

Forecast & Provisão de Curvas de PECLD

Tema: Recuperação de crédito - Inadimplência

Autores: Kleber José de Moura Junior

Co-Autores: Thiago De Jesus Costa; Maria Fatima Costa De Souza

Empresa: EDP São Paulo Distribuição de Energia S.A

Resumo

O projeto visa desenvolver um modelo preditivo para a provisão das Perdas Estimadas em Crédito de Liquidação Duvidosa (PECLD), utilizando contabilidade, macroeconomia, microeconomia, big data e machine learning. O objetivo é melhorar a precisão das previsões orçamentárias, garantindo uma gestão financeira eficiente e minimizando perdas de receita. Baseado nas normas CPC 47 (IFRS 15) e CPC 48 (IFRS 9), o projeto assegura conformidade regulatória e precisão nas demonstrações financeiras. Aplicado ao setor de distribuição de energia, regulamentado pela ANEEL, o modelo preditivo integrará diversas áreas do conhecimento para entender os fatores de inadimplência e utilizará machine learning para prever com precisão os valores de PECLD, permitindo uma alocação eficiente de recursos e melhorando a saúde financeira da empresa.

1. Introdução

Desde o ano de 2010, o Brasil passou a adotar as normas do International Financial Reporting Standard (IFRS), especificamente a IAS 39, que se refere a um conjunto de normas contábeis amplamente aceitas globalmente. A IAS 39, no contexto da Perdas Estimadas em Crédito de Liquidação Duvidosa (PECLD), permite que as instituições financeiras estimem as perdas por redução ao valor recuperável de ativos, considerando todas as exposições ao crédito, e não apenas aquelas de baixa qualidade. Este alinhamento com os padrões internacionais foi um passo importante para aumentar a transparência e a comparabilidade das demonstrações financeiras brasileiras.

Com a evolução das normas contábeis, a IAS 39 foi substituída pela IFRS 9, que foi adotada no Brasil como CPC 48. A IFRS 9 introduziu o conceito de "perdas esperadas", exigindo que as instituições financeiras reconheçam perdas de crédito esperadas desde o momento em que os ativos financeiros são inicialmente reconhecidos. Este modelo de perdas esperadas representa uma mudança significativa em relação ao modelo anterior de "perdas incorridas", proporcionando uma abordagem mais proativa e preventiva na gestão de riscos de crédito. Paralelamente, a IFRS 15, adotada no Brasil como CPC 47, foi introduzida para tratar do reconhecimento de receita de contratos com clientes. Esta norma estabelece um modelo abrangente para determinar quando e como a receita deve ser reconhecida, substituindo uma série de normas e interpretações anteriores. A IFRS 15, emitida em maio de 2014 e em vigor desde janeiro de 2018, trouxe uma abordagem de cinco etapas para o reconhecimento de receita, que inclui a identificação

do contrato, a identificação das obrigações de desempenho, a determinação do preço da transação, a alocação do preço da transação às obrigações de desempenho e o reconhecimento da receita quando (ou à medida que) a entidade satisfaz uma obrigação de desempenho.

No Brasil, a adoção dessas normas é essencial para garantir a conformidade regulatória e a precisão das demonstrações financeiras. A Agência Nacional de Energia Elétrica (ANEEL) desempenha um papel crucial na regulamentação do setor de distribuição de energia, estabelecendo diretrizes rigorosas para a operação e gestão financeira das distribuidoras. A conformidade com as normas CPC 47 e CPC 48 é fundamental para que as empresas do setor de energia possam operar de maneira sustentável e eficiente, atendendo às exigências regulatórias e assegurando a transparência financeira. A ANEEL, criada em 1996, é responsável por regular e fiscalizar a produção, transmissão, distribuição e comercialização de energia elétrica no Brasil. A agência tem como missão proporcionar condições favoráveis para que o mercado de energia elétrica se desenvolva com equilíbrio entre os agentes e em benefício da sociedade. Nesse contexto, a adoção das normas CPC 47 e CPC 48 pelas distribuidoras de energia é vital para garantir a transparência e a confiança dos investidores e consumidores no setor elétrico brasileiro, proporcionando uma visão mais precisa e transparente de sua saúde financeira e de seus riscos de crédito.

