

DOI: <https://doi.org/10.9771/rcufba.v19i2.69667>

***Machine Learning* Aplicado à Previsão de Lucros: Uma Solução Prática para Contadores e Consultores que Atendam Pequenas e Médias Empresas**

**Machine Learning Applied to Profit Forecasting: a Practical Solution for Accountants and Consultants Serving Small and Medium-Sized Enterprises**

**Thiago Rocha de Almeida**

FUCAPE Business School  
thiagordalmeida@gmail.com

**Octavio Locatelli**

FUCAPE Business School  
octaviolocatelli@fucape.br

**RESUMO**

Este artigo apresenta uma solução prática e acessível para a previsão de lucros em pequenas e médias empresas (PMEs), utilizando ferramentas de *Machine Learning* sem necessidade de codificação (*no-code*). A proposta destina-se a contadores, analistas e consultores que desejam aplicar inteligência preditiva com os dados existentes — mesmo que fragmentados ou incompletos. Por meio de um pipeline estruturado e replicável, exemplificado nas plataformas *BigML* e *Google AutoML (Vertex AI)*, o trabalho demonstra como organizar e tratar dados financeiros, integrando as estimativas geradas pelos modelos a regras de negócio que apoiam a tomada de decisão. O modelo permite iniciar com planilhas simples e evoluir gradualmente a maturidade analítica da organização, promovendo previsibilidade financeira mesmo em ambientes com baixa infraestrutura tecnológica. Como limitação, destaca-se a ausência de validação empírica longitudinal em cenários reais, o que reforça a importância da supervisão humana e da contextualização gerencial dos resultados. A proposta alinha-se aos princípios de transformação digital progressiva e busca democratizar o uso estratégico de *Machine Learning* na gestão financeira empresarial.

**Palavras-chave:** previsão de lucros, *machine learning*, análise preditiva.

**ABSTRACT**

This article presents a practical and accessible solution for profit forecasting in small and medium-sized enterprises (SMEs) using *no-code Machine Learning* tools. The proposal is intended for accountants, analysts, and consultants who seek to apply predictive intelligence using existing data — even when fragmented or incomplete. Through a structured and replicable pipeline, exemplified using platforms such as *BigML* and *Google AutoML (Vertex AI)*, the study demonstrates how to organize and process financial data, integrating model-generated estimates with business rules that support decision-making. The model enables organizations to begin with simple spreadsheets and gradually advance their analytical maturity, promoting financial predictability even in environments with limited technological infrastructure. As a limitation, the study highlights the absence of longitudinal empirical validation in real operational contexts, which reinforces the importance of human supervision and managerial contextualization of the results. The proposal aligns with the principles of progressive digital transformation and seeks to democratize the strategic use of *Machine Learning* in financial management.

**Keywords:** profit forecasting, machine learning, predictive analytics.

---



---

Recebido em: 22/08/2025. Aceito em: 11/12/2025. Publicado em: 18/02/2026. Editor: Arlindo Menezes da Costa Neto



## 1 POR QUE PREVER LUCROS COM PRECISÃO AINDA É UM DESAFIO CENTRAL PARA PEQUENAS E MÉDIAS EMPRESAS?

Prever lucros com precisão é um dos maiores desafios enfrentados por pequenas e médias empresas. Em um cenário de margens comprimidas e flutuações constantes, estimar o desempenho financeiro futuro é crucial para decisões de investimento, alocação de recursos e formação de preços. No entanto, a realidade operacional dessas empresas torna essa tarefa especialmente difícil.

Grande parte dessas organizações opera com dados fragmentados, armazenados em múltiplas planilhas, sistemas ERP pouco integrados ou mesmo registros manuais. Essas informações, por vezes incompletas ou inconsistentes, não seguem um padrão temporal estável e frequentemente apresentam lacunas, ruídos ou distorções. Além disso, são impactadas por mudanças internas (como trocas de sistema, alterações de processo) e externas (como sazonalidades, inflação, câmbio ou crises inesperadas), o que compromete a continuidade e a confiabilidade das séries históricas utilizadas para projeções.

Mesmo ferramentas acessíveis, como funções de previsão do Excel, relatórios financeiros automatizados ou módulos de ERP, ainda se apoiam em suposições simplificadas. Esses recursos normalmente operam com tendências lineares, médias móveis ou extrapolações básicas, o que reduz sua eficácia diante de contextos complexos e instáveis. Mesmo modelos estatísticos sofisticados apresentam limitações importantes quando aplicados em ambientes com dados inconsistentes. Estudos como o de Kuryłek (2024) demonstram que, em determinados mercados, esses modelos são superados por estratégias básicas, como repetir o resultado do mesmo período do ano anterior, ajustando pequenos desvios — uma lógica simples, mas que funciona melhor quando os dados disponíveis são escassos ou pouco confiáveis. Segundo Lee e Shin (2020), isso decorre da rigidez dos métodos clássicos frente à variabilidade e múltiplos fatores simultâneos.

Essas limitações técnicas se agravam quando se considera que a maioria das pequenas e médias empresas não conta com profissionais especializados, como cientistas de dados ou analistas financeiros. Nesses casos, a responsabilidade pela previsão recai sobre gestores administrativos, contadores e consultores externos. Mesmo com experiência prática, esses profissionais enfrentam restrições de tempo, ferramentas e metodologia para transformar dados ruidosos e desorganizados em estimativas confiáveis.

Como consequência, a previsão de lucros nessas empresas é muitas vezes feita com

base na intuição, em planilhas simplificadas ou em expectativas passadas, o que distorce o planejamento orçamentário e aumenta a exposição a riscos operacionais e financeiros. A ausência de previsões confiáveis também impede a realização de simulações de cenários, limitando a capacidade da organização de se antecipar a mudanças no mercado ou tomar decisões mais seguras e embasadas.

A relevância desse desafio torna-se ainda mais evidente quando observados dados empíricos sobre o desempenho e a sobrevivência das pequenas empresas no Brasil. Estudos mostram que fragilidades na gestão financeira, na capacidade de planejamento e no uso de informações contábeis estruturadas estão entre os principais fatores que comprometem a continuidade desses negócios. Conforme Santos e Assis (2024), muitas MPEs subutilizam a contabilidade como instrumento de gestão, limitando-se ao cumprimento de obrigações fiscais, o que reduz sua capacidade de análise de custos, margens e desempenho operacional.

