito no país cresceu 26,2% no primeiro semestre de 2021 em relação ao mesmo período de 2020, este crescimento se deve principalmente pela retomada econômica do país após a pandemia de COVID-19, fortalecido pelo avanço da vacinação da população, confiança financeira dos consumidores e as taxas de juros em níveis atrativos. Os objetivos dos empréstimos são em sua maioria para aquisição de bens ou renegociação de dívidas.

2.2 PREVISÃO DE DEMANDA

2.2.1 Modelos de Previsão de Demanda

A previsão de demanda é o resultado de uma modelagem analítica de um sistema. Esta modelagem se fundamenta em resultados de períodos passados e entrega previsões do que pode acontecer em períodos futuros, estas estimativas podem ajudar na tomada de decisão de todo o planejamento de setores de uma empresa, gerenciamento de orçamento e fluxo de caixa (PRADO, 2020).

Existem dois métodos para realizar uma previsão de demanda, o primeiro denominado qualitativo, no qual pode se utilizar de entrevista com gestores, pesquisa de vendas, método Delphi ou pesquisa com clientes. No método qualitativo são levadas em consideração as opiniões das pessoas envolvidas no processo, e por isto são mais subjetivas.

O segundo método é o quantitativo, no qual são utilizados dados históricos combinados com técnicas estatísticas para entender padrões de comportamento de uma demanda passada e estimar uma demanda futura, geralmente são mais assertivos pois evitam a interferência de julgamentos e opiniões erradas (MARI, 2017).

Dentro do método quantitativo existe uma subdivisão entre os modelos estatísticos, que são aqueles voltados para séries temporais e séries causais. As séries temporais são aquelas que presumem que o resultado de uma variável depende exclusivamente do tempo, como por exemplo Médias Móveis, Suavização Exponencial e *Autoregressive Integrated Moving Average* (ARIMA). Entretanto, os modelos causais presumem que o valor de uma variável dependente é o resultado de várias outras variáveis independentes, que pode incluir ou não o tempo, alguns exemplos são a Regressão Linear Simples e Regressão Linear Múltipla (MARI, 2017).

2.2.2 Regressão Linear Múltipla

A Regressão Linear Múltipla (RLM) é uma extensão da Regressão Linear Simples (RLS). A diferença entre elas é a que a RLS é resultado de uma única variável, enquanto a RLM resulta do relacionamento de infinitas variáveis, ambas as regressões são formadas por uma constante, somado ao resultado do produto entre o fator de importância e uma variável, que por fim é somado ao erro residual (MARI, 2017).

A vantagem de se utilizar de muitas variáveis regressoras, é que muitos dos casos de sistemas reais, uma única variável preditora não é suficiente para explicar o modelo. Para montar o modelo regressivo, é necessário que as variáveis regressoras tenham baixa correlação entre si, entretanto, devem ter grande correlação entre a variável resposta. Um ótimo recurso para se verificar a correlação entre duas variáveis é o coeficiente de determinação (r^2), ele é o resultado da soma dos quadrados de uma regressão dividida pela soma dos quadrados de uma variável, o resultado é sempre entre 0 e 1, e é utilizado comumente em percentual, explicando assim a possível variação em relação a variável resposta (OLIVEIRA; MILANI; SILVA, 2019).

A RLM depende da associação de um fator de importância para cada uma das variáveis regressoras, esse fator de importância, também chamado de parâmetro de inclinação ou Beta (β), é determinado através do método dos Mínimos Quadrados Ordinários (MQO). Na RLM esta técnica de otimização procura estimar e ajustar os valores de β para minimizar a soma dos erros quadrados do modelo (SILVA, 2020). Devido à complexidade de diversos modelos, esta técnica está incorporada em algoritmos de diversos programas de Econometria, inclusive o GRETL. De acordo com Moreira (2015) uma RLM é expressa de acordo com a Equação 1, onde X é a variável regressora, n é o número de variáveis e Y é a variável de resposta.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_n X_n \quad (1)$$

2.2.3 Coeficientes de Correlação e Determinação

Durante a construção de um modelo preditivo como a RLM, é preciso verificar dois fatores importantes, a correlação e a determinação. Ambos avaliam a perfeição da relação entre uma variável regressora e a variável de resposta. O coeficiente de correlação (R) pode assumir qualquer valor entre +1 e -1, onde o valor $R = +1$ indica uma correlação perfeita positiva, no qual de acordo com que uma variável regressora varia, a variável de resposta varia na mesma proporção e sentido, se o valor for de $R = -1$ ocorre a mesma coisa, entretanto, com sentido oposto, quando $R = 0$ então não existe nenhuma correlação entre as variáveis (MOREIRA,

2015). A Equação 2 mostra como é realizado o cálculo do R, onde n é o número de amostras, X é a variável regressora e Y é a variável de resposta.

$$R = \frac{n \sum XY - (\sum X)(\sum Y)}{\sqrt{n \sum X^2 - (\sum X)^2} \sqrt{n \sum Y^2 - (\sum Y)^2}} \quad (2)$$

O Quadro 1 elaborado por Moreira (2015), mostra como é possível interpretar os resultados de r.

Quadro 1 - Relação entre o valor de r e a qualidade da sua correlação

r	Correlação
0 a 0,2	Muito baixa
0,2 a 0,4	Baixa
0,4 a 0,6	Média
0,6 a 0,8	Alta
0,8 a 1,0	Muito Alta

Fonte: Moreira (2015)

Moreira (2015) complementa que pode se utilizar o R^2 ao invés do R, visto que é possível ser mais conservador com os valores obtidos, visto que a determinação sempre será menor que a correlação, já que para obter o R^2 basta elevar ao quadrado o R, e um número entre 0 e 1 elevado ao quadrado sempre é menor que o valor original. O R^2 é utilizado para saber a proporção de variância entre duas variáveis, sendo possível verificar o quanto uma variável explica a outra em porcentagem (p. ex. um R^2 de 0,85 significa que o comportamento de X explica 85% da variação de Y). A mesma interpretação de resultado demonstrado no Quadro 1, é válido para o R^2 e a qualidade da determinação.

2.2.4 Intervalo de Confiança

A previsão de uma série sozinha pode não demonstrar com clareza as informações dadas pelo modelo, visto que é muito improvável que o valor originado pela previsão será atingido de fato no sistema real, para isto é necessário medir o grau de certeza do modelo com uma determinada confiança que geralmente é escolhida dependendo de cada caso. Vale ressaltar que quanto maior a probabilidade de um intervalo conter determinado parâmetro, maior será o intervalo. Geralmente com poucos dados espera-se intervalos maiores (MENEZES;

VALENÇA, 2013). O intervalo de confiança (IC) pode ser calculado automaticamente no *software* GRETl de acordo com a confiança estatística desejada.

Para calcular o IC é necessário ter o erro padrão da estimativa, que pode ser calculado através da Equação 3, onde S_t é o erro padrão (também chamado de desvio padrão), A_t é a demanda real e F_t é a demanda prevista e n é a quantidade de amostras. (MOREIRA, 2015).

$$S_t = \sqrt{\frac{\sum (A_t - F_t)^2}{n-2}} \quad (3)$$

Com o valor do erro padrão calculado, o intervalo é obtido através da Equação 4, onde Z é o número de erros padrão de acordo com uma curva normal para a confiança escolhida (p. ex. $Z = 1,96$ para uma confiança de 95%, $Z = 1,64$ para uma confiança de 90%). Sendo assim a previsão de demanda terá um limite superior e inferior, que será respectivamente a previsão calculada somada e subtraída do S_t multiplicado pela Z (MOREIRA, 2015).

$$IC = F_t \pm S_t Z \quad (4)$$

2.2.5 Erros de Previsão de Demanda

Segundo Fitzsimmons (2014) existem diversas métricas para avaliar a precisão de uma previsão, dentre elas vale ressaltar o Erro de previsão acumulado (CFE, *cumulative forecast error*), a Média do desvio absoluto (MAD, *mean absolute deviation*), o Erro quadrático médio (MSE, *mean squared error*) e o Erro percentual absoluto médio (MAPE, *mean absolute percentage error*).