Diante da atual situação econômico-financeira do país, é extremamente relevante atentar para este assunto. A economia brasileira enfrenta desafios significativos, incluindo altas taxas de inadimplência e volatilidade econômica. A crise econômica, agravada pela pandemia de COVID-19, resultou em um aumento da inadimplência e em uma maior necessidade de provisões para perdas de crédito. Nesse contexto, a adoção das normas CPC 47 (IFRS 15) e CPC 48 (IFRS 9) no Brasil representa um avanço significativo na transparência e na comparabilidade das demonstrações financeiras. A conformidade com essas normas é essencial para a sustentabilidade financeira das instituições financeiras e das empresas de distribuição de energia, especialmente em um ambiente econômico desafiador. A adoção dessas práticas contábeis robustas não apenas fortalece a posição das empresas no mercado nacional, mas também as prepara para competir e prosperar no cenário global. Além disso, a integração de técnicas de machine learning e a aplicação de conceitos de macroeconomia e microeconomia podem proporcionar um estudo mais robusto e detalhado, permitindo uma análise mais precisa e abrangente dos fatores que influenciam a inadimplência e a saúde financeira das instituições. O uso de machine learning, por exemplo, pode ajudar a identificar padrões complexos e prever a probabilidade de inadimplência com maior precisão, enquanto a análise macroeconômica e microeconômica pode fornecer insights valiosos sobre as condições econômicas gerais e o comportamento dos agentes econômicos, respectivamente. Dessa forma, a combinação dessas abordagens pode melhorar significativamente a capacidade das instituições de gerenciar riscos e tomar decisões informadas, contribuindo para a estabilidade e o crescimento sustentável no longo prazo.

2. Desenvolvimento

O desenvolvimento de um modelo de previsão orçamentária assertiva para PECLD requer uma abordagem interdisciplinar que integra contabilidade, macroeconomia, microeconomia, big data e machine learning. Por ser um projeto interdisciplinar, a estrutura do projeto é fundamental para garantir a coerência e a sistematicidade do processo de desenvolvimento. A definição clara dos objetivos específicos, a descrição detalhada das fases do projeto e a identificação das principais fontes de dados e ferramentas analíticas são essenciais para uma abordagem organizada e eficiente. A metodologia adotada deve ser rigorosa, permitindo a replicabilidade e a validação dos resultados obtidos.

Para assegurar a organização e a eficiência do projeto interdisciplinar , foi utilizado a metodologia ágil Scrum, que permitiu dividir o projeto em sprints, que são ciclos de trabalho curtos e iterativos, garantindo que cada etapa fosse claramente definida e que os prazos fossem estabelecidos de maneira realista. A aplicação desta metodologia facilitou a coordenação das atividades e o monitoramento do progresso, assegurando que o projeto fosse conduzido de forma estruturada e eficiente. Desta forma, a estrutura do projeto conforme a metodologia Scrum foi:

1. **Kick-off:** Reunião de kick-off para alinhar todos os detalhes sobre os objetivos do projeto, a metodologia a ser utilizada e as expectativas de cada fase. Esta reunião inicial foi crucial para garantir que todos estivessem na mesma página e comprometidos com o sucesso do projeto.
2. **Recuperação de Receita e Faturamento** (levantamento dos dados): Definição do escopo e os objetivos específicos para a coleta de dados. Identificamos as principais fontes de dados e estabelecemos as tarefas necessárias para completar esta fase.
3. **Mercado - Micro e Macroeconomia:** Análise econômica - macroeconômica e microeconômica. Utilizamos ferramentas analíticas para coletar e analisar dados econômicos relevantes.
4. **Provisão de Curvas de PECLD:** Desenvolvimento da metodologia e lógica da provisão de curvas de PECLD. Estabelecemos os critérios de sucesso e as métricas para avaliar a precisão dos modelos preditivos.
5. **Modelo de Machine Learning:** Desenvolvimento dos modelos de machine learning a serem utilizados, o processo de treinamento e validação dos modelos.
6. **Forecast Orçamentário e Cenários:** Geração das previsões orçamentárias em função do provisionamento PECLD e criação de cenários distintos econômicos para simulação de cenários.
7. **Sprint Retrospective:** Após a conclusão de cada sprint, realizamos uma retrospectiva para avaliar o que funcionou bem, o que pode ser melhorado e como podemos aplicar essas lições aprendidas nos sprints futuros.