Evidências de larga escala reforçam esse cenário. O Relatório Técnico de Sobrevivência das Empresas Mercantis Brasileiras (2017–2022)(Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (Sebrae), 2023) indica que a taxa de sobrevivência após cinco anos é de apenas 74,3% entre microempresas e 57,7% entre MEIs, revelando elevada vulnerabilidade. Somente entre 2017 e 2022, mais de 3 milhões de MEIs e 451 mil microempresas foram encerradas. Além disso, metade dos MEIs que fecharam permaneceu ativa por menos de 11 meses, evidenciando dificuldades estruturais de gestão e previsibilidade financeira.

Esses indicadores mostram que a incapacidade de antecipar resultados, projetar margens e avaliar cenários futuros não é apenas um problema técnico, é um fator diretamente associado à mortalidade empresarial. Assim, a dificuldade de prever lucros com precisão não é um desafio isolado, mas um elemento central da fragilidade operacional das PMEs, reforçando a necessidade de soluções que permitam análises preditivas mesmo em ambientes de baixa organização de dados e infraestrutura limitada.

Diante desse cenário, o objetivo geral deste artigo é apresentar e descrever um *pipeline* prático, acessível e replicável para a previsão de lucros em pequenas e médias empresas, mesmo quando os dados disponíveis são fragmentados ou incompletos. A proposta é voltada a contadores, analistas e consultores, aproveitando o acesso privilegiado desses profissionais a informações-chave, como receitas, custos e sazonalidades, para estruturar previsões preditivas viáveis em ambientes com baixa maturidade analítica ou tecnológica.

## 2 O PARADOXO DA PREVISÃO: EMPRESAS QUE MAIS PRECISAM SÃO AS QUE MENOS CONSEGUEM IMPLEMENTAR

As peculiaridades dos dados faltantes, dispersos e despadronizados nas PMEs exigem abordagens mais flexíveis que os modelos tradicionais podem oferecer. É nesse contexto que o *Machine Learning* (ML) se destaca como uma alternativa viável, acessível e cada vez mais aplicável à realidade dessas empresas. Em vez de depender de séries completas e dados perfeitamente estruturados — como requerem técnicas convencionais —, os algoritmos de ML aprendem padrões mesmo a partir de dados parciais, adaptando-se continuamente conforme novas informações são inseridas (Holmström & Carroll, 2024). Isso representa uma mudança importante: sai a rigidez explicativa, entra a flexibilidade preditiva, mais adequada aos ambientes incertos e incompletos em que operam as PMEs.

Essa lacuna se evidencia com ainda mais força em setores que operam com margens comprimidas, sazonalidade alta ou forte dependência de fatores externos. Em mercados como o varejo, a logística e a distribuição, uma falha na previsão de lucros pode gerar excesso de estoque, desperdício de recursos e perda de competitividade. Como apontam Sundberg & Holmström (2023), a maioria das soluções preditivas mais avançadas está fora do alcance das empresas que mais precisam delas, seja por custo, seja pela complexidade de implementação.

Diversos modelos de *Machine Learning* voltados à previsão de séries temporais têm demonstrado bons resultados ao identificar padrões ocultos e lidar com variáveis externas, mesmo em contextos desafiadores (Elend et al., 2020; Lim et al., 2021). Além disso, plataformas *no-code* — como destacam Sundberg & Holmström (2023) — democratizam o acesso, permitindo que contadores e consultores usem ML sem depender de especialistas técnicos.

Outro benefício está na ampliação das fontes de dados. ML permite incorporar variáveis antes ignoradas, como clima, campanhas, indicadores econômicos, dados de redes sociais ou logística, enriquecendo as previsões com sinais mais próximos da realidade do negócio (Fischer et al., 2020; Kuryłek, 2024).

Essa abordagem também se mostra eficaz em mercados emergentes ou nichos com pouca cobertura analítica, preenchendo lacunas deixadas pela ausência de previsões setoriais. Contudo, como destacam Neubert & Montañez (2020) e Holmström & Magnusson (2025), adotar ML com sucesso requer planejamento, infraestrutura mínima e objetivos claros. Modelos de referência amplamente utilizados no mercado reforçam que a criação de valor com IA depende de integração entre tecnologia, pessoas e processos.

Por fim, é importante reconhecer limitações. Modelos como *DeepAR* ou *TFT* podem sofrer com *overfitting* — uma situação em que o modelo aprende demais sobre os dados do passado, capturando ruídos e flutuações específicas em vez de padrões gerais. Como mostrou Kuryłek (2024), isso compromete a capacidade de generalização para novos cenários, especialmente quando os dados são escassos ou mal estruturados. Nesses casos, abordagens simples e bem calibradas continuam sendo úteis. Mesmo assim, o ML oferece um salto qualitativo frente à intuição ou médias estáticas.

Assim, para contadores e consultores que buscam agregar valor aos seus serviços, o ML representa uma ferramenta poderosa, acessível e ajustada à realidade de muitas PMEs, especialmente quando aplicado com critérios práticos e foco no contexto do cliente.

### 3. UM PIPELINE ACESSÍVEL DE PREVISÃO DE LUCROS COM ML

A proposta desta seção é apresentar um modelo prático, acessível e de baixo custo, voltado a contadores, analistas e consultores que já detêm os dados financeiros e operacionais de seus clientes. Esses profissionais, que acompanham de perto a rotina das empresas e conhecem seus números com profundidade, estão em posição privilegiada para liderar o uso de ferramentas de *Machine Learning* de forma prática e estratégica.

A solução apresentada neste artigo é baseada em um *pipeline* de previsão de lucros ajustável à realidade de pequenas e médias empresas, sem exigir investimentos elevados em tecnologia. A ideia central é que o próprio consultor organize os dados disponíveis em planilhas simples, enriqueça com fontes públicas relevantes (como inflação, câmbio, clima, entre outros) e utilize plataformas acessíveis *no-code* — como *BigML* ou *Google AutoML Tables (Vertex IA)* — para gerar modelos preditivos calibrados com o contexto de cada cliente. Ao final, os resultados são apresentados em dashboards interativos que facilitam simulações e decisões mais assertivas.