Como toda previsão deve ser feita de maneira não enviesada, no rastreamento da média real dos dados a soma dos erros entre a previsão e a demanda real deve ser sempre minimizada para alcançar o zero, contando com as diferenças positivas e negativas, e para isto é utilizado o CFE (FITZSIMMONS, 2014). A Equação 5 mostra como é calculado o CFE, onde A_t significa o valor real para cada período e F_t significa o valor previsto de cada período.

$$CFE = \sum A_t - F_t \quad (5)$$

Outro método comum para a verificação do erro de previsão é a MAD, ela fornece a

média dos desvios de erros de forma absoluta, o que dá um peso igual para cada um dos erros (FITZSIMMONS, 2014). A Equação 6 demonstra qual é a fórmula para o cálculo da MAD, onde n é o número de períodos.

$$MAD = \sum \frac{|A_t - F_t|}{n} \quad (6)$$

O MSE é dedicado para os casos em que errar é caro ou perigoso demais para a empresa, pode-se elevar os erros ao quadrado para dar mais peso a eles (FITZSIMMONS, 2014). A Equação 7 demonstra como é calculado o MSE.

$$MSE = \sum \frac{(A_t - F_t)^2}{n} \quad (7)$$


Às vezes, é necessário que o erro seja colocado em perspectiva (p. ex. um erro de 3 em uma previsão de 10 é muito alto se comparado com o erro de 3 em uma previsão de 100 ou de 1000) para dar uma significância do erro em relação ao todo, para estes casos utiliza-se o MAPE (FITZSIMMONS, 2014). O MAPE é calculado de acordo com a Equação 8, e o seu resultado é dado em porcentagem.

$$MAPE = \frac{\sum \frac{|A_t - F_t|}{A_t}}{n} (100) \quad (8)$$

2.2.6 Etapas do Modelo de Previsão de Demanda

Segundo Tubino (2000), para se realizar a modelagem de um modelo preditivo, é necessário que sejam realizadas cinco etapas, que estão demonstradas na Figura 2.

Figura 2 – Etapas do modelo de previsão de demanda



Fonte: Tubino (2000).

O objetivo do modelo pode ser alcançado através das necessidades da empresa, podendo ser na maior parte recursos ou produtos. Quanto maior o horizonte de previsão maior deve ser o erro considerado pelo gestor, a sofisticação e o detalhamento dependem da importância relativa do produto e da quantidade de dados disponíveis (TUBINO, 2000).

Sobre a coleta e análise de dados Tubino (2000) elencou algumas premissas, sendo elas:

- Quanto maior a quantidade de dados históricos coletados, mais confiável é a análise;
- Os dados devem buscar a caracterização da demanda pelos produtos e não necessariamente o histórico de vendas;
- Variações extraordinárias devem ser substituídas por valores médios;
- O tamanho do período tem influência direta na escolha do método.

Sabendo do tipo de dados obtidos, deve-se escolher o método de previsão, cada método tem seu campo de ação e aplicabilidade, não existindo um método padrão que seja adequado a todas as situações. Deve-se levar em conta o custo de utilização da ferramenta e sua

acuracidade, para horizontes maiores e estratégicos vale a pena investir mais do que uma previsão para a área operacional (TUBINO, 2000).

Definida a técnica de previsão é realizada a modelagem e obtida a previsão de demanda, ressaltando que quanto maior o horizonte analisado, maior o erro assumido pelo modelo. Com o passar dos tempos as previsões serão alcançadas pela demanda real e será necessário atualizar a modelagem, sendo necessário inclusive trocar o método utilizado (TUBINO, 2000).

2.2.7 Indicadores Econômicos

Para a realização de qualquer tipo de previsão no mercado financeiro é sempre associado algum indicador macroeconômico do país, Bernardelli, Bernardelli e Castro (2017) elencaram os principais indicadores macroeconômicos utilizados em estudos de regressão de diversos países, dentre eles estão o Produto Interno Bruto, Taxa de câmbio do dólar, Taxa Básica de Juros, Inflação e Expectativa de agentes. Cada um dos indicadores possui diversas variações e mudam de acordo com o país.

No Brasil estes são os principais indicadores de cada de acordo com Bernadelli e Castro (2020):

- Produto Interno Bruto: PIB mensal em dólar (US\$ milhões) (PIB)
- Taxa de Câmbio do Dólar: Índice da taxa de câmbio efetiva real (descontado do IPCA)
- Taxa de Juros: taxa Overnight/SELIC acumulada no mês (SELIC Over)

2.2.8 GRETL


O nome GRETL vem da abreviação de *GNU Regression, Econometrics and Time-series Library*. O GRETL é um programa multiplataforma, escrito em linguagem de programação C, gratuito, de código aberto. Ele reúne um pacote de programas e técnicas de análises econométricas. A sua última versão foi lançada em 18 de janeiro de 2021, mas, a sua primeira versão foi programada pelo ex-professor de economia da Universidade da Califórnia em São Diego e escritor do livro *Introductory econometrics with applications*, Ramu Ramanathan e desde então tem recebido atualizações constantes de vários contribuidores de todo o mundo, com todas as suas versões disponíveis gratuitamente no seu site oficial⁴. A cada

⁴ Link de acesso para o site oficial: gretl.sourceforge.net

biênio é realizado uma conferência, que reúne diversos estudos e avanços no campo da econometria com o objetivo de apresentar e incorporar ao programa todas estas melhorias (COTTRELL; LUCHETTI, 2021).

Atualmente o GRETL é dotado de uma interface gráfica muito amigável e intuitiva, conforme demonstrado na Figura 3, sendo possível realizar com rapidez qualquer análise econométrica em dados já tratados, e para a Regressão Linear Múltipla (RLM) a sua modelagem é feita utilizando o Método dos Mínimos Quadrados (MQO), e os resultados podem ser estudados no próprio programa e testados com diversas técnicas como por exemplo o R^2 (COTTRELL e LUCHETTI, 2021).

Figura 3 – Tela inicial do GRETL



Fonte: Elaborado pelo autor (2021)

Uma das vantagens de se adotar o GRETL como um programa analítico, é que por ser de código aberto ele possui compatibilidade com quaisquer outros programas que são utilizados no mercado, e.g. *Microsoft Excel*, *Python*, *Gnumeric*, *Stata* e vários outros. Os seus resultados podem ser facilmente incorporados em outros programas ou estudos, visto que ele fornece todas as variáveis necessárias para a construção de qualquer modelo, como por exemplo o β na RLM (COTTRELL e LUCHETTI, 2021).

2.3 TRABALHOS CORRELATOS

2.3.1 Fatores Que Impactam a Demanda de Bens de Consumo Duráveis: Um Estudo em uma Indústria de Utilidade Doméstica

Botelho (2020) elenca neste estudo diversos fatores que puderam se traduzir como influências para a demanda de uma indústria de móveis. A lista dos fatores escolhidos foram: PIB, renda, desemprego, publicidade, qualidade, preço, ciclo de vida e clima. Para a escolha das variáveis regressoras foi utilizado o método *stepwise*, que confirmou que das variáveis testadas, apenas 7 foram escolhidas, excluindo do estudo os gastos com publicidade, logo após foi verificado a sazonalidade na demanda, o que não impediu a aplicação da regressão linear múltipla como método preditivo para as vendas de 3 produtos.