A integração de contabilidade, economia, big data e machine learning neste projeto proporcionou uma ferramenta poderosa para a gestão financeira, com impacto significativo na precisão das previsões orçamentárias e na redução das perdas de receita. A adoção desta abordagem inovadora não apenas melhorou a eficiência operacional, mas também fortaleceu a resiliência financeira da empresa em um ambiente econômico dinâmico e desafiador.



Figura 1- Metodologia

Com a estrutura do projeto definida pela metodologia ágil Scrum, cada etapa foi cuidadosamente planejada e executada para garantir a eficiência e a precisão dos resultados. A seguir, detalharemos os principais tópicos segmentados conforme os sprints estabelecidos, abordando desde o levantamento de dados até a geração de previsões orçamentárias e a criação de cenários econômicos. Esta segmentação permitiu uma

abordagem iterativa e colaborativa, essencial para o sucesso do desenvolvimento do modelo de previsão orçamentária para PECLD.

1. *Recuperação de Receita e Faturamento*

A recuperação de receita é um aspecto crítico para a sustentabilidade financeira das empresas de distribuição de energia. A análise detalhada do histórico de recuperação de receita permite identificar áreas de melhoria e implementar estratégias para aumentar a eficiência na recuperação de valores devidos. Além disso, a análise de faturamento fornece insights valiosos sobre o comportamento de consumo dos clientes, permitindo a identificação de padrões de consumo irregulares que podem indicar fraudes ou outros problemas.

A etapa de Recuperação de Receita e Faturamento é a fase inicial do processo de coleta de dados, o qual é essencial para a construção da análise de provisionamento de PECLD. Nesta fase, são realizadas análises minuciosas de todo o histórico de recuperação de receita e faturamento, utilizando contas contábeis específicas e aplicando filtros de negócio específicos. A importância desta análise reside na sua capacidade de fornecer uma base sólida, detalhada e representativa para o estudo subsequente de provisionamento de PECLD.

A análise de dados nesta etapa é fundamentalmente data-driven, utilizando técnicas de big data para processar e analisar grandes volumes de informações. A abordagem data-driven permite uma compreensão mais profunda e precisa dos padrões de recuperação de receita e inadimplência, facilitando a identificação de tendências e anomalias que podem impactar o provisionamento de PECLD. A utilização de big data é crucial, pois permite a integração e análise de dados de diversas fontes, proporcionando uma visão holística e detalhada do comportamento dos consumidores e das receitas.

Para uma melhor segmentação do provisionamento, clusterização dos clientes foram divididas em três segmentos: Classe, Tensão e Consumo. A categoria Classe refere-se à classificação dos consumidores, que pode incluir, por exemplo, consumidores residenciais, comerciais e industriais. A categoria Tensão diz respeito ao nível de tensão elétrica fornecida aos consumidores, que pode variar de baixa a alta tensão. A categoria Consumo abrange tanto os consumos devidos a consumidores regulares quanto a consumidores irregulares de energia.

A segmentação dos dados em Classe, Tensão e Consumo é essencial para a construção de uma matriz de provisionamento precisa e eficaz. Ao segmentar os dados, é possível identificar padrões específicos de inadimplência e recuperação de receita em diferentes grupos de consumidores, permitindo a aplicação de estratégias de provisionamento mais direcionadas e eficazes. Por exemplo, consumidores industriais de alta tensão podem apresentar padrões de inadimplência diferentes dos consumidores residenciais de baixa tensão, e essas diferenças devem ser levadas em consideração na análise de provisionamento.