Essa abordagem segue os princípios de adaptabilidade e simplicidade defendidos por Lee e Shin (2020) e Holmström & Carroll (2024), valoriza a democratização do uso de IA em ambientes corporativos (Sundberg & Holmström, 2023) e comprova a efetividade de modelos enxutos e bem direcionados em contextos de baixa estrutura, como observado por Kuryłek (2024) e Fischer et al. (2020).

A primeira etapa para aplicar a solução consiste na organização dos dados já disponíveis no contexto de trabalho do contador ou consultor. Esses profissionais geralmente têm acesso a informações-chave da empresa, como receitas, despesas, fluxo de caixa e

investimentos. Para iniciar o processo, é recomendável reunir essas variáveis em uma planilha simples (Excel ou *Google Sheets*), onde cada linha representa um período (mensal, bimestral ou trimestral) e cada coluna corresponde a uma variável relevante.

Algumas informações complementares — como dados sobre campanhas promocionais, sazonalidades, operações logísticas, indicadores econômicos ou engajamento digital — podem não estar sob responsabilidade direta do profissional, mas podem ser solicitadas à empresa-cliente de forma orientada, conforme a necessidade do modelo.

Mesmo que nem todos os dados estejam completos, é possível prosseguir com a aplicação da solução. Um dos maiores benefícios dessa abordagem é a inclusão de métodos automáticos de preenchimento inteligente de lacunas nos dados, processo conhecido como imputação de dados ausentes, como demonstrado no estudo de Elend et al. (2020). Por exemplo, se em determinado mês o custo fixo não foi registrado, a ferramenta pode preencher esse valor com base na média dos meses anteriores, ou com algoritmos que reconhecem padrões históricos semelhantes daquela variável.

### Tabela 1

*Exemplos de variáveis relevantes para a previsão de lucros e suas fontes de obtenção.*

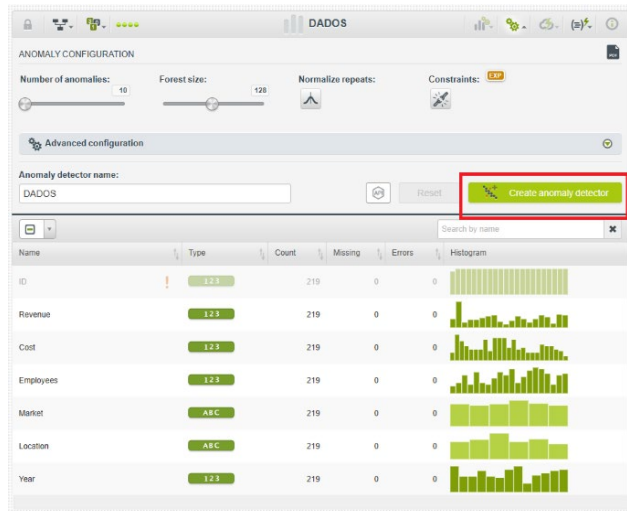
<b>Categoria</b>	<b>Variáveis necessárias</b>	<b>Onde obter</b>
Receita	Receita líquida por período	ERP, relatórios contábeis
Custos	Custos fixos e variáveis	Planilha de controle ou sistema
Estoque	Volume médio, perdas, giro	Planilha, sistema de estoque
Vendas	Por canal (e-commerce, loja física)	Sistema de faturamento, planilhas
Investimentos	Gasto com marketing, expansão	Financeiro, marketing
Eventos Sazonais	Feriados, campanhas, promoções, mudanças de política de preço	Planejamento comercial
Indicadores Econômicos	Inflação (IPCA, IGP-M), câmbio, PIB setorial, taxa de juros	APIs públicas (IBGE, BCB, INMET)
Tendências de consumo	Dados de busca por produtos, menções em redes sociais, picos de interesse	<i>Google Trends</i> , APIs do Twitter, TikTok, Instagram
Engajamento digital	Taxa de cliques em campanhas, tempo médio no site, abandono de carrinho	<i>Google Analytics</i> , <i>Facebook Ads</i> , <i>RD Station</i> , etc.
Operações e logística	Atrasos na entrega, rupturas na cadeia, indicadores de transporte	Sistema de gerenciamento de transporte, planilhas, documentos de recebimento de entrega

Isso pode ser feito de forma prática por meio de plataformas como o *BigML*, onde o usuário sobe sua planilha e por meio da funcionalidade de transformação de dados (*Feature Engineering*), cria campos com regras condicionais ou expressões matemáticas, que analisa os dados disponíveis e sugere o valor mais coerente com o histórico da empresa. Já no *Google AutoML Tables (Vertex IA)*, o processo ocorre durante o carregamento do *dataset*, com sugestões automáticas de preenchimento com média, mediana ou modelo preditivo, acessíveis diretamente na etapa de pré-processamento de dados. Alternativamente, ferramentas como *Power Query* no Excel ou complementos de inteligência artificial no *Google Sheets* também permitem realizar essa tarefa com comandos simples de preenchimento automático com base em médias móveis ou tendências. Esses recursos tornam o processo acessível mesmo para equipes sem conhecimento técnico, viabilizando a continuidade do projeto mesmo com conjuntos de dados incompletos.

Após preencher os dados ausentes, o segundo desafio é garantir que os dados estejam coerentes com a realidade da empresa. Isso inclui identificar valores fora do padrão esperado, como uma receita de R\$ 9 milhões em um mês em que normalmente se fatura R\$ 90 mil. Esses desvios extremos, conhecidos como outliers, podem comprometer a qualidade da previsão ao fazer o modelo aprender padrões distorcidos. Para realizar essa verificação, o gestor do projeto pode utilizar o *BigML*, acessando o menu “*Anomalies*” e selecionando a opção “*Create Anomaly Detector*”, que identifica automaticamente registros atípicos com base em análise estatística. A plataforma destaca as linhas mais suspeitas e permite sua revisão ou exclusão. Já no *Google AutoML Tables (Vertex IA)*, os outliers são sinalizados automaticamente durante a fase de pré-processamento, com alertas visuais e sugestões de tratamento diretamente na interface de visualização dos dados.