Em média o modelo preditivo adquirido era capaz de explicar 42,5% da demanda dos 3 tipos de produtos, gerando um MAPE médio de 25,3%, ou seja, utilizando 4 variáveis regressoras foi possível na média conseguir um R^2 de 0,425 errando a previsão em média 25% a mais do que os valores reais. Não resultando em uma previsão de qualidade, entretanto, com o estudo o autor conseguiu encontrar também outras informações relevantes sobre a empresa estudada, mais especificamente sobre o comportamento de compra dos seus clientes, servindo assim como insumos estratégicos para a empresa.

2.3.2 Modelo de Previsão de Demanda de uma Autopeça Fornecedora para o Setor de Máquinas Agrícolas

O artigo publicado por Vidas et al. (2020) teve como objetivo realizar a previsão de demanda para as vendas de uma empresa localizada em São Paulo, a empresa estudada era do ramo de máquinas agrícolas, para a realização da previsão, foi utilizado a RLM, foram elencadas algumas variáveis regressoras que são: taxa de juros do crédito rural, valor das máquinas, área total plantada no país e o PIB agrícola nacional. Foi realizado o estudo de correlação para as variáveis regressoras e todas elas foram capazes de explicar a variável de resposta.

Foi então modelado a previsão de demanda obtendo-se um r^2 de 0,9997 com nível de confiança de 80% entre o modelo criado e a demanda real da empresa, sendo este um resultado excelente para o estudo. Entretanto no artigo os autores não se interessaram em criar previsões futuras para a empresa em questão, realizando somente a avaliação do modelo preditivo, visto

que os resultados obtidos entregaram mais valor para a empresa ao entregar uma forma de análise de impacto das variáveis quanto a demanda futura da empresa, como por exemplo notou que não fazia sentido acompanhar a taxa de juros do crédito rural pois sua variação não entregava um valor considerável na previsão futura, diferente do PIB Agrícola que aumentava a expectativa de venda da empresa em R\$ 0,11 para R\$ 1,00 no aumento do PIB. O método em questão foi utilizado pela empresa como uma forma de testar hipóteses e cenários futuros alterando as variáveis preditoras do modelo de acordo com as expectativas da empresa.

2.3.3 Demand Forecast of New Retail Target Products Based on Multiple Linear Regression

O artigo “Previsão de demanda de novos produtos alvos de varejo baseado na regressão linear múltipla”, de Zhou et al. (2020) trata sobre a previsão de demanda para a venda de alguns produtos de varejo da empresa SKC. Os dados históricos coletados foram de apenas um ano devido ao curto ciclo de vida do produto, os fatores considerados como variáveis regressoras foram o preço médio de custo, o preço de venda, o desconto de feriado, características de venda e informações do inventário.

O preço de venda é o fator de menor influência, e foi descartado durante a modelagem, e o fator mais influente é o custo do produto. O modelo final foi capaz de entregar um r^2 de 0,9337, que é considerado um ótimo modelo. Paralelo a isto, foi realizada uma segunda modelagem utilizando da Suavização Exponencial Quadrática, para o segundo método, os dados que eram somente 13 meses, foram divididos em dados de treinamento e de teste, sendo que os últimos 3 meses do ano eram utilizados para testar a demanda prevista pelo modelo. O MAPE médio obtido foi de 0.09 ou 9%, que é considerado um ótimo resultado.

2.3.4 Modelo de Previsão para uma Série Temporal de Dados de Cabotagem

O estudo de realizado por Borges e Mattos (2020) aborda o transporte de cargas pelo modal hidroviário brasileiro, mais especificamente na modalidade de cabotagem, técnica responsável pelo transporte de mercadorias entre portos. Os dados utilizados para o estudo abrangem o histórico de toneladas transportadas por cabotagem no Brasil entre o período de 1997 e 2018, sendo que os dados usados para modelagem são referentes aos anos de 1997 até 2013, com os outros 5 anos utilizados para testar a qualidade dos modelos. Foram utilizados

diversos métodos de previsão que vão desde o mais simples até os mais complexos, sendo eles: Método das médias, Método Naive, Método Drift, Método de Regressão Linear, Método de Suavização Exponencial e Método de Box-Jenkins.

Para a realização da modelagem e cálculo da previsão de demanda foi utilizado o GRETL e para as verificações de acuracidade foi utilizado o R e do *RStudio*. Foram realizados diversos testes estatísticos e para os modelos mais complexos foi calculado diversas variações. Por fim notou-se que o método mais efetivo para os dados não foi exatamente um dos mais complexos e sim a regressão linear, que conseguiu um ótimo resultado com 0,97 de R^2 . A vantagem foi pelo fato de que os dados possuíam uma certa tendencia crescente e não havia sazonalidade em seus valores tendo assim a regressão linear simples se destacado com seu intervalo de confiança que abrangia quase por completo todos os dados históricos.

CAPÍTULO 3 - METODOLOGIA DE PESQUISA

3.1 DESCRIÇÃO DA EMPRESA


A empresa objeto deste estudo é uma *fintech* que atua no setor de crédito imobiliário. É uma das várias empresas controladas por uma holding de empresas financeiras e de tecnologias, possui pouco mais de um ano de operação. Atualmente trabalha com apenas um único produto, que é o *home equity* também conhecido como crédito com garantia imobiliária, entretanto, ele é oferecido em todo o território nacional, através de uma plataforma digital por muitos parceiros.

Devido à grande experiência dos sócios e o nicho das outras empresas do grupo, a empresa começou bem estruturada e com excelentes parceiros, o que permitiu aproveitar muito bem o momento de expansão do mercado de crédito. Os parceiros são uma parte essencial para a empresa, já que eles atuam em diversas etapas do sistema interno, sendo que os principais são aqueles que estão junto aos clientes, oferecendo o produto da empresa para o público-alvo que é constituído principalmente por empresários ou funcionários públicos que possuem renda declarada e buscam empréstimos entre R\$50.000,00 até R\$ 5.000.000,00.

Atualmente a empresa conta com 6 analistas e 2 originadores de novos negócios, que trabalham em horário comercial, de segunda a sexta das 8:00 às 18:00 com intervalo entre as 12:00 e 13:00, os analistas realizam toda a etapa de análise e aprovação do crédito, enquanto os originadores buscam por novas parcerias. Por mais que o escritório funcione apenas em horário comercial, o sistema por ser digital, funciona 24 horas todos os dias da semana, visto que cada parceiro pode enviar uma nova operação sempre que precisar.

Como a principal fonte de clientes vem dos parceiros, a demanda da empresa cresce cada vez mais de acordo com o número de novas parcerias, os parceiros geralmente são empresas de consultoria financeira ou até mesmo imobiliárias, então eles possuem conhecimento sobre o produto o suficiente para oferecer os produtos da empresa para os clientes. Para incentivo de trazer novas operações o parceiro recebe uma comissão do volume das operações realizadas com sucesso. A Figura 4 demonstra as principais relações da empresa, onde o cliente alcança a empresa pelo parceiro, e assim a empresa com tecnologias e estruturas de outras empresas transformam a solicitação de crédito do cliente em um produto de investimento que é oferecido a fundos de investimento que buscam rentabilizar o capital de seus investidores, caso tudo ocorra bem tudo é formalizado nos cartórios.