Em resumo, a etapa de Recuperação de Receita e Faturamento é fundamental para o sucesso do estudo de provisionamento de PECLD. A análise detalhada e segmentada dos dados, utilizando técnicas de big data, permite uma compreensão profunda dos padrões de recuperação de receita e inadimplência, proporcionando uma base sólida para a construção de uma matriz de provisionamento precisa e eficaz. Esta abordagem inovadora não apenas melhora a eficiência operacional, mas também fortalece a resiliência financeira da empresa em um ambiente econômico dinâmico e desafiador.

2. *Mercado - Micro e Macroeconomia*

A análise do mercado atual e a previsão futura são etapas cruciais para o provisionamento PECLD. Nesta seção, abordaremos os principais indicadores macro e microeconômicos que influenciam a inadimplência de crédito, tais como IPCA, IGP-M, TJLP, TLP, Selic, Risco-Brasil, Taxa de Desemprego (PNAD), Nível de Emprego, PIB, entre outros. A partir desses dados, é possível estipular a inadimplência de crédito livre tanto

para pessoas físicas quanto jurídicas, permitindo uma análise detalhada do comportamento do mercado de crédito. A compreensão da curva de inadimplência passa pela análise do ciclo do mercado de crédito e seus principais indicadores.

A composição dos indicadores econômicos influencia diretamente a inadimplência de crédito, com alguns indicadores exercendo um impacto maior e outros, menor. Por exemplo, a taxa Selic não explica completamente a relação de causa e efeito sobre a inadimplência, mas oferece uma visão sobre a dinâmica temporal das séries. A taxa de juros ao crédito livre responde com defasagem ao ciclo de alta da Selic, a inadimplência por sua vez, coincide temporalmente com as oscilações das taxas de juros, mas a causalidade não é direta. O movimento de alta da inadimplência geralmente começa após o aumento dos juros, mas tende a cair um pouco antes da redução das taxas.



Figura 2 - Taxa Selic X Inadimplência

Quando o Banco Central eleva a taxa de juros, o impacto no mercado de crédito ocorre com alguma defasagem. O encarecimento do crédito e a desaceleração da atividade econômica resultam em um aumento da inadimplência. Na fase de saída do ciclo, a inadimplência começa a diminuir antes, pois as condições restritivas impedem o aumento adicional do endividamento, forçando as famílias a desalavancar seus orçamentos.




Figura 3 - Taxa Selic X comprometimento de Renda

Através dessas análises e outras, é possível estipular a inadimplência de crédito livre de pessoa física e jurídica. Esse processo resulta em uma função degrau, onde diferentes níveis de inadimplência são penalizados de forma crescente, com os débitos mais antigos recebendo punições mais severas. Essa abordagem permite uma avaliação mais precisa e justa do risco de crédito, ajustando as provisões de acordo com a antiguidade das dívidas e a evolução dos indicadores econômicos.

Em resumo, a análise dos dados de mercado e a previsão futura são essenciais para entender o comportamento da inadimplência de crédito. A dinâmica das taxas de juros, o comprometimento de renda das famílias e as condições econômicas gerais influenciam diretamente a inadimplência, que tende a se estabilizar em níveis elevados devido ao cenário econômico atual.

3. *Provisão de Curvas de PECLD*

A PECLD é um componente essencial das demonstrações financeiras, especialmente no contexto das normas contábeis internacionais CPC 47 (IFRS 15) e CPC 48 (IFRS 9) como mencionado anteriormente. Estas normas fornecem diretrizes para o reconhecimento de receita e a mensuração de instrumentos financeiros, respectivamente, e são fundamentais para garantir a precisão e a transparência das provisões.