**Figura 1**

*Detecção de outliers pelo BigML.*



**Fonte:** Elaborado pelos autores a partir de BigML (2025).

Após a validação e limpeza dos dados, o pipeline segue para a etapa de preparação dos dados para modelagem, conhecida como engenharia de atributos. Essa etapa consiste em criar colunas a partir dos dados existentes, de modo que o modelo consiga identificar padrões sazonais, tendências de crescimento ou relações entre variáveis. No *BigML*, esse processo pode ser realizado no menu “*Feature Engineering*”, utilizando a opção “*Create Feature*”, onde a plataforma oferece sugestões automáticas de atributos adicionais com base no tipo de dado e na sua recorrência. No *Google AutoML (Vertex IA)*, esse enriquecimento acontece de forma automática durante a configuração do modelo, com reconhecimento de campos temporais, categóricos e numéricos, além da geração de combinações estatísticas relevantes. Essas transformações são fundamentais para aumentar a capacidade do modelo de reconhecer padrões ocultos e entregar previsões mais precisas.

Com os dados organizados, limpos e enriquecidos com novos atributos que facilitam a identificação de padrões relevantes, o próximo passo é treinar o modelo de *machine learning*. É nessa etapa que a ferramenta analisará o histórico da própria empresa para entender quais variáveis têm mais influência sobre o lucro e como elas se comportam ao longo do tempo. A partir desse aprendizado, o modelo passa a ser capaz de estimar os resultados futuros com base em diferentes combinações de variáveis.

Na prática, esse treinamento pode ser realizado de forma simples com plataformas como *BigML* ou *Google AutoML (Vertex IA)*, que oferecem fluxos automáticos de criação de modelos. No *BigML*, após importar o conjunto de dados já tratado, o gestor ou analista deve

selecionar a opção “1-Click Model” e indicar a variável de saída como “Lucro” ou “Resultado Financeiro”. A plataforma cria automaticamente um modelo de regressão, divide os dados entre treino e teste, e apresenta os resultados de desempenho com gráficos de fácil interpretação. É possível testar diferentes algoritmos e visualizar quais variáveis mais influenciaram o resultado.

No *Google AutoML (Vertex IA)*, o processo é semelhante: ao subir os dados para a plataforma, o usuário deve marcar qual campo será previsto (*target*) e iniciar o treinamento com a opção “Train Model”. A ferramenta realiza toda a preparação técnica em segundo plano e fornece, ao final, relatórios com métricas como  $R^2$ , RMSE e erro percentual, além de um painel de previsões para novos dados.

## Figura 2

Treinando o modelo automatizado Google Auto ML (Vertex IA).

**Fonte:** Elaborado pelos autores a partir do *Google Auto ML (Vertex IA)* (2025).

Essas plataformas também indicam automaticamente quais variáveis tiveram maior peso nas previsões — um recurso essencial para gestores que desejam entender quais fatores estão mais diretamente relacionados ao desempenho financeiro da empresa. A partir desse modelo treinado, será possível não apenas prever os lucros de períodos futuros, mas também realizar simulações, comparando diferentes cenários de investimento, vendas ou variações econômicas.

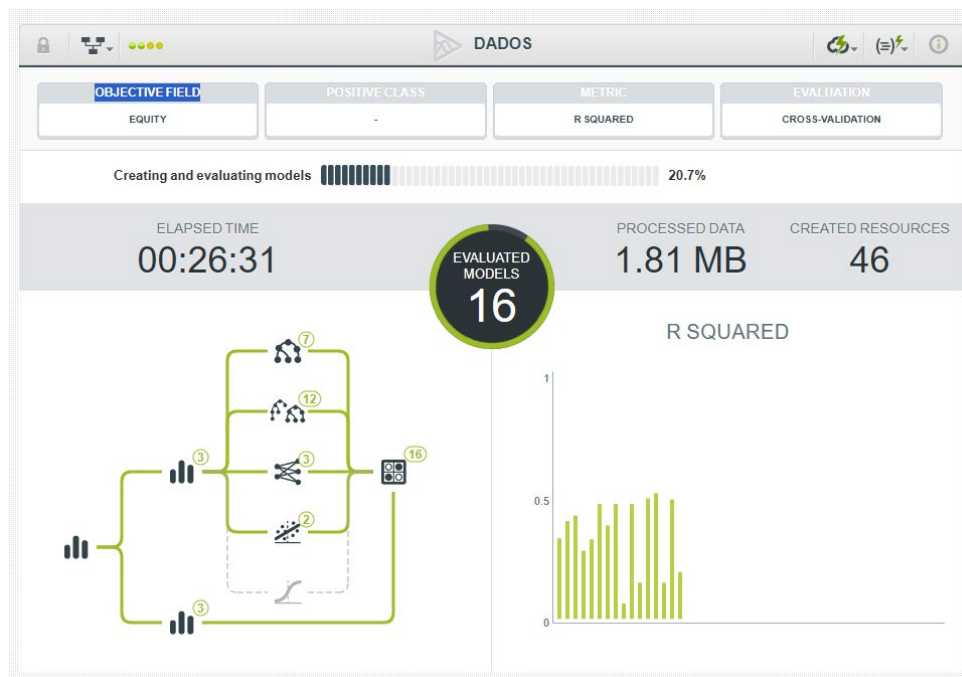
Com os dados organizados e enriquecidos, chega o momento de aplicar os modelos de

*machine learning* que irão gerar as previsões de lucro da empresa. É nesse ponto que o sistema aprende com o próprio histórico da organização quais fatores mais influenciam os resultados financeiros — e como essas variáveis interagem ao longo do tempo.

Na plataforma *BigML*, o treinamento do modelo pode ser feito de duas formas: de maneira assistida, com o gestor ou analista selecionando diretamente o tipo de modelo a ser utilizado; ou por meio do recurso *OptiML*, que automatiza essa escolha. Ao ativar o *OptiML*, a plataforma testa centenas de combinações entre diferentes algoritmos (como árvores de decisão, regressão linear, florestas aleatórias e redes neurais), avaliando o desempenho de cada uma com base nos dados fornecidos. Ao final, ela apresenta o modelo com os melhores resultados, prontos para uso, sem necessidade de conhecimento técnico para interpretar as opções.