Figura 4 – Relações e modelo de negócio da empresa



Fonte: Elaborado por autor (2021)

3.2 ETAPAS DA PESQUISA

3.2.1 Coleta de Dados

Esta primeira etapa foi constituída principalmente pela coleta de indicadores econômicos relevantes para o setor de crédito, sendo elas o PIB, Câmbio e SELIC Over, da série histórica da quantidade de parceiros cadastrados e a quantidade de solicitações de crédito recebidas na plataforma, estas informações foram extraídas do sistema interno da empresa e do Sistema de Gerenciamento de Séries Temporais (SGS) do BACEN (2021), os dados são fundamentais para se calcular a previsão de demanda, que tentará prever a quantidade de operações cadastradas no sistema.

Vale ressaltar que a empresa é nova e possuía poucos dados históricos a serem obtidos, com 17 períodos no total, os dados são compreendidos dentre o período de abril de 2020 até agosto de 2021, sendo utilizadas várias variáveis macroeconômicas para a aplicação da modelagem, aproveitando todos os benefícios da RLM compensando assim a falta de amostragem.

3.2.2 Escolha das Variáveis

As variáveis foram elencadas prioritariamente de acordo com o seu R e R^2 , buscando selecionar aquelas com coeficientes acima de 0,6, visto que o foco era tornar o modelo o mais seguro possível para compensar a sua falta de dados históricos, e, portanto, era importante que fosse avaliado o máximo de informações possíveis para deixar o modelo mais robusto e confiável.

De acordo com Hair et al. (2009), tem-se uma relação entre o número de amostras e o número de variáveis regressoras, existindo uma proporção de 1 regressora para cada 15 à 20 amostras, então é possível existir uma limitação no número de variáveis regressoras de acordo com a limitação da amostra do sistema. Entretanto, para este trabalho seguiu-se a lógica dos trabalhos correlatos, que por possuírem produtos com curto ciclo de vida, e consequentemente pouca amostragem, foram analisadas diversas variáveis regressoras, não limitando suas variáveis regressoras, entretanto apenas aquelas que possuíam um R^2 acima de 0,6 foram utilizadas na equação de regressão.

3.2.3 Modelagem Preditiva

A etapa de modelagem da previsão de demanda foi realizada inteiramente no *software* GRETL, sendo necessário adicionar ao modelo somente as variáveis mais importantes que explicam a demanda, ou seja, aquelas que possuíam um impacto considerável na demanda real do produto, mensurado de acordo com o R e o R^2 . O modelo buscou prever todos os períodos abordados pelo estudo, de forma que foi possível medir e avaliar o seu erro e seu Intervalo de Confiança (IC).

Para a determinação dos coeficientes β foi utilizado o método MQO, os vários testes de erros foram calculados automaticamente pelo GRETL.

3.2.4 Avaliação do Modelo

Para a etapa de avaliação, o modelo foi testado nos seguintes parâmetros de erros: MSE, MAD, CFE e MAPE. Estes primeiros são explicados em perspectiva, visto que não possuem um valor único que demonstre se foram bons valores ou não, complementar a isto foi realizado também a verificação do R e do R^2 do modelo em relação aos dados reais, que segundo

Moreira (2015) estes devem ser entre 0,6 e 1 para ser considerado no mínimo bons.


Para a previsão criada pelo modelo, foi criado um intervalo de confiança de 95% para demonstrar a acurácia da modelagem e, para facilitar a interpretação do resultado, foi criado um gráfico demonstrando o comportamento da demanda real e da demanda prevista, além de demonstrar em forma de área o intervalo de confiança do modelo.

CAPÍTULO 4 - RESULTADOS E DISCUSSÕES

4.1 COLETA DE DADOS

Foi inicialmente fornecido pela empresa o histórico de vendas que podem ser visualizados na Figura 3 e Quadro 2.


Figura 5 – Total de Solicitações de Crédito Mensais



Fonte: Elaborado pelo autor (2021)

É notável que existe uma tendência crescente de solicitações de crédito, e esta será a variável de resposta do modelo, pois por mais que nem todas as solicitações se tornem realmente em empréstimos, é necessário que empresa seja capaz de analisar os pedidos em tempo hábil, e deve, portanto, se preparar para qualquer quantidade de pedidos de empréstimos.

Os gestores podem se beneficiar da previsão das quantidades de solicitações enquanto preparam e otimizam a infraestrutura da empresa para a demanda futura. Entretanto, o momento atual da empresa recém criada é de plena expansão, conforme a Figura 6, que demonstra a quantidade de parcerias firmadas pela empresa, destinadas exclusivamente para trazer novas solicitações de crédito.

Figura 6 – Histórico de parcerias ativas

Fonte: Elaborado pelo autor (2021)

A tendência crescente de parcerias é alinhada como crescente aumento na quantidade de empréstimos e, portanto, será uma das variáveis regressoras do modelo. Entretanto ela sozinha não consegue explicar o atual cenário econômico para o mercado financeiro, sendo assim foram elencadas algumas variáveis macroeconômicas para obter a perspectiva do mercado no modelo.

O Quadro 2 demonstra as variáveis econômicas escolhidas, pertencentes também a um conjunto de variáveis elencadas por Bernadelli e Castro (2020), e todas têm como fonte o Sistema de Gerenciamento de Séries Temporais (SGS) do BACEN (2021), um sistema que reúne todas as principais séries históricas de indicadores econômicos e financeiros do país, cada uma das séries possui um código único de identificação para consulta dentro do sistema.

Quadro 2 – Variáveis econômicas

Variável	Descrição	Fonte
PIB	PIB mensal em dólar (U\$ milhões)	Série 4.385
Juros	Taxa de juros–taxa Overnight/Selic, acumulado mensal	Série 4.390
Câmbio	Índice da taxa de câmbio efetiva real (descontado oIPCA)	Série 11.752

Fonte: Elaborado pelo autor (2021)

Foram extraídas do SGS todas as séries históricas das variáveis econômicas existentes dentro do intervalo de tempo abordado pelo presente estudo. Bernadelli e Castro (2020) ainda sugerem por incluir uma variável de tendência que consiste em um valor crescente que recebe valor 1 no primeiro período da série e é acrescido de +1 em cada período. Porém esta variável não foi utilizada visto que a empresa está estreando no mercado e o modelo pode absorver a falsa visão de que quanto maior o tempo da empresa no mercado maior será a sua demanda e, portanto, sua demanda seria infinita. Foi utilizada a mesma lógica de alguns dos trabalhos correlatos e dispensado por completo a utilização de uma variável temporal no modelo. A relação com todas as variáveis escolhidas e seus respectivos valores são expostas no Quadro 3.

Quadro 3 – Valores e variáveis selecionados

Ano	Mês	Solicitações (un)	Parceiros (un)	PIB (U\$ milhões)	Juros (%)	Câmbio (R\$)
2020	abr	1	1	103.399	0,28	141,15
2020	mai	1	1	98.575	0,24	149,83
2020	jun	32	2	112.711	0,21	139,5
2020	jul	25	3	118.065	0,19	144,21
2020	ago	29	4	113.333	0,16	151,34
2020	set	23	10	116.821	0,16	148,91
2020	out	40	21	116.329	0,16	154,3
2020	nov	54	32	121.294	0,15	148,42
2020	dez	33	39	131.292	0,16	141
2021	jan	31	49	120.126	0,15	147,01
2021	fev	47	65	123.182	0,13	148,58
2021	mar	97	99	128.906	0,2	152,42
2021	abr	83	126	128.807	0,21	150,94
2021	mai	55	153	134.663	0,27	144,1
2021	jun	82	196	141.257	0,31	136,73
2021	Jul	64	265	141.227	0,36	139,49
2021	Ago	87	321	138.594	0,43	144,78


Fonte: Elaborado pelo autor (2021)

Durante o período entre março e abril de 2021, ocorreu um excesso de demanda provocado principalmente pela reabertura econômica com o fim das quarentenas estaduais em todo o país referentes à pandemia do COVID-19, o que causou uma distorção nos dados e foi, portanto, necessário excluir estas duas séries históricas do conjunto para que fosse possível criar um modelo de melhor qualidade.