Para a provisão de curvas de PECLD, levantamos dados de negócio e utilizamos uma abordagem de perda esperada em um horizonte de cinco anos. Isso significa que as perdas são reconhecidas ao longo de um período de cinco anos, refletindo uma visão de longo prazo sobre a inadimplência. Coletamos dados históricos e atuais sobre o comportamento de pagamento dos clientes, incluindo informações sobre inadimplência e recuperação de receita. Com base nesses dados, traçamos uma curva que representa o comportamento de perdas de receita ao longo dos anos. Esta curva é ajustada para refletir as expectativas futuras.




Figura 4 - Curva de Perdas de Receita

Desenvolvemos uma matriz de provisionamento que indica a probabilidade de perda de receita em cada período (mês). Esta matriz é construída aplicando dados de negócio e de mercado para simular a movimentação econômica. Utilizamos dados macroeconômicos e microeconômicos para simular diferentes cenários econômicos e avaliar seu impacto nas perdas de receita. Isso nos permite ajustar a matriz de provisionamento para refletir as condições econômicas variáveis.

A aplicação desta metodologia, em conformidade com as normas CPC 47 e CPC 48, assegura que as provisões para PECLD sejam calculadas de maneira consistente e transparente. A integração de dados de negócio e de mercado permite uma visão abrangente e detalhada dos padrões de inadimplência, enquanto a utilização de técnicas avançadas de machine learning melhora a precisão das previsões. Esta abordagem inovadora não apenas melhora a eficiência operacional, mas também fortalece a resiliência financeira da empresa em um ambiente econômico dinâmico e desafiador.

4.

Nesta etapa, foram construídos dois modelos de machine learning com o objetivo de analisar e prever a inadimplência de crédito, utilizando dados de mercado macro e microeconômicos. Esses modelos são fundamentais para o provisionamento de PECLD e para a previsão de orçamento em diferentes cenários econômicos e de negócios. O primeiro modelo de machine learning foi desenvolvido para encontrar a curva de provisionamento que melhor se adequa aos dados, ou seja, uma curva fit. Este modelo visa suavizar a curva de inadimplência, permitindo descrever valores esperados, matriz e perdas PECLD que resultam na probabilidade de perder receita ao longo de cinco anos. Os dados de input para este modelo incluem tanto dados de negócios quanto dados de mercado econômico.

Para construir este modelo, utilizamos técnicas de regressão. Existem diversos tipos de regressão, as quais se destacam são a Regressão Linear Simples, logística e a Polinomial. Os modelos de regressão linear ou logística são ótimos para aprender fenômenos simples, nos quais as variáveis interagem de forma linear. Infelizmente, quase nenhuma relação que observamos no mundo é linear, principalmente as de interesse das ciências humanas. Regressões polinomiais são extensões dos modelos lineares, a partir da adição de preditores extras e pesos que são obtidos ao elevar cada um dos preditores originais a uma potência. Essa abordagem nos trás uma forma simples de ajustar ou “fitar” uma não linearidade aos dados. Por exemplo: Numa regressão cúbica seriam usados três variáveis, X , X^2 e X^3 como preditor, desta forma equação da regressão polinomial pode ser escrita da seguinte forma:

$$\hat{y}_{w,b} = f_{w,b}(x) = (w_1 \cdot x_1) + (w_2 \cdot x_2^2) + (w_3 \cdot x_3^3) + \dots + (w_n \cdot x_n^k) + (b) \quad (1)$$

Entretanto, como as variáveis interagem de forma não linear, a equação também pode ser:

$$\hat{y}_{w,b} = f_{w,b}(x) = \sum_{j=1}^n (w_n) \cdot (\cos x_n) + (b_n) \quad (2)$$

Ou

$$\hat{y}_{w,b} = f_{w,b}(x) = \sum_{j=1}^n (w_n) \cdot (\log x_n) + (b_n) \quad (3)$$

onde:

- \hat{y} é o valor previsto;
- n é o número de características;
- x_i é o valor da i -ésima característica;
- b é o coeficiente linear, valor onde a reta corta o eixo das ordenadas (y);
-

w_i é o peso da i -ésima característica.




Figura 5 - Representação Fit Curva

Ou seja, não existe apenas uma forma para equação da regressão polinomial, pois ela tem uma característica não linear. Desta forma, a equação vai depender muito do ajuste e da dispersão dos dados. Entretanto, é preciso lembrar que, teoricamente, podemos aproximar qualquer função com um polinômio, permitindo capturar relações mais complexas entre as variáveis.




Figura 6 - Curva Real X Ajuste da Curva Fit

O segundo modelo de machine learning utiliza as probabilidades geradas pelo primeiro modelo (matriz, esperada e perdas) para fazer um forecast de orçamento em diferentes cenários econômicos e de negócios. Este modelo é essencial para a tomada de decisões estratégicas, permitindo prever o impacto de diferentes

condições econômicas e de mercado sobre a inadimplência e o orçamento. Para este modelo, utilizamos técnicas de machine learning específicas para previsão (forecasting), com destaque para o modelo ARIMA (AutoRegressive Integrated Moving Average). O ARIMA é um modelo estatístico que captura a autocorrelação nos dados de séries temporais, ajustando componentes autorregressivos e de médias móveis. Ele é particularmente eficaz para dados que exibem padrões sazonais e tendências ao longo do tempo.

O modelo ARIMA foi treinado e validado utilizando técnicas de validação cruzada e métricas de performance específicas para previsão, como o erro absoluto médio (MAE) e o erro quadrático médio (MSE). A validação cruzada foi aplicada para garantir a robustez do modelo e sua capacidade de generalização. A implementação dos modelos foi realizada utilizando bibliotecas de machine learning como Scikit-Learn e statsmodels, que oferecem ferramentas robustas para construção, treinamento e validação de modelos. A análise dos resultados mostrou que os modelos foram capazes de capturar a dinâmica da inadimplência de crédito e prever com precisão os impactos de diferentes cenários econômicos.

Em resumo, a construção desses dois modelos de machine learning permite uma análise detalhada e precisa do provisionamento de PECLD, utilizando dados de mercado macro e microeconômicos. Através da suavização da curva de provisionamento e da previsão de orçamento em diferentes cenários, é possível tomar decisões informadas e estratégicas para mitigar riscos.

5.

Considerações Finais

O desenvolvimento de um modelo de previsão orçamentária assertiva para PECLD demonstrou a importância de uma abordagem interdisciplinar. A utilização da metodologia ágil Scrum foi fundamental para garantir a organização e a eficiência do projeto, permitindo uma divisão clara das etapas e um monitoramento contínuo do progresso. Cada fase do projeto desempenhou um papel crucial na construção de um modelo robusto e preciso para o provisionamento de PECLD. A fase inicial de Recuperação de Receita e Faturamento forneceu uma base sólida de dados, essencial para a análise subsequente. Através de uma análise detalhada e segmentada dos dados, utilizando técnicas de big data, foi possível identificar padrões de recuperação de receita e inadimplência, fundamentais para a construção de uma matriz de provisionamento precisa e eficaz.

A análise de Mercado - Micro e Macroeconomia foi a etapa seguinte, onde os principais indicadores econômicos que influenciam a inadimplência de crédito foram examinados. A compreensão da dinâmica das taxas de juros, do comprometimento de renda das famílias e das condições econômicas gerais permitiu ajustar as provisões de acordo com a antiguidade das dívidas e a evolução dos indicadores econômicos. Esta análise foi crucial para estipular a inadimplência de crédito livre tanto para pessoas físicas quanto jurídicas.

Na fase de Provisão de Curvas de PECLD, a integração dos dados de negócio e de mercado permitiu traçar uma curva que representa o comportamento de perdas de receita ao longo dos anos. Utilizando uma abordagem de perda esperada em um horizonte de cinco anos, em conformidade com as normas contábeis internacionais CPC 47 (IFRS 15) e CPC 48 (IFRS 9), foi possível desenvolver uma matriz de provisionamento que indica a probabilidade de perda de receita em cada período. Esta matriz foi ajustada para refletir as expectativas futuras, considerando diferentes cenários econômicos.

Os Modelos de Machine Learning construídos foram essenciais para analisar e prever a inadimplência de crédito. O primeiro modelo permitiu suavizar a curva de inadimplência, ajustando-a para descrever valores esperados, matriz e perdas PECLD. O segundo modelo utilizou as probabilidades geradas pelo primeiro para fazer um forecast de orçamento em diferentes cenários econômicos e de negócios. A implementação desses modelos, utilizando bibliotecas robustas de machine learning, demonstrou a capacidade de capturar a dinâmica da inadimplência de crédito e prever com precisão os impactos de diferentes cenários econômicos.



Figura 7 - Forecast & Provisão de Curvas da PECLD

A integração de contabilidade, economia, big data e machine learning neste projeto proporcionou uma ferramenta poderosa para a gestão financeira, com impacto significativo na precisão das previsões orçamentárias e na redução das perdas de receita. A adoção desta abordagem inovadora não apenas melhorou a eficiência operacional, mas também fortaleceu a resiliência financeira da empresa em um ambiente econômico dinâmico e desafiador.

Em conclusão, o modelo de previsão orçamentária para PECLD desenvolvido neste projeto representa um avanço significativo na gestão financeira, combinando rigor metodológico, análise de dados e técnicas avançadas de machine learning. Esta abordagem interdisciplinar e iterativa, fundamentada na metodologia ágil Scrum, assegurou a precisão e a eficiência dos resultados, oferecendo uma solução robusta e adaptável para a gestão de riscos financeiros em um cenário econômico em constante evolução.

3. Conclusão

A implementação deste projeto resultou em previsões orçamentárias mais assertivas, reduzindo a incerteza e permitindo uma alocação de recursos mais eficiente. A abordagem interdisciplinar que integra contabilidade, macroeconomia, microeconomia, big data e machine learning foi fundamental para o desenvolvimento de um modelo robusto e preciso de previsão orçamentária para Provisão para PECLD.

A melhoria na previsão de PECLD contribuirá significativamente para a minimização das perdas de receita, uma vez que permitirá a identificação precoce de potenciais inadimplentes e a adoção de medidas preventivas. A capacidade de prever com precisão os valores de PECLD permitirá que a empresa ajuste suas estratégias de crédito e cobrança, otimizando o fluxo de caixa e melhorando a saúde financeira geral em um ambiente econômico dinâmico e desafiador.

A utilização da metodologia ágil Scrum garantiu uma organização eficiente do projeto, permitindo uma execução estruturada e dentro dos prazos estabelecidos. A análise detalhada de dados de recuperação de receita e faturamento, juntamente com a consideração de indicadores macro e microeconômicos, forneceu uma base sólida para a construção de uma matriz de provisionamento precisa.

Os modelos de machine learning desenvolvidos foram essenciais para suavizar a curva de provisionamento e prever o impacto de diferentes cenários econômicos e de negócios. A aplicação de técnicas avançadas de machine learning, como modelo ARIMA, permitiu capturar a dinâmica da inadimplência de crédito e fornecer previsões orçamentárias precisas.

Em conclusão, o modelo de previsão orçamentária para PECLD desenvolvido neste projeto oferece uma solução robusta e adaptável para a gestão de riscos financeiros. A combinação de técnicas avançadas de machine learning com uma abordagem interdisciplinar e iterativa assegurou a precisão e a eficiência dos resultados, proporcionando uma ferramenta essencial para a tomada de decisões estratégicas e a otimização da saúde financeira da empresa.

4. Referências bibliográficas

NEZ, Evandro de; GOLLO. Utilização da PECLD para gerenciamento de resultados em empresas listadas na BM&FBOVESP. 2017.

SILVA, Kátia Oliveira. Provisão para créditos de liquidação duvidosa (PCLD) calculada conforme as normas do BACEN e IFRS: comparação. 2018

SANTANA, Jéssica dos Santos. Perda estimada com créditos de liquidação duvidosa (PECLD): impacto da nova regulação contábil nas companhias brasileiras do setor de consumo cíclico. 2021