**Figura 3**

*Ferramenta OptiML criando modelos automaticamente.*



**Fonte:** Elaborado pelos autores a partir de BigML (2025).

Para quem preferir selecionar o modelo manualmente, o BigML oferece as seguintes opções:

**Tabela 2**

*Comparativo entre modelos preditivos disponíveis no BigML e suas aplicações práticas.*

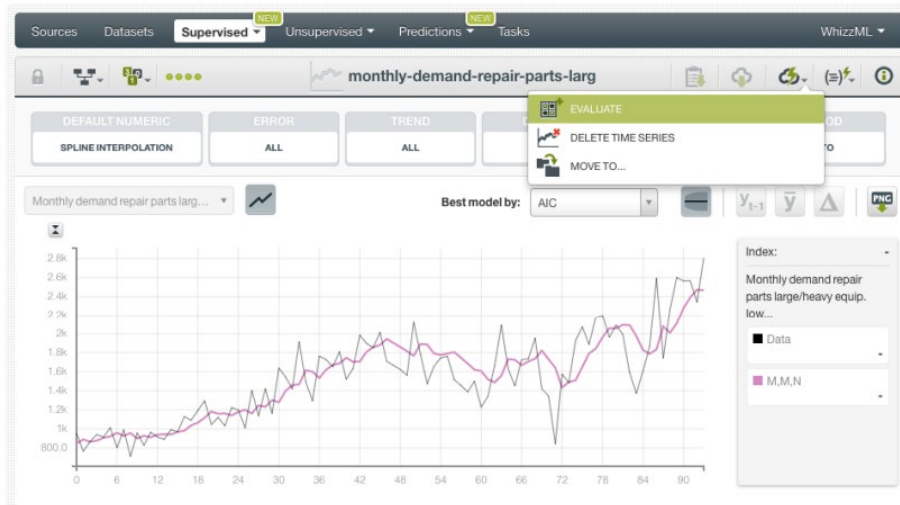
<b>Modelo (Big ML)</b>	<b>Quando usar?</b>	<b>Vantagens</b>
Linear Regression	Quando os dados têm relações diretas e comportamentos mais estáveis	Fácil de interpretar, rápido de treinar, útil como linha de base
Decision Tree	Quando se deseja visualizar regras claras de impacto nos lucros	Transparente e explicativo, ideal para apresentações internas
Random Decision Forest	Quando há muitas variáveis e dados com ruído ou padrões não lineares	Robusto e com boa performance mesmo com dados variados
Gradient Boosted Trees	Quando se busca alta acurácia e os dados estão limpos e estruturados	Excelente para capturar padrões complexos, com ótimo desempenho preditivo
Deepnets	Quando há grande volume de dados e múltiplas variáveis inter-relacionadas	Capaz de identificar padrões ocultos e gerar previsões ajustadas
Time Series Forecasting	Quando se quer prever lucros com base apenas em séries históricas	Útil para empresas com poucos dados complementares ou estrutura enxuta

Durante o treinamento, o *BigML* divide automaticamente os dados em dois grupos: um para aprendizado (treinamento) e outro para teste (validação). Essa divisão permite verificar a qualidade da previsão e evitar que o modelo “memorize” os dados em vez de aprender os padrões reais.

A qualidade do modelo é analisada por meio da função *Evaluate*, que compara os valores previstos com os valores reais do conjunto de teste e apresenta os principais indicadores de desempenho de forma visual e acessível. Entre essas métricas, destaca-se o RMSE (*Root Mean Squared Error*), que mede a média das diferenças quadráticas entre os valores reais e previstos, penalizando com mais intensidade os erros maiores. Já o MAAPE (*Mean Arctangent Absolute Percentage Error*) é útil em contextos com alta variabilidade ou valores muito baixos, pois suaviza os erros percentuais extremos com o uso da função arco-tangente. O  $R^2$  (Coeficiente de Determinação), por sua vez, indica o quanto o modelo explica a variação dos dados: valores próximos de 1 sugerem boa explicação, embora não garantam qualidade se houver overfitting. Esses indicadores permitem ao consultor ou analista verificar a robustez do modelo antes de aplicá-lo, facilitando decisões mais seguras com base em dados reais.

**Figura 4**

*Avaliação da série temporal pelo menu Evaluate de ações rápidas.*

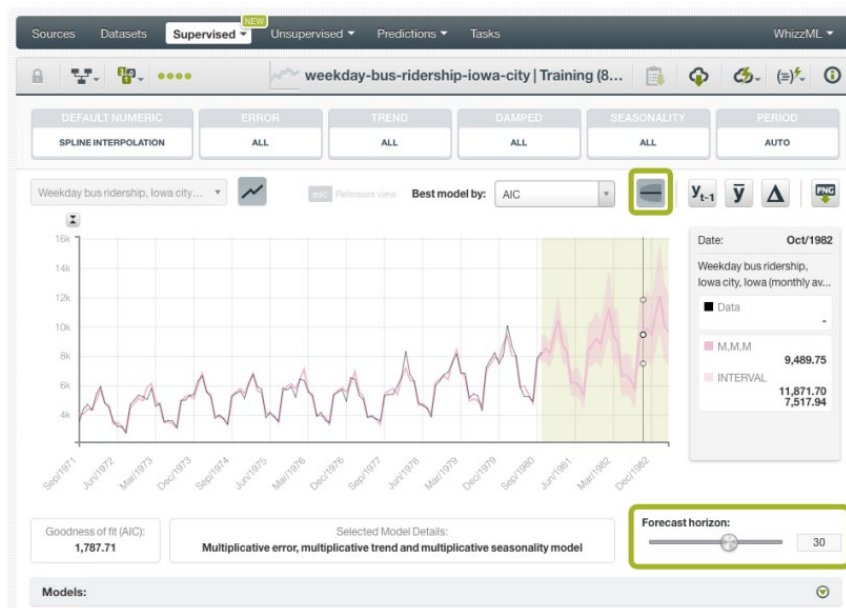


**Fonte:** Elaborado pelos autores a partir de BigML (2025).

Uma vez validado, o modelo pode ser utilizado imediatamente para prever os lucros dos próximos meses ou trimestres. Os resultados são disponibilizados de forma visual por meio de dashboards conectados diretamente às planilhas da empresa. Ferramentas como *Power BI*, *Tableau*, *Google Looker Studio* ou interfaces interativas criadas com *Streamlit* podem ser utilizadas para tornar as informações claras, acionáveis e fáceis de navegar.

**Figura 5**

*Previsão de séries temporais no BigML.*

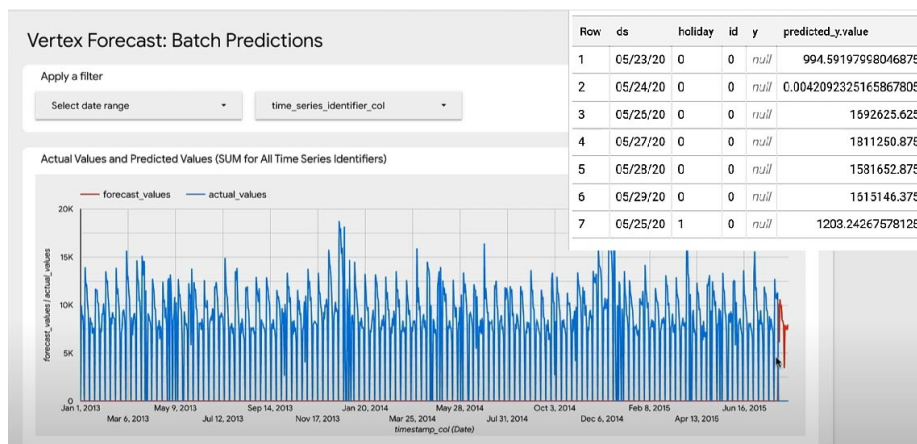


**Fonte:** Elaborado pelos autores a partir de BigML (2025).

Para empresas que desejam uma experiência ainda mais simplificada, o *Google AutoML* representa uma alternativa robusta e automatizada. Diferente do *BigML*, que permite a escolha manual dos algoritmos, o *Google AutoML* cuida de todo o processo de modelagem de forma autônoma. Basta importar a planilha com os dados da empresa, indicar qual variável se deseja prever — neste caso, o lucro — e a ferramenta se encarrega de testar diversos modelos e combinações de parâmetros em segundo plano. Ao final, o sistema entrega automaticamente o modelo com melhor desempenho, já validado, acompanhado de métricas como RMSE,  $R^2$  e ranking de variáveis por importância. Essa abordagem é ideal para empresas que querem adotar *machine learning* sem tomar decisões técnicas, aproveitando uma solução poderosa e integrada ao ecossistema do *Google Cloud*, com possibilidade de escalar a aplicação conforme o negócio evolui.

### Figura 6

Visualização de previsões no Google Vertex AI.



Fonte: Elaborado pelos autores a partir do *Google Auto ML (Vertex IA)* (2025).

Após a etapa de avaliação do modelo, as previsões geradas não devem ser interpretadas de forma automática. A literatura demonstra que a inteligência artificial, especialmente em contextos organizacionais, não substitui o julgamento humano, mas o complementa. Campbell et al. (2020) destacam que a IA amplia a capacidade analítica, mas somente se integrada à interpretação profissional, que considera nuances operacionais e fatores não observáveis nos dados. Da mesma forma, Tursunbayeva e Chalutz-Ben Gal (2024) enfatizam que a adoção de sistemas de IA depende da confiança, da explicabilidade e da participação ativa dos usuários na validação dos resultados, o que torna indispensável uma etapa gerencial de verificação.

Nesse sentido, o *pipeline* proposto incorpora uma camada de validação baseada em regras de negócio, que funciona como um filtro de plausibilidade antes que as previsões sejam utilizadas para decisões financeiras. Essa etapa é fundamental porque, como apontam Sundberg e Holmström (2023), ferramentas *no-code* democratizam o uso da IA por profissionais sem formação técnica, mas não eliminam problemas estruturais nos dados, como lacunas, ruídos ou vieses.

A primeira regra recomenda que previsões que apontem aumentos de lucro significativamente acima do comportamento histórico — como valores superiores a aproximadamente vinte por cento da média dos últimos meses — sejam revisadas à luz de informações contextuais, incluindo sazonalidade, campanhas em andamento, novos contratos ou eventos operacionais relevantes. Essa verificação é coerente com a literatura de previsão temporal, que ressalta a importância de considerar fatores sazonais e eventos explicativos na interpretação dos resultados, como discutido por Lim et al. (2021) ao abordar modelos capazes de identificar padrões persistentes e eventos significativos em séries históricas.

Da mesma forma, quando a previsão indicar queda brusca ou lucro negativo, recomenda-se acionar uma análise específica de caixa e margem operacional, pois tais variações podem refletir tanto deterioração real do desempenho quanto inconsistências nos dados de entrada. Essa verificação reforça o alinhamento entre ciência de dados e lógica de negócios defendido por Reddy et al. (2024), que argumentam que a geração de valor depende da capacidade de conectar estimativas preditivas às estruturas financeiras reais da organização.

Outra regra de validação refere-se à compatibilidade entre a previsão e a capacidade operacional da empresa. Sempre que o modelo projetar receitas superiores ao volume máximo que a empresa é capaz de produzir, estocar ou atender — considerando sua estrutura atual —, o resultado deve ser ajustado para refletir limites reais de operação. Essa orientação está alinhada ao *AI Transformation Framework* de Holmström e Magnusson (2025), segundo o qual iniciativas de IA só produzem valor quando estão consistentes com restrições organizacionais e níveis reais de maturidade analítica.

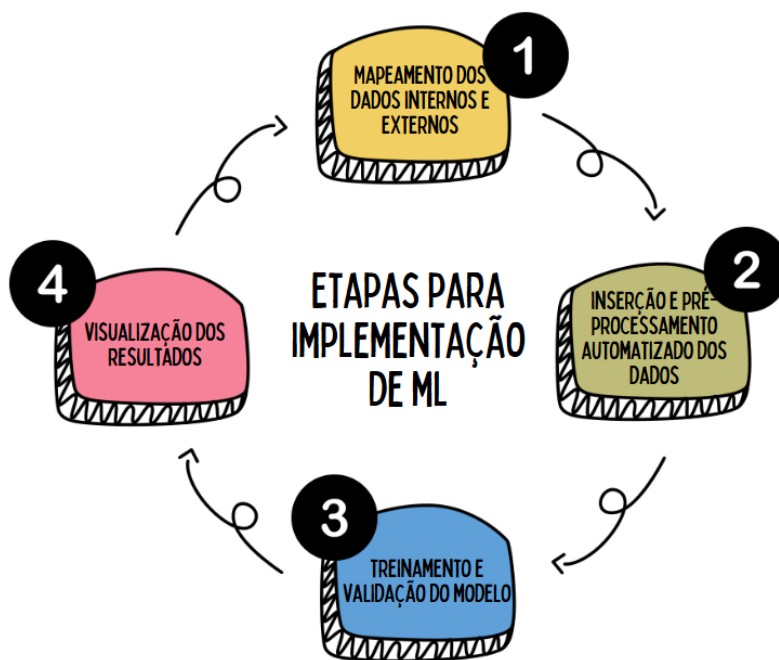
Por fim, em casos que envolvam eventos extraordinários ou inéditos para os quais não exista histórico — como mudança de sistema, abertura de nova unidade, alteração drástica no mix de produtos ou reestruturações internas —, os resultados precisam ser ajustados manualmente. Como pontuam Sundberg e Holmström (2023), plataformas *no-code* não dispõem de mecanismos automáticos para antecipar o impacto de eventos inéditos, o que reforça a importância da intervenção humana para evitar interpretações equivocadas.

Ao integrar essas regras de validação ao *pipeline*, o processo de previsão torna-se mais robusto e aderente às condições reais das pequenas e médias empresas. Em vez de substituir o especialista, o modelo passa a trabalhar em conjunto com ele, combinando automação analítica com interpretação profissional — exatamente a combinação apontada na literatura como necessária para que a IA gere valor prático e sustentável nas organizações.

Para tornar a implementação da solução viável no dia a dia de contadores e consultores, propomos um plano prático em quatro etapas, pensado para ser executado com ferramentas acessíveis e conhecimento técnico básico. O objetivo é permitir que esses profissionais conduzam o processo de previsão de lucros de forma estruturada, mesmo em contextos com baixa maturidade tecnológica.

**Figura 7**

*Ciclo prático de implementação da previsão de lucros com Machine Learning.*



**Fonte:** Elaborado pelos autores (2025).

Este modelo foi pensado para crescer junto com a empresa. Ele pode ser iniciado com dados básicos organizados em planilhas e com o uso de plataformas gratuitas ou de baixo custo. Com o tempo, à medida que a organização evolui, é possível incorporar novas fontes de dados — como redes sociais, análises de sentimento do consumidor, inteligência competitiva e automações via *API* — tornando o modelo mais robusto e estratégico.

Essa escalabilidade está alinhada com os princípios de transformação digital

progressiva descritos por Neubert & Montañez (2020) e pelo *AI Transformation Framework* de Holmström & Magnusson (2025), que defendem que a maturidade analítica das empresas cresce à medida que o uso prático da inteligência artificial se torna parte das rotinas decisórias.

Com a aplicação do *pipeline*, os impactos vão além da esfera técnica. A empresa passa a contar com previsões realistas de lucro, continuamente ajustadas a novos dados, o que fortalece o planejamento financeiro e reduz riscos. Com essa base, torna-se possível simular cenários, antecipar flutuações de mercado e tomar decisões embasadas com mais segurança, deixando a intuição como apoio — e não como única referência.

Com o tempo, a organização passa a reagir mais rapidamente a variações de mercado, ajustando estratégias com base em dados reais — e não em estimativas ultrapassadas ou metas fixas. Isso se conecta diretamente ao conceito de “organizações adaptativas” discutido por Holmström & Carroll (2024) e à visão de transformação digital progressiva descrita por Neubert & Montañez (2020).

Outro benefício é a autonomia: a solução foi pensada para operar em plataformas *no-code*, permitindo que o próprio time de gestão ou financeiro conduza a análise com apoio pontual. Isso torna o processo mais ágil e sustentável, ampliando a maturidade analítica da empresa.

Ainda assim, é importante reconhecer limitações. A qualidade dos dados históricos, a regularidade das atualizações e a clareza nos objetivos influenciam diretamente a eficácia da previsão. Modelos de *machine learning*, por mais sofisticados, não substituem o olhar estratégico e a experiência humana. Eles apoiam, mas não decidem — e devem ser interpretados com senso crítico.

A ausência de organização mínima, objetivos claros ou um responsável pelo acompanhamento pode comprometer a continuidade da solução. Por isso, o uso responsável e consciente da tecnologia é o que diferencia iniciativas bem-sucedidas de experimentos frustrados.

Reconhecer essas limitações, inclusive, é um passo essencial para gerar valor real e evitar frustrações. Quando aplicada com propósito, a previsão preditiva fortalece a cultura de dados, reduz a incerteza e transforma a empresa em uma organização mais adaptativa e preparada para os desafios do mercado.

#### 4 DE PLANILHAS A DECISÕES INTELIGENTES: UM PRIMEIRO PASSO PARA A CULTURA PREDITIVA

Este artigo tecnológico foi desenvolvido com um objetivo claro: oferecer às empresas um caminho viável, acessível e prático para começar a usar *machine learning* na previsão de lucros, mesmo sem estrutura técnica avançada. Em vez de discutir conceitos abstratos ou apresentar soluções genéricas, buscamos entregar um *pipeline* inicial — um modelo replicável, baseado em ferramentas já disponíveis no mercado, que possa ser aplicado imediatamente por gestores e analistas de negócio em contextos reais.

A proposta não exige conhecimento profundo em ciência de dados, nem grandes investimentos iniciais. O que se oferece aqui é um passo a passo objetivo para que a empresa organize suas informações, trate seus dados e, com o apoio de plataformas como *BigML* ou *Google AutoML Tables (Vertex IA)*, consiga gerar previsões úteis para a tomada de decisão. Mais do que um modelo fechado, esta é uma base sobre a qual cada organização poderá construir suas próprias versões, ajustadas às suas necessidades, particularidades de mercado e níveis de maturidade analítica.

O que estamos propondo não é apenas a adoção de uma tecnologia, mas o início de uma mudança cultural: sair do improviso e da intuição como único suporte às decisões financeiras, e passar a contar com previsões embasadas em dados reais, continuamente ajustadas conforme o negócio evolui. A previsão de lucros por *machine learning*, neste contexto, torna-se um instrumento de apoio estratégico, capaz de antecipar riscos, testar hipóteses e ampliar a confiança na hora de decidir.

Para começar, a empresa precisa de muito menos do que se imagina. É necessário reunir o histórico de receita, custos, vendas, estoque, investimentos e eventos relevantes em uma planilha simples — mesmo que com lacunas. É importante também identificar variáveis externas que possam influenciar o lucro, como inflação, câmbio, clima, engajamento digital ou comportamento de consumo, que podem ser captadas por *APIs* públicas ou ferramentas como *Google Trends* e *Google Analytics*. Em seguida, é preciso aplicar o tratamento inicial: preencher dados ausentes, remover valores fora da curva e gerar atributos derivados que ajudem o modelo a enxergar padrões. Com isso feito, basta subir os dados em uma das plataformas indicadas, escolher ou deixar que o sistema selecione o modelo ideal, validar os resultados com base nas métricas geradas e, por fim, visualizar tudo de forma prática em dashboards interativos conectados à planilha.

O mais importante é entender que esse processo pode começar pequeno, com os dados

que a empresa já possui, e crescer à medida que ela se familiariza com o uso da tecnologia. É assim que se constrói, com consistência, uma cultura analítica orientada à realidade — onde previsões não substituem a estratégia, mas a tornam mais robusta, adaptável e preparada para os desafios de um mercado cada vez mais dinâmico.

Este estudo concentra-se na descrição de um *pipeline* de previsão de lucros para pequenas e médias empresas utilizando técnicas de *Machine Learning no-code*. A proposta restringe-se à apresentação de um procedimento operacional aplicável por contadores, analistas e consultores, não abrangendo a validação empírica longitudinal do modelo em casos reais. Como limitação, a aplicabilidade do *pipeline* depende do nível de organização dos dados financeiros disponíveis e da maturidade digital das empresas, o que pode influenciar a qualidade das previsões. Além disso, as plataformas utilizadas, *BigML* e *Google AutoML/Vertex AI*, operam em modelo *freemium*, com recursos avançados sujeitos a cobrança, o que pode limitar a adoção em organizações com restrições orçamentárias. Reconhece-se também que previsões automatizadas devem ser complementadas por regras de negócio e análise contextual realizada por profissionais, evitando interpretações mecanicistas dos resultados.

## REFERÊNCIAS

- Campbell, C., Sands, S., Ferraro, C., Tsao, H.-Y. (Jody), & Mavrommatis, A. (2020). From data to action: How marketers can leverage AI. *Business Horizons*, 63(2), 227–243. <https://doi.org/10.1016/j.bushor.2019.12.002>
- Elend, L., Tideman, S. A., Lopatta, K., & Kramer, O. (2020). *Earnings Prediction with Deep Learning* (V. 12325, p. 267–274). [https://doi.org/10.1007/978-3-030-58285-2\\_22](https://doi.org/10.1007/978-3-030-58285-2_22)
- Fischer, J. A., Pohl, P., & Ratz, D. (2020). A machine learning approach to univariate time series forecasting of quarterly earnings. *Review of Quantitative Finance and Accounting*, 55(4), 1163–1179. <https://doi.org/10.1007/s11156-020-00871-3>
- Holmström, J., & Carroll, N. (2024). How organizations can innovate with generative AI. *Business Horizons*, S0007681324000247. <https://doi.org/10.1016/j.bushor.2024.02.010>
- Holmström, J., & Magnusson, J. (2025). Navigating the organizational AI journey: The AI transformation framework. *Business Horizons*, S0007681325000023. <https://doi.org/10.1016/j.bushor.2025.01.002>
- Kuryłek, W. (2024). Can we profit from BigTechs' time series models in predicting earnings per share? Evidence from Poland. *Data Science in Finance and Economics*, 4(2), 218–235. <https://doi.org/10.3934/DSFE.2024008>
- Lee, I., & Shin, Y. J. (2020). Machine learning for enterprises: Applications, algorithm selection, and challenges. *Business Horizons*, 63(2), 157–170. <https://doi.org/10.1016/j.bushor.2019.10.005>
- Lim, B., Arik, S. Ö., Loeff, N., & Pfister, T. (2021). Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4), 1748–1764. <https://doi.org/10.1016/j.ijforecast.2021.03.012>
- Neubert, M. J., & Montañez, G. D. (2020). Virtue as a framework for the design and use of artificial intelligence. *Business Horizons*, 63(2), 195–204. <https://doi.org/10.1016/j.bushor.2019.11.001>
- Reddy, R. C., Mishra, D., Goyal, D. P., & Rana, N. P. (2024). Data science and business value: Insight into the alignment process. *Business Horizons*, S0007681324001253. <https://doi.org/10.1016/j.bushor.2024.09.002>
- Santos, S. S. A., & Assis, P. R. D. (2024). A IMPORTÂNCIA DA CONTABILIDADE FINANCEIRA PARA AS MICRO E PEQUENAS EMPRESAS. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, 10(11), 5257–5279. <https://doi.org/10.51891/rease.v10i11.17005>
- Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (Sebrae). (2023). *Sobrevivência das empresas mercantis brasileiras (2017–2022)*.
- Sundberg, L., & Holmström, J. (2023). Democratizing artificial intelligence: How no-code AI can leverage machine learning operations. *Business Horizons*, 66(6), 777–788. <https://doi.org/10.1016/j.bushor.2023.04.003>
- Tursunbayeva, A., & Chalutz-Ben Gal, H. (2024). Adoption of artificial intelligence: A TOP framework-based checklist for digital leaders. *Business Horizons*, 67(4), 357–368. <https://doi.org/10.1016/j.bushor.2024.04.006>