4.2 ESCOLHA DAS VARIÁVEIS

Para a escolha das variáveis regressoras foi obtido a correlação (R) das variáveis quanto à variável Solicitações pelo GRET, conforme a Figura 7.

Figura 7 – Matriz de coeficiente de correlação



Fonte: Elaborado pelo autor (2021)

A partir dos valores R obtidos na matriz, referentes a correlação das variáveis e o número de solicitações, foi calculado o R^2 de cada uma das variáveis em relação à variável de resposta. O valor de R^2 foi obtido elevando-se o valor de R ao quadrado, o objetivo de obter estes valores foi avaliar quais das variáveis elencadas conseguem explicar de boa maneira a variável de resposta. O Quadro 4 resume os valores obtidos.

Quadro 4 – Coeficientes de correlação e determinação

Teste	Parceiros	PIB	Juros	Câmbio
R^2	0,72	0,81	0,27	0,09
R	0,85	0,90	0,52	-0,30

Fonte: Elaborado pelo autor (2021)


A taxa de câmbio foi a variável que possuía a menor correlação dentre todas, sendo assim ela não foi elencada para montar o modelo, juntamente a taxa de juros, que também não obteve nenhum valor acima de 0,6, portanto ambas as variáveis foram excluídas do estudo por

serem consideradas insuficientes para serem aceitas.

As variáveis de Parceiros e PIB foram as melhores dentre os valores, possuindo uma covariância ótima e uma alta correlação de acordo com a recomendação de Moreira (2015), o que significa que ambas possuem o mesmo comportamento e variam no mesmo sentido ao avançar dos períodos, e, portanto, foram as únicas consideradas para compor o modelo.

O modelo será constituído de apenas 2 variáveis regressoras, que é um número menor do que as variáveis que foram consideradas nas pesquisas de Botelho (2020), Vidas et al. (2020) e Zhou et al. (2020). A Figura 8 mostra a visualização do comportamento das variáveis escolhidas para compor o modelo através do GRETL.

Figura 8 – Comportamento das variáveis escolhidas




Fonte: Elaborado pelo autor (2021)

4.3 MODELAGEM PREDITIVA

Foi utilizado do método MQO para escolher os valores de β para o modelo. A figura 9 mostra os valores obtidos na tela de resultados da modelagem, neste vale destacar que o coeficiente β_1 referente à variável parceiros é igual a 0,177387 e o coeficiente β_2 referente à

variável PIB tem o valor de 0,000220708.

Figura 9 – Resultado do modelo



	coeficiente	erro padrão	razão-t	p-valor	
Parceiros	0,177387	0,0349670	5,073	0,0002	***
PIB	0,000220708	3,64053e-05	6,063	4,02e-05	***

Média var. dependente	40,26667	D.P. var. dependente	25,19769
Soma resid. quadrados	2136,092	E.P. da regressão	12,81853
R-quad. não-centrado	0,935679	R-quadrado centrado	0,759691
F(2, 13)	94,55606	P-valor(F)	1,80e-08
Log da verossimilhança	-58,47420	Critério de Akaike	120,9484
Critério de Schwarz	122,3645	Critério Hannan-Quinn	120,9333


Fonte: Elaborado pelo autor (2021)

Sendo assim a Equação 5 demonstra a regressão obtida pelo GRETL.

$$\text{Solicitações} = \text{Parceiros} \cdot 0,177387 + \text{PIB} \cdot 0,000220708 \quad (5)$$

Com a Equação 5 a empresa pode realizar a previsão para alguns cenários futuros esperados pela empresa, visto que é preciso somente substituir o valor da variável parceiros pelo número esperado de parceiros no período desejado e substituir o valor da variável PIB pelo valor esperado do PIB para o próximo período. Os valores de parceiros podem ser obtidos por planejamento interno da empresa e o valor do PIB através de vários estudos mensais disponíveis para o mercado financeiro. Por exemplo, expectativa de um PIB de U\$ 143.000 milhões e 400 parceiros geraria uma demanda de 102 solicitações de crédito.

A Figura 10 demonstra o comportamento da regressão em relação ao histórico de solicitações.

Figura 10 – Comportamento da Regressão

Fonte: Elaborado pelo autor (2021)


O valor efetivo é aquele que corresponde aos valores reais e o valor ajustado se refere a previsão feita por RLM.

A previsão se ajusta muito bem aos dados, com exceção dos períodos relativos aos meses de iniciais e alguns meses no final de 2020, o que era esperado devido ao MQO, que tenta minimizar ao máximo o erro residual da previsão com os dados reais, e, portanto, ao errar prevendo valores acima que o real no começo da série ele compensa este erro errando prevendo valores abaixo do esperado nos períodos seguintes da série.

4.4 AVALIAÇÃO DO MODELO

Para a avaliação do modelo foi calculado o erro obtido em cada um dos períodos através do GRETL, que software é chamado de resíduo, os valores podem ser observados na Figura 11.

Figura 11 – Erros da regressão



The screenshot shows the 'gretl: apresentar dados' window. It displays the model estimation interval from 2020:04 to 2021:06 and the standard error of the regression as 12,8185. Below this, a table lists the observed values ('Solicitacoes'), the adjusted values ('ajustado'), and the residuals ('resíduo') for each time period from 2020:04 to 2021:06. At the bottom, a section titled 'Estatísticas de avaliação da previsão usando 15 observações' provides various performance metrics for the model's predictions.

	Solicitacoes	ajustado	resíduo
2020:04	1,00	23,00	-22,00
2020:05	1,00	21,93	-20,93
2020:06	32,00	25,23	6,77
2020:07	25,00	26,59	-1,59
2020:08	29,00	25,72	3,28
2020:09	23,00	27,56	-4,56
2020:10	40,00	29,40	10,60
2020:11	54,00	32,45	21,55
2020:12	33,00	35,90	-2,90
2021:01	31,00	35,20	-4,20
2021:02	47,00	38,72	8,28
2021:03	55,00	56,86	-1,86
2021:04	82,00	65,94	16,06
2021:05	64,00	78,18	-14,18
2021:06	87,00	87,53	-0,53

Estatísticas de avaliação da previsão usando 15 observações	
Erro Médio	-0,4141
Erro Unitário Médio Quadrado	11,933
Erro Absoluto Médio	9,2857
Erro Percentual Médio	-282,12
Erro Percentual Médio Absoluto	300,26
Theil's U2	0,70965

Fonte: Elaborado pelo autor (2021)

A Figura 7 demonstra o comportamento do erro de acordo com o tempo.

Figura 12 – Comportamento do erro

Fonte: Elaborado pelo autor (2021)

Os erros ficaram na média entre 25 solicitação para mais ou para menos. Para melhor compreender os erros, foram calculados em ambiente externo ao GRETL os indicadores CFE, MAD, MSE e MAPE, visto que o GRETL não tem disponível estes indicadores de erro. Os resultados são demonstrados no Quadro 5.

Quadro 5 – Indicadores de Erro

Erro	CFE	MAD	MSE	MAPE
Valor	-6,21	8,19	125,65	129,41

Fonte: Elaborado pelo autor (2021)


O método do MQO conseguiu entregar um CFE de -6,21, ou seja, a soma de todos os erros da previsão resultou em soma -6,2, o que é um bom sinal de qualidade para o modelo visto que é um valor pequeno em comparação à quantidade de operações já recebidas, já o valor do MAD demonstra que o modelo preditivo geralmente erra em 8,19 solicitações, o que é um

também é um bom valor, pois para Tubino (2007) o valor do erro acumulado não pode nunca ultrapassar o valor de 4 MAD. Quanto ao MSE, também foi obtido um bom resultado, visto que por mais que a previsão tenha errado os erros foram muito pequenos, ou seja, devido ao fato de não ter errado com valores muito grandes o MSE foi pequeno. E por fim o MAPE indicou que o modelo erra em média 129% das vezes, porém este indicador, que é bem didático, não costuma entregar bons resultados quando os valores reais do estudo variam muito ou são muito baixos, e ambas as situações ocorrem nos dados referentes a solicitações, e por isso ele não é útil para a avaliação do modelo.

Foi calculado também pelo GRETL o R^2 da previsão em relação aos dados, conforme a figura 9, e foi identificado que a RLM explica 75,96% dos valores reais, o que para Moreira (2015) é considerado que o modelo possui uma alta qualidade.

Para verificar o intervalo de confiança da RLM, foi plotado um gráfico com o intervalo de confiança de 95%, para verificar a segurança do modelo. O gráfico está presente na Figura 13.

Figura 13 – Intervalo de confiança da previsão



Fonte: Elaborado pelo autor (2021)

O IC conseguiu compreender por completo toda a adversidade do mundo real, e mesmo que sua margem inferior tenha ficado negativa por um período, pela natureza dos dados, qualquer resultado negativo deve ser interpretado como 0. Sendo assim o modelo consegue sim ser um bom modelo preditivo para a *fintech* estudada visto que o intervalo de confiança da previsão não foi ultrapassado durante todo o período estudado.

CAPÍTULO 5 - CONCLUSÕES

Este estudo foi capaz de identificar dentro de uma *fintech*, mais especificamente do setor de crédito, quais são os fatores que impactam o recebimento das suas solicitações de crédito, a identificação destes fatores se teve naturalmente durante o processo de modelagem de uma Regressão Linear Múltipla que tinha como objetivo prever a demanda futura das solicitações de crédito e auxiliar os gestores em suas decisões estratégicas. Por fim os resultados obtidos demonstraram que a RLM consegue sim explicar o comportamento da demanda de uma *fintech* mesmo com poucos períodos de informação.

De acordo com as especificidades pertencentes ao mercado financeiro, setor de crédito e ao modelo de funcionamento da *fintech*. Para o estudo foram elencados como possível influenciadores do modelo quatro variáveis, sendo elas: a quantidade de parceiros da empresa, o PIB do Brasil convertido em Dólar, a taxa de juros SELIC Over acumulado no mês e o Índice da taxa de câmbio efetivo real atualizada pelo IPCA. As amostras estavam compreendidas entre Abril de 2020 e Agosto de 2021. Após a visualização dos dados notou-se que os períodos março e abril de 2021 foram influenciados fortemente pela reabertura econômica devido a pandemia do COVID-19 e, portanto, foram removidos do conjunto de dados.

Foi definido como filtro das variáveis, que apenas aquelas que possuíssem um R e um R^2 acima de 0,6 seriam elencadas para compor a RLM, durante o processo de filtragem foi escolhido apenas a quantidade de parceiros e o PIB, sendo que ambos convergiam de acordo e positivamente.

O MQO foi utilizado como uma forma de estimar os coeficientes β que compõem a RLM, e para a aplicação deste método, foi utilizado do *software* GRETL, após elaborada a regressão foi comparada sua previsão com os dados reais e obteve-se um R^2 de 0,76, portanto a RLM demonstrou-se eficiente como um modelo de previsão para a demanda da empresa.

Para constatar a eficiência do modelo, foram calculados indicadores estatísticos de erros, sendo que o CFE demonstrou que o modelo era excelente, entregando o valor de -6,21, o MAD indicou que o modelo na média errou em 8,19 o número de solicitações, que para os dados da amostra e modelo de negócio se provou um bom resultado, já o MSE entregou um bom resultado beneficiado por uma grande quantidade de pequenos erros durante todo o período, validando novamente a alta qualidade do modelo, o indicador MAPE também foi calculado, porém foi desconsiderado na análise visto que a variação dos valores nos dados reais penalizaram fortemente o indicador. Por fim, concluiu-se que foi construído um bom modelo,

comprovado pelos valores dos indicadores utilizados.

Buscando aumentar a confiança do modelo, foi criado também através do GRETl um Intervalo de Confiança para a previsão, que compreendeu por completo toda a demanda real com 95% de confiança, confirmando novamente sua aderência aos dados reais e sua capacidade de explicar a demanda real.

O modelo em sua totalidade foi considerado importante para a empresa visto que ele pode ser facilmente utilizado pelos gestores, pois basta elencar alguns valores para as variáveis regressoras e multiplicar os coeficientes, os valores para os períodos futuros podem ser obtidos facilmente por estimativas já disponíveis pelo mercado ou por expectativas internas da empresa tornando o modelo fácil de ser implantado na empresa e com quase nenhum custo de manutenção.

Por mais que o modelo atualmente consiga explicar uma quantidade considerável da demanda da empresa, a metodologia utilizada para criá-lo permite que o modelo possa ser facilmente melhorado com a adição de outras variáveis, principalmente aquelas que são internas à empresa, e.g. Investimento em marketing ou taxa de estruturação, buscando entender como as ações da empresa podem influenciar melhor a demanda e aumentar a precisão do modelo.

Como contribuição teórica deste estudo, este visa enriquecer os poucos estudos referentes a *fintechs* no Brasil, fornecendo evidências matemáticas sobre os aspectos que podem influenciar diretamente o mercado de crédito. E em termos práticos, este visa auxiliar os gestores nas tomadas de decisão e na melhor compreensão do cenário em que a empresa atua, fazendo o uso de elementos estatísticos em comparação com suas experiências.

Confrontando as limitações e observações obtidas durante a realização deste estudo, surgem como demandas para os futuros estudos:

- Pesquisas mais aprofundadas sobre os fatores que impactam o mercado de crédito no Brasil;
- Estudos comparativos de técnicas de previsão para empresas consideradas como *fintechs* ou *startups*;
- Estudos comparativos da demanda de várias empresas do setor de crédito, abordando técnicas qualitativas e quantitativas;
- Pesquisas abordando outros segmentos no mercado financeiro.

REFERÊNCIAS

BACEN. **SGS - Sistema Gerenciador de Séries Temporais**. 2.1. [S. l.], 22 set. 2021. Disponível em: www3.bcb.gov.br/sgspub/. Acesso em: 22 set. 2021.

BALTAZAR, Ana Paula. A nova fronteira do crédito no Brasil: Pesquisa Fintechs de Crédito 2019. **PWC Brasil**, [S. l.], ano 2019, 19 set. 2019. Disponível em: <https://www.pwc.com.br/pt/estudos/setores-atividades/financeiro/2019/pesquisa-credito-digital-19-mobile.pdf>. Acesso em: 28 mar. 2021.

BERNARDELLI, Luan Vinicius; BERNARDELLI, Alessandro garcia; CASTRO, Gustavo Henrique Leite de. A INFLUÊNCIA DAS VARIÁVEIS MACROECONÔMICAS E DO ÍNDICE DE EXPECTATIVAS NO MERCADO ACIONÁRIO BRASILEIRO: UMA ANÁLISE EMPÍRICA PARA OS ANOS DE 1995 A 2015. **Gestão, Finanças e Contabilidade**, Salvador, ano 2017, v. 7, n. 1, p. 78-96, 16 jan. 2017. DOI 10.18028/2238-5320/rgfc.v7n1p78-96. Disponível em: <https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwjO0-HfgYHZAhWAD7kGHboODocQFnoECACQAQ&url=https%3A%2F%2Frevistas.uneb.br%2Findex.php%2Ffinanc%2Farticle%2Fdownload%2F2941%2F2028%2F&usq=AOvVaw3qPI3sP49U5nczUcxMiRvs>. Acesso em: 15 set. 2021.

BERNADELLI, Luan Vinicius; CASTRO, Gustavo Henrique Leite de. MERCADO ACIONÁRIO E VARIÁVEIS MACROECONÔMICAS: EVIDÊNCIAS PARA O BRASIL. **Revista Catarinense da Ciência Contábil**, Santa Catarina, ano 2020, v. 19, p. 1-15, 31 jan. 2020. DOI <https://doi.org/10.16930/2237-766220202892>. Disponível em: <https://www.redalyc.org/jatsRepo/4775/477562247001/477562247001.pdf>. Acesso em: 15 set. 2021.

BORGES, Francine da Silva; MATTOS, Viviane Leite Dias de. MODELO DE PREVISÃO PARA UMA SÉRIE TEMPORAL DE DADOS DE CABOTAGEM. In: ERMAC/RS, X., 2020, Rio Grande do Sul. **Anais do X Encontro Regional de Matemática Aplicada e Computacional do Rio Grande do Sul – ERMAC-RS [...]**. [S. l.]: PUC-RS, 2020. ISBN: 978-65-5623-103-7. Disponível em: <https://editora.pucrs.br/edipucrs/acessolivre/anais/1501/assets/edicoes/2020/arquivos/76.pdf>. Acesso em: 15 nov. 2021.

BOTELHO, Alex Monteiro. FATORES QUE IMPACTAM A DEMANDA DE BENS DE CONSUMO DURÁVEIS: UM ESTUDO EM UMA INDÚSTRIA DE UTILIDADE DOMÉSTICA. **Dissertação (Mestrado em Administração) – Universidade Estácio de Sá**, Rio de Janeiro, p. 1-97, 1 jan. 2020. Disponível em: <https://portal.estacio.br/media/4684503/alex-monteiro-botelho.pdf>. Acesso em: 20 jun. 2021.

COTTRELL, Allin; LUCHETTI, Riccardo Jack. **GRETTL: Gnu Regression, Econometrics and Time-series Library**. [S. l.], 18 jan. 2021. Disponível em: <http://gretl.sourceforge.net/index.html>. Acesso em: 2 abr. 2021.

DE CARVALHO, José Ribamar Marques et al. Análise Multicriterial da Competitividade

Empresarial sob tríplice perspectiva: Financeira, Governança Corporativa e Sustentabilidade. **Revista de Globalización, Competitividad y Gobernabilidad**, v. 13, n. 2, 2019. Disponível em: <https://dialnet.unirioja.es/descarga/articulo/7007428.pdf>. Acesso em: 25 mar. 2021.

FITZSIMMONS, James A.; FITZSIMMONS, Mona J. **Administração de serviços**. 7. ed. Porto Alegre: AMGH, 2014. 535 p. ISBN 978-85-8055-328-4.

HAIR, J. F. et al. **Análise Multivariada de Dados**. 6. ed. São Paulo: Bookman, 2009.

JONES, Frances. A onda das fintechs: Popularização de startups financeiras que utilizam recursos tecnológicos de forma intensiva movimentam o setor bancário. **Pesquisa Fapesp**, [S. l.], ano 2020, n. 288, 1 fev. 2020. Disponível em: <https://revistapesquisa.fapesp.br/a-onda-das-fintechs/>. Acesso em: 28 mar. 2021.

KALAY, Marcio El. O que é compliance? tudo que você precisa saber!. **Legal Ethics Compliance**, [S. l.], p. 1, 22 maio 2018. Disponível em: <https://lec.com.br/blog/o-que-e-compliance/>. Acesso em: 6 maio 2021.

MARI, Gustavo De. Previsão de demanda: O guia Definitivo. **Providentia**, [S. l.], p. 1, 21 fev. 2017. Disponível em: <https://www.providentia.com.br/blog/previsao-de-demanda-o-guia-definitivo/>. Acesso em: 30 mar. 2021.

MELLO, Daniel. Procura dos consumidores por crédito cresce 26% no primeiro semestre. **Agência Brasil**, São Paulo, p. 1, 28 jul. 2021. Disponível em: <https://agenciabrasil.ebc.com.br/economia/noticia/2021-07/procura-dos-consumidores-por-credito-cresce-26-no-primeiro-semester-0>. Acesso em: 15 nov. 2021.

MENEZES, Breno; VALENÇA, Mêuser. CONSTRUINDO INTERVALOS DE CONFIANÇA NA PREVISÃO DA POTÊNCIA DO VENTO UTILIZANDO RESERVOIR COMPUTING. **SBIC**, [S. l.], p. 1-6, 7 jun. 2013. DOI 10.21528/CBIC2013-238. Disponível em: http://abricom.org.br/wp-content/uploads/2016/03/bricccicbic2013_submission_238.pdf. Acesso em: 19 jun. 2021.

MENEZES, Karina. **Os maiores desafios das fintechs brasileiras**. [S. l.], 26 fev. 2020. Disponível em: <https://blog.idwall.co/os-maiores-desafios-das-fintechs-brasileiras/>. Acesso em: 28 mar. 2021.

MOREIRA, Daniel Augusto. **Administração da Produção e Operações**. 2. ed. rev. e aum. São Paulo: Cengage Learning, 2015. 625 p. ISBN 978-85-221-0587-8.

MOȘTEANU, Narcisa Roxana. Challenges for Organizational Structure and design as a result of digitalization and cybersecurity. **The Business & Management Review**, v. 11, n. 1, p. 278-286, 2020. Disponível em: https://www.researchgate.net/profile/Hany-Hanna-2/publication/344793035_TOE_Model_Adoption_of_Block_Chain/links/5fecdaf1a6fdccdb81ad7e3/TOE-Model-Adoption-of-Block-Chain.pdf#page=288. Acesso em: 25 mar. 2021.

OLIVEIRA, Maria Clara de Melo; MILANI, Eder Angelo; SILVA, Josney Freitas. A ESTATÍSTICA COMO FERRAMENTA PARA AUXILIAR A TOMADA DE DECISÃO

EM UMA PEQUENA EMPRESA: O USO DA REGRESSÃO LINEAR MÚLTIPLA E O SOFTWARE R. **Revista FAFIBE on-line**, [S. l.], ano 2019, v. 12, n. 1, p. 38-55, 25 nov. 2019. Disponível em:

<https://www.unifafibe.com.br/revista/index.php/fafibeonline/article/view/726>. Acesso em: 2 abr. 2021.

PRADO, Tatiana. **Saiba quais são os benefícios da previsão de demanda e qual é a sua importância**: Entenda qual é o impacto da previsão de demanda em uma empresa e como ela pode ser fundamental para a gestão de estoque e para o PCP.. [S. L.], 29 jun. 2020. Disponível em: <https://www.voitto.com.br/blog/artigo/previsao-de-demanda>. Acesso em: 27 mar. 2021.

REDAÇÃO NUBANK. O que é fintech e por que esse termo ficou tão popular?: Empresas oferecem soluções mais simples e baratas para a população. **Blog Nubank**, [S. l.], p. 1, 17 mar. 2020. Disponível em: <https://blog.nubank.com.br/fintech-o-que-e/>. Acesso em: 2 nov. 2021.

REIS, Tiago. Mercado de Crédito: como funciona? Para que serve?. **Suno Artigos**, [S. l.], p. 1, 1 dez. 2017. Disponível em: <https://www.suno.com.br/artigos/mercado-de-credito/>. Acesso em: 10 maio 2021.

SCHMOLLER, Lindomar et al. Pesquisa Deep Dive Fintech 2020. **PWC Brasil**, [S. l.], p. 1-19, 23 out. 2020. Disponível em: https://www.pwc.com.br/pt/publicacoes/setores-atividade/assets/financeiro/2021/pesquisa_deep_dive_fintech_2020_23_dez2020.pdf. Acesso em: 6 maio 2021.

SILVA, João Pedro Fontoura da. O Método dos Mínimos Quadrados Ordinários e Regressão Linear Simples. **LAMFO**, [S. l.], p. 1, 7 fev. 2020. Disponível em: <https://lamfo-unb.github.io/2020/02/07/O-M%C3%A9todo-dos-M%C3%ADnimos-Quadrados-Ordin%C3%A1rios-e-Regress%C3%A3o-Linear-Simples/>. Acesso em: 2 abr. 2021.

SZAJMAN, Abram; MARTINS, Ives Gandra da Silva. Competitividade no sistema financeiro, por Abram Szajman e Ives Gandra da Silva Martins: Artigo analisa os impactos da falta de concorrência bancária no desenvolvimento nacional. **FECOMERCIO**SP, São Paulo/SP, ano 2019, p. 1, 27 maio 2019. Disponível em: <https://www.fecomercio.com.br/conselhos/conselho-superior-de-direito/noticias/competitividade-no-sistema-financeiro-por-abram-szajman-e-ives-gandra-da-silva-martins>. Acesso em: 25 mar. 2021.

TUBINO, Dalvio Ferrari. **Manual de planejamento e controle da produção**. 2. ed. São Paulo: Atlas, 2000. 220 p. ISBN 85-224-2426-8.

VIDAS, Lucas Bonini et al. Modelo de previsão de demanda de uma autopeça fornecedora para o setor de máquinas agrícolas. **XV SIMPÓSIO DOS PROGRAMAS DE MESTRADO PROFISSIONAL UNIDADE DE PÓS-GRADUAÇÃO, EXTENSÃO E PESQUISA**, São Paulo, ano 2020, n. XV, p. 893-902, 12 nov. 2020. Disponível em: <http://www.pos.cps.sp.gov.br/files/artigo/file/952/c6439f716289afdc07ff4057b671529f.pdf>. Acesso em: 20 jun. 2021.

ZHOU, Beifen et al. Demand Forecast of New Retail Target Products based on Multiple Linear Regression. **Academic Journal of Business & Management**, [S. l.], ano 2020, v. 2, 1 jan.

2020. 5, p. 114-118. DOI 10.25236/AJBM.2020.020512. Disponível em: <https://francispress.com/papers/2625>. Acesso em: 20 jun. 2021.

ATA DE SESSÃO PÚBLICA DE APRESENTAÇÃO DE TRABALHO DE CONCLUSÃO DE CURSO

No dia 03/12/2021, às 07:15 horas, o (a) estudante Isaque Marques Pascoal, do curso de Engenharia de Produção da Pontifícia Universidade Católica de Goiás, expôs, em Sessão Pública de Apresentação de Trabalho de Conclusão de Curso, o trabalho intitulado Previsão de demanda em uma fintech por meio do método da regressão linear múltipla para a Banca de Avaliação composta pelos (as) docentes:

Prof. Me. Vitor Hugo Martins e Resende (Orientador), Prof. Dr. Ricardo Caetano Rezende e Prof. Me. Santiago Meireles Rocha.

O trabalho da Banca de Avaliação foi conduzido pelo (a) docente Presidente que, inicialmente, após apresentar os docentes integrantes da Comissão, concedeu 20 minutos ao (a) estudante (a) para que este (a) expusesse o trabalho. Após a exposição, o (a) docente Presidente concedeu a palavra a cada membro convidado da Comissão para que estes arguissem o (a) estudante. Após o encerramento das arguições, a Banca de Avaliação, reunida isoladamente, avaliou o trabalho desenvolvido e o desempenho do (a) estudante na exposição, considerada a trajetória deste (a) no desenvolvimento do TCC. Como resultado da avaliação, a Banca de Avaliação deliberou pela:

() Aprovação.

(X) Aprovação, condicionado às correções recomendadas pelos membros da banca.

() Reprovação.

Aprovação, condicionado às correções recomendadas pelos membros da banca.

A Banca de Avaliação conclui que o(a) estudante está **APROVADO(A) condicionado às correções** de forma e/ou conteúdo **recomendados**. As correções deverão ser indicadas no formulário de Avaliação Final de Trabalho de Conclusão de Curso. O(A) estudante terá o prazo de 7 dias para os ajustes e entrega da versão final ao professor (a) orientador (a), contado a partir da data da sessão de apresentação pública do TCC.

FORMULÁRIO DE AVALIAÇÃO FINAL DE TRABALHO DE CONCLUSÃO DE CURSO

Nome do estudante: Isaque Marques Pascoal

Título do TCC: Previsão de demanda em uma fintech por meio do método da regressão linear múltipla

CRITÉRIOS DE AVALIAÇÃO DA APRESENTAÇÃO DO TCC (Av1: Presidente da Banca Avaliadora, Av2 e Av3: Membros Convidados da banca avaliadora)	Av1	Av2	Av3
SOBRE O TRABALHO ESCRITO	5,5	5,5	5,5
Sub-total (6,0)			
SOBRE APRESENTAÇÃO ORAL	2,0	2,0	2,0
Sub-total (2,0)			
SOBRE SUSTENTAÇÃO ARGUIÇÃO PELA BANCA	2,0	2,0	2,0
Sub-total (2,0)			
Nota final da Banca			
Nota do Av1		9,5	
Nota do Av2		9,5	
Nota do Av3		9,5	
Média das notas dos membros da banca examinadora		9,5	

Correções recomendadas:

Acrescentar dados quantitativos no resumo, revisar sumário, eliminar resultados esperados, explicar o porque não utilizou o IOR, destacar variáveis por 38, somar previsão de lucro com as limitações da questão 5, explicar IPCA, acrescentar palavra "ótimo" na conclusão.

Nome (por extenso) e assinatura do Membro Presidente da Banca Avaliadora (Av1):

VITOR HUGO MARTINS E RESENDE

Me. Vitor Hugo Martins e Resende

[Assinatura]

Assinatura Membro Presidente

Nome (por extenso) e assinatura do Membro Convidado da Banca Avaliadora (Av2):

Ricardo Caetano Rezende

Dr. Ricardo Caetano Rezende

[Assinatura]

Assinatura do Membro Convidado

Nome (por extenso) e assinatura do Membro Convidado da Banca Avaliadora (Av3):

Santiago Meireles Rocha

Me. Santiago Meireles Rocha

[Assinatura]

Assinatura do Membro Convidado

Reprovação.

A Banca de Avaliação conclui que o trabalho apresentado não satisfaz as condições mínimas e o estudante está **REPROVADO(A)**.

A Banca Avaliadora:

Membro Presidente da Banca Avaliadora:

Membro Convidado da Banca Avaliadora:

Membro Convidado da Banca Avaliadora: