

FATEC SP – FACULDADE DE TECNOLOGIA DE SÃO PAULO
ANÁLISE E DESENVOLVIMENTO DE SISTEMAS

JOÃO VITOR ALVES DA SILVA

MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE INADIMPLÊNCIA

SÃO PAULO

2025

FATEC SP – FACULDADE DE TECNOLOGIA DE SÃO PAULO
JOÃO VITOR ALVES DA SILVA

MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE INADIMPLÊNCIA

Trabalho submetido como exigência
parcial para a obtenção do Grau de
Tecnólogo em Análise e Desenvolvimento
de Sistemas
Orientador: Me. VALTER YOGUI

SÃO PAULO
2025

RESUMO

Este trabalho tem como objetivo analisar o uso de modelos de Inteligência Artificial na previsão de inadimplência, com ênfase na compreensão de como diferentes algoritmos supervisionados têm sido aplicados por instituições financeiras para estimar o risco de crédito. A partir de uma revisão bibliográfica e documental, busca-se explorar o funcionamento geral de modelos como regressão logística, árvores de decisão, random forest e XGBoost, destacando suas contribuições, vantagens e limitações em cenários reais. Também se pretende discutir os critérios comumente utilizados para avaliar esses modelos — como acurácia, precisão e área sob a curva ROC —, além de identificar os benefícios práticos que a adoção dessas tecnologias pode trazer à gestão de crédito. Por fim, espera-se apresentar reflexões e recomendações que possam orientar o uso responsável e eficaz da Inteligência Artificial no setor financeiro, mesmo em organizações que ainda estão em fase inicial de transformação digital.

Palavras-chave: Inteligência Artificial. Inadimplência. Aprendizado de Máquina. Modelos Preditivos. Setor Financeiro.

ABSTRACT

This study aims to analyze the use of Artificial Intelligence models in default prediction, with an emphasis on understanding how different supervised algorithms have been applied by financial institutions to estimate credit risk. Through a bibliographic and documentary review, the work explores the general functioning of models such as logistic regression, decision trees, random forest, and XGBoost, highlighting their contributions, advantages, and limitations in real-world scenarios. It also discusses the criteria commonly used to evaluate these models—such as accuracy, precision, and the area under the ROC curve—as well as identifying the practical benefits that the adoption of such technologies can bring to credit management. Finally, the study intends to present reflections and recommendations to guide the responsible and effective use of Artificial Intelligence in the financial sector, even in organizations that are still in the early stages of digital transformation.

Keywords: Artificial Intelligence. Default. Machine Learning. Predictive Models. Financial Sector.

SUMÁRIO

1	INTRODUÇÃO	9
2	OBJETIVOS	10
3	EVOLUÇÃO DA TECNOLOGIA DE INTELIGÊNCIA ARTIFICIAL.....	11
3.1	Introdução	11
3.2	Nascimento e Primeiros Passos (década de 1950)	11
3.3	Otimismo e Primeiros Sistemas Especialistas (década de 1960 e 1970) ...	12
3.4	Primeiro “Inverno da IA” (final dos anos 1970 – início dos 1980).....	12
3.5	Resurgimento com Sistemas Especialistas e Redes Neurais (décadas de 1980 e 1990).....	12
3.6	Segundo “Inverno de IA” (final dos anos 1980 e início dos 1990).....	13
3.7	Era do Aprendizado de Máquina e Big Data (anos 2000)	13
3.8	Revolução do Deep Learning (2010 em diante).....	13
4	INTELIGÊNCIA ARTIFICIAL.....	14
4.1	Introdução	14
4.2	O que é Inteligência Artificial?.....	14
4.3	Inteligência	15
4.4	Tipos de Inteligência Artificial.....	15
4.5	Modelos de Inteligência Artificial	16
4.6	Linguagens e Bibliotecas	19
4.6.1	Padrões em Inteligência Artificial	19
4.6.2	Variações das bibliotecas	20
4.6.3	Funcionalidades das Bibliotecas.....	21
5	INFRAESTRUTURA	22
5.1	Introdução	22
5.2	Definição	22
5.3	Características Essenciais	23
6	MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE INADIMPLÊNCIA	25
6.1	Introdução	25
6.2	Definição	25

6.3	Padrões de Aprendizado de Máquina Aplicados à Previsão de Inadimplência	26
6.3.1	Regressão Logística	27
6.3.1.1	Motivo de ser usado na previsão de inadimplência	27
6.3.1.2	Pontos fortes e limitações	27
6.3.1.3	Casos reais de aplicação	27
6.3.2	Árvores de Decisão	28
6.3.2.1	Motivo de ser usado na previsão de inadimplência	28
6.3.2.2	Pontos fortes e limitações	28
6.3.2.3	Casos reais de aplicação	29
6.3.3	Random Forest	29
6.3.3.1	Motivo de ser usado na previsão de inadimplência	29
6.3.3.2	Pontos fortes e limitações	29
6.3.3.3	Casos reais de aplicação	30
6.3.4	Redes Neurais Artificiais	30
6.3.4.1	Motivo de ser usado na previsão de inadimplência	30
6.3.4.2	Pontos fortes e limitações	30
6.3.4.3	Casos reais de aplicação	31
6.3.5	Gradient Boosting	31
6.3.5.1	Motivo de ser usado na previsão de inadimplência	31
6.3.5.2	Pontos fortes e limitações	31
6.3.5.3	Casos reais de aplicação	32
7	CONCLUSÃO	33
	REFERÊNCIAS	34

1 INTRODUÇÃO

A inadimplência representa um dos principais desafios para o setor financeiro, pois compromete a saúde das operações de crédito, afeta os resultados das instituições e aumenta os riscos associados à concessão de empréstimos. Diante desse cenário, a gestão eficiente do risco de crédito tornou-se essencial para bancos, financeiras e outras organizações que atuam com concessão de crédito. Com a evolução da Inteligência Artificial e, em especial, dos métodos de aprendizado de máquina, novas possibilidades têm surgido para o aumento de modelos preditivos mais precisos e eficazes na identificação de perfis com maior viabilidade de inadimplência.

A crescente disponibilidade de grandes volumes de dados, somada à evolução de algoritmos supervisionados, tem transformado a forma como as instituições financeiras avaliam o risco de seus clientes. Modelos como regressão logística, árvores de decisão, random forest e XGBoost têm se destacado por sua capacidade de reconhecer padrões em conjuntos de dados históricos e contribuir para decisões mais seguras e automatizadas. Esses modelos não apenas auxiliam na redução de perdas financeiras, como também tornam os processos de análise de crédito mais ágeis e consistentes.

Neste contexto, o presente trabalho tem como proposta analisar a aplicabilidade de diferentes modelos de Inteligência Artificial na previsão de inadimplência, através de uma abordagem teórica baseada em revisão bibliográfica e documental. Busca-se compreender o funcionamento desses algoritmos, discutir suas vantagens e limitações e comparar seus desempenhos a partir de métricas amplamente utilizadas na literatura, como acurácia, precisão e AUC-ROC (Área sob a Curva Receiver Operating Characteristic) é uma métrica que avalia a habilidade de um modelo distinguir entre diferentes classes, como clientes adimplentes e inadimplentes. Ela mostra o equilíbrio entre a taxa de acertos e os erros do modelo ao variar o limite de decisão. Quanto mais próxima de 1 for essa área, melhor será o desempenho do modelo na separação correta dos grupos. Ao final, pretende-se apresentar reflexões e recomendações que possam orientar a escolha e o uso desses modelos em instituições financeiras que desejam adotar soluções baseadas em IA para a gestão de risco de crédito.

2 OBJETIVOS

Estudar a utilização de modelos de Inteligência Artificial na previsão de inadimplência, com ênfase na comparação teórica do desempenho de diferentes algoritmos supervisionados utilizados no setor financeiro. Para isso, busca-se realizar uma revisão bibliográfica e documental sobre a aplicação de técnicas de aprendizado de máquina, como regressão logística, árvores de decisão, random forest e XGBoost, destacando seus fundamentos, vantagens, limitações e principais aplicações no âmbito da gestão de risco de crédito. Além disso, pretende-se comparar o desempenho desses modelos com base em métricas estatísticas discutidas na literatura, como acurácia, precisão e área sob a curva ROC (AUC-ROC — Area Under the Curve – Receiver Operating Characteristic). Essa métrica avalia o potencial de um modelo distinguir corretamente entre dois grupos — neste caso, clientes inadimplentes e adimplentes — a partir da relação entre a taxa de verdadeiros positivos e a de falsos positivos. Quanto maior for a área sob essa curva, mais eficiente será o modelo na separação entre as categorias, mesmo em cenários com dados desbalanceados. Com base nessa análise, o estudo busca oferecer recomendações que orientem instituições financeiras interessadas em adotar soluções que utilizam IA na gestão do risco de crédito.

3 EVOLUÇÃO DA TECNOLOGIA DE INTELIGÊNCIA ARTIFICIAL

3.1 Introdução

Antes do surgimento da Inteligência Artificial (IA), o estudo da mente e dos processos de raciocínio humano era uma área de interesse principalmente da filosofia, da psicologia e da lógica matemática. Desde a antiguidade, pensadores buscavam compreender os processos do pensamento, do ato de decidir e da aprendizagem. No século XX, avanços na matemática e na ciência da computação abriram novas possibilidades para projetar máquinas aptas a desempenhar tarefas que exigem inteligência.

A invenção do computador digital nas décadas de 1940 e 1950 marcou um período decisivo, pois permitiu que cálculos complexos e operações lógicas fossem executados de maneira automática e rápida. Pesquisadores começaram a imaginar se as máquinas poderiam, além de calcular, também pensar e aprender, inspirados por conceitos da lógica formal, da teoria da informação e das neurociências.

Esse contexto multidisciplinar, aliado ao crescimento das capacidades computacionais, criou as condições para o surgimento da IA como área de pesquisa específica. Assim, antes mesmo da criação dos primeiros sistemas inteligentes, já existia um interesse profundo em entender e simular a inteligência humana utilizando máquinas, o que motivou os precursores da IA a desenvolverem seus primeiros algoritmos e modelos.

3.2 Nascimento e Primeiros Passos (década de 1950)

O início da história da IA pode ser atribuído à década de 1950, com o trabalho marcante de Alan Turing, "Computing Machinery and Intelligence" (TURING, 1950), onde propôs o Teste de Turing como parâmetro para julgar a inteligência das máquinas.

Em 1956, durante a Conferência de Dartmouth, organizada por John McCarthy, Marvin Minsky, Nathaniel Rochester e Claude Shannon, o termo "Inteligência Artificial" foi formalmente cunhado. Nesse evento, definiu-se a intenção de projetar máquinas que consigam replicar aspectos da inteligência humana (RUSSELL; NORVIG, 2013).

Exemplo prático: O programa Logic Theorist (1956), desenvolvido por Allen Newell e Herbert Simon, reconhecido como o primeiro software de IA, solucionou automaticamente teoremas matemáticos.

3.3 Otimismo e Primeiros Sistemas Especialistas (década de 1960 e 1970)

Nesse intervalo de tempo, predominava o entusiasmo de que em poucas décadas seria possível criar máquinas com inteligência humana. Destaca-se a elaboração de sistemas especialistas, como o DENDRAL (para análise química) e o MYCIN (diagnóstico médico), que demonstraram a aplicabilidade prática da IA em tarefas especializadas (RUSSELL; NORVIG, 2013).

Exemplo prático: O MYCIN, desenvolvido na Universidade de Stanford, conseguiu diagnosticar infecções bacterianas e recomendar tratamentos, superando médicos especialistas em testes controlados.

3.4 Primeiro “Inverno da IA” (final dos anos 1970 – início dos 1980)

As expectativas elevadas foram frustradas pelas limitações computacionais e pela dificuldade de generalização dos sistemas especialistas. Este período ficou conhecido como o "inverno da IA", caracterizado pela redução do investimento público e privado na área (GOODFELLOW; BENGIO; COURVILLE, 2016).

Exemplo prático: A frustração com os robôs Shakey e Freddy, que apresentavam limitações severas em ambientes não controlados, contribuiu para a crise de confiança na IA.

3.5 Resurgimento com Sistemas Especialistas e Redes Neurais (décadas de 1980 e 1990)

O período da década de 1980 marcou o ressurgimento da IA, com a consolidação comercial dos modelos especialistas, como o XCON, da Digital Equipment Corporation, que configurava sistemas de computadores automaticamente, gerando economias milionárias (RUSSELL; NORVIG, 2013).

Simultaneamente, ocorreu a redescoberta dos sistemas de redes neurais artificiais, graças ao algoritmo de retropropagação (Rumelhart, Hinton e Williams, 1986), que permitiu o treinamento de redes mais complexas.

Exemplo prático: O XCON configurou mais de 80 mil pedidos com precisão, sendo um dos primeiros sucessos comerciais da IA.

3.6 Segundo “Inverno de IA” (final dos anos 1980 e início dos 1990)

Mesmo com esses avanços, a dificuldade de generalizar sistemas especialistas e os desafios enfrentados pelas redes neurais resultaram no segundo "inverno da IA". A elevada complexidade computacional e a escassez de dados de qualidade prejudicaram o progresso da área (GOODFELLOW; BENGIO; COURVILLE, 2016).

Exemplo prático: Muitos sistemas especialistas tornaram-se obsoletos rapidamente, pois exigiam manutenção constante e adaptação manual, o que era inviável.

3.7 Era do Aprendizado de Máquina e Big Data (anos 2000)

O advento da internet, a explosão dos dados digitais e o aumento do poder computacional transformaram a IA. O aprendizado de máquina (Machine Learning) tornou-se o centro das pesquisas, com algoritmos como SVM, Random Forest e Gradient Boosting sendo amplamente utilizados para classificação e previsão, inclusive em crédito e risco financeiro (RUSSELL; NORVIG, 2013).

Exemplo prático: Modelos de Machine Learning são atualmente usados por instituições financeiras para prever inadimplência e fraudes em tempo real.

3.8 Revolução do Deep Learning (2010 em diante)

O desenvolvimento do deep learning, com redes neurais profundas, trouxe avanços significativos. Algoritmos como o Convolutional Neural Networks (CNN) e o Long Short-Term Memory (LSTM) impulsionaram áreas como visão computacional, interpretação da linguagem natural e, em tempos mais recentes, aplicações financeiras (GOODFELLOW; BENGIO; COURVILLE, 2016).

Exemplo prático: Empresas como PayPal e Nubank utilizam modelos baseados em deep learning para prever inadimplência, avaliar crédito e detectar fraudes, demonstrando a importância prática da IA no setor financeiro.

4 INTELIGÊNCIA ARTIFICIAL

4.1 Introdução

Após a contextualização histórica e evolutiva da Inteligência Artificial (IA), faz-se necessário apresentar alguns conceitos fundamentais que fornecerão a base para a compreensão dos capítulos subsequentes. A IA configura-se como um campo abrangente, cujas aplicações variam desde sistemas simples, como assistentes virtuais e filtros automatizados, até modelos avançados de aprendizado de máquina utilizados no estudo de grandes quantidades de dados e na definição de decisões estratégicas.

Geralmente, os sistemas de IA são compostos por algoritmos capazes de identificar padrões, aprender com dados históricos e realizar previsões de forma altamente autônoma e eficiente. Para isso, são estruturados sobre plataformas computacionais que permitem o processamento, a manipulação e a extração de informações relevantes, promovendo resultados otimizados e sustentando aplicações em diferentes setores sociais, como o da saúde, a indústria, o comércio e, especialmente, o setor financeiro.

4.2 O que é Inteligência Artificial?

Inteligência Artificial (IA) é um campo da computação focado na criação de sistemas projetados para reproduzir comportamentos inteligentes, como o raciocínio, a aprendizagem e a tomada de decisões. Segundo Russell e Norvig (2016), IA pode ser definida como o estudo de agentes que percebem seu ambiente e tomam ações para maximizar suas chances de alcançar seus objetivos. Já para Nilsson (1998), é a atividade dedicada a fazer com que máquinas se comportem de maneira que, se fosse um ser humano, seria considerada inteligente.

Para viabilizar comportamentos inteligentes, a IA utiliza técnicas como aprendizado de máquina, redes neurais e processamento de linguagem natural, que permitem a análise de grandes volumes de dados e a tomada de decisões baseada em padrões extraídos. O desempenho desses sistemas é avaliado por intermédio de métricas específicas, como acurácia e precisão, e sua aplicação requer cuidados com

aspectos éticos e de segurança, com o propósito de garantir a transparência e o uso responsável da tecnologia.

4.3 Inteligência

Inteligência pode ser definida como a capacidade de adquirir, compreender e aplicar conhecimentos e habilidades para resolver problemas, tomar decisões e adaptar-se a novas situações. Essa capacidade envolve processos cognitivos como raciocínio, aprendizado, percepção e planejamento. Por exemplo, um indivíduo pode demonstrar inteligência ao interpretar informações complexas, reconhecer padrões e gerar soluções criativas para desafios diversos.

Assim como dados podem ser quantificados e armazenados, a inteligência pode ser vista como uma entidade dinâmica que utiliza informações para produzir respostas adequadas em contextos variados. No âmbito humano, a inteligência está relacionada à capacidade cerebral de processar informações de forma eficiente, integrando memórias, experiências e estímulos externos. Em sistemas artificiais, essa capacidade é simulada por meio de algoritmos e modelos computacionais que buscam replicar os processos cognitivos humanos, possibilitando a automação de tarefas que requerem julgamento e adaptação (RUSSELL; NORVIG, 2016).

Portanto, a inteligência não se restringe apenas ao acúmulo de dados, mas engloba a interpretação e a aplicação contextualizada desses dados para alcançar objetivos específicos, sendo fundamental para o desenvolvimento de sistemas inteligentes capazes de aprender e evoluir com a experiência.

4.4 Tipos de Inteligência Artificial

A Inteligência Artificial pode ser classificada em diferentes tipos, conforme seu nível de capacidade e complexidade. Uma das divisões mais comuns é entre a IA estreita, geral e superinteligente.

A Inteligência Artificial Estreita (IA Fraca) é projetada para executar tarefas específicas e limitadas, como reconhecimento facial, assistentes virtuais ou sistemas de recomendação. Apesar de poderem superar humanos em determinadas funções, esses sistemas não possuem consciência ou compreensão geral do mundo,

funcionando exclusivamente dentro do domínio para o qual foram programados (SUTTON; BARTO, 2018).

Já a Inteligência Artificial Geral (IA Forte) refere-se a sistemas que possuem capacidade intelectual equivalente à humana, podendo aprender, raciocinar, compreender e resolver problemas em diversos contextos, sem limitações específicas. Embora seja um objetivo de longo prazo da pesquisa em IA, ainda não foi plenamente alcançada (RUSSELL; NORVIG, 2016).

Por fim, a Inteligência Artificial Superinteligente é um conceito hipotético que descreve que pode superar a inteligência humana em praticamente todos os aspectos, incluindo criatividade, tomada de decisão e habilidades sociais. Essa forma de IA levanta importantes debates éticos e de segurança devido ao seu potencial impacto na sociedade (BOSTROM, 2014).

4.5 Modelos de Inteligência Artificial

Para garantir a eficácia e a precisão dos resultados obtidos por sistemas baseados em Inteligência Artificial, é fundamental que o desenvolvedor compreenda qual modelo de IA será mais adequado ao problema proposto. Essa escolha influencia diretamente no desempenho da aplicação e na qualidade das previsões geradas, podendo minimizar falhas ou até mesmo evitá-las por completo.

Assim, um modelo de Inteligência Artificial pode ser compreendido como uma estrutura matemática ou computacional treinada para identificar padrões e tomar decisões com base em dados históricos (RUSSELL; NORVIG, 2016). Quanto mais adequado o modelo estiver ao contexto da aplicação — ou seja, ao chamado “mini mundo” do problema —, maiores serão as chances de a solução apresentar resultados coerentes, úteis e confiáveis.

Por outro lado, a adoção de um modelo incompatível com o tipo de dado ou com a complexidade do problema pode comprometer seriamente a eficiência do sistema. Nesse caso, as previsões podem se tornar imprecisas, afetando diretamente a tomada de decisões, a confiabilidade do sistema e a credibilidade da organização perante seus usuários.

Em resumo, a escolha do modelo de Inteligência Artificial consiste em representar uma abstração da realidade de forma computacionalmente viável, buscando simular processos cognitivos humanos, como aprendizado, classificação e

previsão. Existem diversas abordagens possíveis — como redes neurais, árvores de decisão ou modelos baseados em ensemble (técnicas que combinam múltiplos algoritmos de aprendizado para obter melhores resultados) —, e a seleção apropriada deve considerar tanto os objetivos da aplicação quanto as características dos dados disponíveis.

4.5.1 Regressão Logística

A regressão logística é um modelo estatístico supervisionado utilizado para estimar a probabilidade de ocorrência de um evento binário, como "inadimplente" ou "adimplente". Baseia-se em uma função logística (sigmoide) para mapear os valores de entrada para uma saída entre 0 e 1. É amplamente utilizada em contextos financeiros por sua simplicidade e capacidade interpretativa (HOSMER; LEMESHOW, 2000).

4.5.2 Árvores de Decisão

As árvores de decisão são modelos de classificação que estruturam o processo de decisão por meio de divisões sucessivas dos dados com base em atributos preditivos. Cada nó interno da árvore representa uma pergunta ou condição sobre uma variável, e cada ramificação leva a novos subconjuntos de dados, até atingir as folhas, que correspondem às classes de saída. Esses modelos são amplamente utilizados por sua simplicidade, interpretabilidade e capacidade de representar regras de decisão de forma gráfica (RUSSELL; NORVIG, 2013).

4.5.3 Random Forest

O Random Forest é um modelo de Inteligência Artificial que usa uma técnica chamada ensemble (que significa combinar vários modelos diferentes para tomar uma decisão mais confiável). Em vez de usar apenas uma árvore de decisão, ele cria várias árvores e faz uma votação entre elas para decidir o resultado final. Isso torna a resposta mais precisa e estável. Além disso, o Random Forest ajuda a evitar o problema de overfitting (quando o modelo aprende tanto os detalhes do exemplo que "decora" os dados e depois erra com informações novas). Por isso, ele funciona muito

bem com bases de dados grandes e cheias de variáveis que se misturam ou se influenciam entre si.

4.5.4 XGBoost (Extreme Gradient Boosting)

XGBoost é um modelo baseado em boosting, que combina várias árvores de decisão fracas, ajustadas sequencialmente, para formar um modelo forte. Possui alta capacidade de generalização e desempenho, sendo amplamente utilizado em competições de ciência de dados e em aplicações empresariais por sua eficiência em grandes volumes de dados.

4.5.5 Redes Neurais Artificiais

As redes neurais são compostas por camadas de unidades chamadas neurônios, que processam informações em formato numérico. São especialmente úteis para reconhecer padrões complexos e não lineares nos dados. Quando combinadas com técnicas de deep learning, essas redes tornam-se ainda mais potentes, embora menos interpretáveis.

4.5.6 Máquinas de Vetores de Suporte (SVM)

O SVM (Support Vector Machine, ou Máquina de Vetores de Suporte) é um modelo de Inteligência Artificial que tenta traçar uma linha ou um plano (chamado de hiperplano, que é como uma linha de separação em espaços com muitas variáveis) que divida os grupos de dados da melhor forma possível, deixando a maior distância entre eles. Esse modelo funciona bem quando há muitas variáveis envolvidas e pode ser usado tanto para classificar dados quanto para prever valores. O SVM costuma ter bom desempenho em situações em que os grupos de dados não estão separados de forma muito clara.

4.6 Linguagens e Bibliotecas

Antes da consolidação das bibliotecas especializadas em Inteligência Artificial, o desenvolvimento de soluções nessa área exigia que os programadores implementassem manualmente algoritmos matematicamente complexos, geralmente utilizando linguagens de programação de baixo ou médio nível, como C ou Java. Essas linguagens, embora poderosas, careciam de estruturas e recursos nativos voltados à manipulação eficiente de dados científicos, dificultando o processo de construção, treinamento e avaliação de modelos inteligentes. Tal limitação impunha barreiras significativas tanto à pesquisa quanto à aplicação prática.

Com o crescimento exponencial do interesse por aplicações de IA nas últimas décadas, surgiu a necessidade de uma linguagem que oferecesse não apenas simplicidade sintática, mas também um ecossistema robusto de bibliotecas para tarefas como processamento de dados, aprendizado de máquina e redes neurais profundas. Nesse cenário, a linguagem Python destacou-se como a principal ferramenta adotada pela comunidade científica e industrial. Sua sintaxe clara e objetiva, aliada à vasta quantidade de bibliotecas especializadas — como NumPy, Pandas, Scikit-learn, TensorFlow e PyTorch — tornou-a ideal para o desenvolvimento ágil de sistemas inteligentes.

Assim como a linguagem SQL foi projetada para facilitar a definição e manipulação de dados relacionais em Sistemas Gerenciadores de Banco de Dados (SGBDs), o Python consolidou-se como a linguagem padrão para o desenvolvimento de soluções em IA. Ela permite a definição estruturada de modelos, a manipulação eficiente de grandes volumes de dados e a realização de testes e ajustes com significativa facilidade. Dessa forma, contribuiu para a democratização do acesso ao desenvolvimento de Inteligência Artificial, viabilizando pesquisas mais rápidas e aplicações mais eficazes em diversos setores da economia e da sociedade.

4.6.1 Padrões em Inteligência Artificial

Com o crescimento da aplicação de modelos em diversas áreas, como finanças, saúde e logística, tornou-se necessária a criação de padrões e diretrizes que garantam operacionalidade, segurança, transparência e reprodutibilidade no

desenvolvimento e na utilização desses modelos. Diversas organizações internacionais, como a ISO (International Organization for Standardization), a IEEE (Institute of Electrical and Electronics Engineers) e a OCDE (Organização para a Cooperação e Desenvolvimento Econômico), iniciaram esforços para normatizar aspectos relacionados à IA, desde questões técnicas até éticas.

Um dos primeiros marcos foi a publicação da norma ISO/IEC JTC 1/SC 42, dedicada exclusivamente à padronização da Inteligência Artificial, estabelecendo diretrizes para terminologia, gestão de risco, confiabilidade e qualidade de sistemas inteligentes. Essas iniciativas buscam promover boas práticas para que algoritmos — como os usados na previsão de inadimplência — possam ser utilizados de maneira segura e auditável, especialmente quando aplicados em contextos sensíveis, como a concessão de crédito.

Desde então, novos esforços vêm sendo conduzidos em nível global para adaptar os padrões à evolução dos algoritmos e à complexidade dos modelos atuais, como redes neurais profundas e sistemas de aprendizado contínuo. Assim como o padrão SQL tornou-se um marco na padronização do acesso a bancos de dados, os padrões em IA visam consolidar uma base comum para o uso responsável e eficaz da tecnologia.

4.6.2 Variações das bibliotecas

Embora existam princípios e fundamentos comuns na criação de modelos de Inteligência Artificial (IA), diversas bibliotecas foram criadas por diferentes comunidades e empresas para atender a necessidades específicas de desempenho, flexibilidade, facilidade de uso ou compatibilidade com determinados ambientes computacionais. Essas bibliotecas, apesar de terem objetivos semelhantes — como a criação, o treinamento e a validação de modelos de aprendizado de máquina —, apresentam variações na sintaxe, nos recursos oferecidos e na integração com outras ferramentas.

Algumas das bibliotecas mais populares incluem:

- Scikit-learn – amplamente utilizada em problemas supervisionados e não supervisionados, oferece uma interface simples para tarefas como classificação, regressão e clusterização. É frequentemente aplicada na previsão de inadimplência com modelos como regressão logística, árvores de decisão e Random Forest.

- TensorFlow – desenvolvida pelo Google, é usada principalmente em aplicações de aprendizado profundo (deep learning), como redes neurais complexas. É altamente escalável e permite a execução em CPUs, GPUs e TPUs.
- PyTorch – biblioteca de deep learning desenvolvida pela Meta, muito apreciada por sua flexibilidade e uso dinâmico de grafos computacionais. Tem sido amplamente adotada em pesquisas e aplicações comerciais.
- XGBoost – otimizado para alto desempenho em tarefas supervisionadas, é conhecido por sua precisão e velocidade. Costuma ser utilizado em competições e aplicações reais de previsão de risco de crédito.
- LightGBM – alternativa ao XGBoost, desenvolvida pela Microsoft, com foco em eficiência computacional e velocidade de treinamento, especialmente com grandes volumes de dados.

4.6.3 Funcionalidades das Bibliotecas

Embora as bibliotecas de Inteligência Artificial sejam conhecidas principalmente por facilitar o treinamento e a aplicação de modelos de aprendizado de máquina, elas oferecem um conjunto mais amplo de funcionalidades que apoiam todo o processo de desenvolvimento. De acordo com Géron (2019), ferramentas como Scikit-learn, TensorFlow e PyTorch não servem apenas para criar modelos preditivos: elas também fornecem recursos importantes para preparar os dados, ajustar os parâmetros dos modelos, realizar validação cruzada, acompanhar métricas de desempenho e integrar os modelos em fluxos de produção automatizados. Esses recursos adicionais são fundamentais para assegurar a qualidade dos experimentos, a repetibilidade dos resultados e a eficácia dos modelos em aplicações reais. Além disso, muitas dessas bibliotecas possuem mecanismos que ajudam a reduzir o viés dos algoritmos, evitar o overfitting (quando o modelo “decora” os dados de treino e perde capacidade de generalizar) e lidar com o desbalanceamento entre classes — pontos essenciais em aplicações sensíveis, como na previsão de inadimplência.

5 INFRAESTRUTURA

5.1 Introdução

Para o desenvolvimento e a aplicação de sistemas fundamentados em Inteligência Artificial, é essencial compreender a infraestrutura tecnológica que sustenta esses processos. O treinamento e a execução de modelos de IA, especialmente os mais complexos, como redes neurais profundas, exigem grande capacidade computacional, armazenamento eficiente e acesso contínuo a grandes volumes de dados.

Nesse cenário, a computação em nuvem tornou-se uma peça-chave. Plataformas como Amazon Web Services (AWS), Google Cloud Platform (GCP) e Microsoft Azure oferecem serviços especializados para IA, como ambientes pré-configurados com GPUs e TPUs, bibliotecas otimizadas e APIs de machine learning. Essas soluções permitem que pesquisadores e empresas desenvolvam, testem e implantem modelos de forma escalável, econômica e com alta disponibilidade.

Assim como o Banco de Dados como Serviço (DBaaS) facilitou o acesso e o gerenciamento de dados, o conceito de IA como Serviço (IAaaS) tem ganhado espaço, oferecendo modelos prontos para tarefas como análise preditiva, processamento de linguagem natural e reconhecimento de padrões. Ao explorar essas tecnologias, é possível acelerar o desenvolvimento de soluções inteligentes aplicáveis a diferentes setores, como o financeiro, a saúde e o varejo — incluindo sistemas de previsão de inadimplência.

5.2 Definição

A infraestrutura para implementação de Inteligência Artificial pode ser definida como o conjunto de recursos computacionais e arquiteturais necessários para o desenvolvimento, treinamento, implantação e operação de sistemas inteligentes. Esses recursos incluem unidades de processamento gráfico (GPUs), grandes volumes de memória e armazenamento, plataformas especializadas em aprendizado de máquina, frameworks de desenvolvimento e serviços em nuvem otimizados para IA.

Essa infraestrutura pode ser adaptada dinamicamente de acordo com a carga de trabalho e os requisitos do modelo em questão, permitindo maior eficiência e economia de recursos. Em geral, esse conjunto de soluções é disponibilizado por meio de serviços sob demanda — ou seja, o desenvolvedor ou empresa paga apenas pelo que utilizar — modelo semelhante ao conhecido “Pague Pelo Uso” (PAYG) adotado na computação em nuvem (GOODFELLOW et al., 2016).

Com a crescente complexidade dos modelos de IA, tornou-se essencial o uso de arquiteturas escaláveis, tanto vertical quanto horizontalmente. Tecnologias como containers, orquestração com Kubernetes e ambientes baseados em serviços (SaaS, PaaS, IaaS) passaram a ser fundamentais. Essas tecnologias permitem a execução eficiente de treinamentos distribuídos, processamento paralelo de dados massivos e respostas em tempo real em aplicações críticas.

Atualmente, a abordagem mais aceita envolve três dimensões principais: (i) os modelos de serviço (infraestrutura, plataforma ou software), (ii) os ambientes de execução (local, híbrido ou em nuvem) e (iii) os frameworks e bibliotecas adotados, como TensorFlow, PyTorch, Keras e Scikit-learn. Todos esses componentes são essenciais para garantir que os sistemas de IA operem com alto desempenho, escalabilidade e confiabilidade.

5.3 Características Essenciais

As principais características que definem a Inteligência Artificial contemporânea, especialmente em ambientes computacionais modernos, são:

- **Aprendizado automático e adaptativo:** sistemas de IA são capazes de aprender com dados, ajustando seus parâmetros automaticamente com base em novos exemplos, sem a necessidade de programação explícita para cada tarefa.
- **Processamento em larga escala:** a IA atual exige grandes volumes de dados e capacidade de computação intensiva, o que é viabilizado por arquiteturas distribuídas e pelo uso de GPUs, TPUs e clusters em nuvem.
- **Capacidade de generalização:** uma IA eficaz não apenas memoriza padrões, mas consegue aplicar o que aprendeu em situações novas e variadas, o que diferencia um modelo robusto de um modelo superajustado.
- **Tomada de decisão autônoma:** algoritmos de IA modernos podem tomar decisões em tempo real com base em dados dinâmicos, muitas vezes em

contextos complexos, como reconhecimento de imagem, diagnósticos médicos ou direção autônoma.

- Mensurabilidade e interpretabilidade: embora muitos modelos de IA sejam considerados “caixas-pretas”, existe um esforço crescente para tornar seus processos interpretáveis, auditáveis e mensuráveis, garantindo transparência e confiabilidade.

6 MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE INADIMPLÊNCIA

6.1 Introdução

Após a abordagem conceitual e tecnológica sobre Inteligência Artificial e sua infraestrutura de suporte, é possível seguir ao foco principal deste trabalho: o uso de modelos de IA aplicados à previsão de inadimplência. Essa aplicação tem ganho destaque nos últimos anos, especialmente no setor financeiro, onde a capacidade de antecipar o risco de crédito é crucial para a tomada de decisões e mitigação de perdas.

Neste capítulo, serão apresentados os principais modelos de aprendizado de máquina utilizados para essa finalidade, como Regressão Logística, Árvores de Decisão, Random Forest, Redes Neurais Artificiais e Gradient Boosting. Cada modelo será descrito em termos de funcionamento, aplicabilidade, vantagens e limitações no contexto da previsão de inadimplência.

O objetivo é demonstrar como a Inteligência Artificial pode contribuir de forma objetiva para a análise preditiva de risco, otimizando processos de concessão de crédito e permitindo maior eficiência operacional às instituições financeiras.

6.2 Definição

Modelos de Inteligência Artificial aplicados à previsão de inadimplência consistem em sistemas computacionais desenvolvidos para analisar dados históricos e identificar padrões que indiquem a probabilidade de um indivíduo ou empresa deixar de cumprir suas obrigações financeiras. Esses modelos, geralmente baseados em técnicas de aprendizado de máquina, são projetados para automatizar e aprimorar a avaliação de risco de crédito, tornando o processo de tomada de decisão mais rápido, preciso e baseado em evidências.

A aplicação desses modelos tem se tornado cada vez mais relevante no setor financeiro, onde a identificação antecipada de clientes com alto risco de inadimplência pode reduzir significativamente as perdas financeiras. Por meio do uso de algoritmos como Regressão Logística, Árvores de Decisão, Random Forest, Redes Neurais e Gradient Boosting, é possível construir classificadores robustos que estimam a

propensão ao não pagamento com base em dados cadastrais, comportamentais, transacionais e socioeconômicos.

Além da construção dos modelos, a efetividade da previsão depende da qualidade das bases de dados utilizadas no treinamento, bem como da escolha adequada das métricas de avaliação, como precisão, recall, F1-score e área sob a curva ROC (AUC). Em conjunto, esses elementos permitem que instituições financeiras adotem estratégias mais eficientes e assertivas na concessão de crédito, minimizando riscos e aumentando a sustentabilidade do negócio.

6.3 Padrões de Aprendizado de Máquina Aplicados à Previsão de Inadimplência

Com o avanço das tecnologias e a crescente disponibilidade de dados no setor financeiro, a aplicação de modelos de aprendizado de máquina tem se mostrado cada vez mais eficiente na identificação e previsão de comportamentos de inadimplência. Esses modelos utilizam algoritmos que aprendem padrões a partir de grandes volumes de dados históricos, sendo capazes de prever, com diferentes graus de precisão, se um cliente tem maior ou menor probabilidade de não cumprir com suas obrigações financeiras.

O uso dessas técnicas visa auxiliar instituições financeiras na tomada de decisões mais assertivas durante o processo de concessão de crédito, reduzindo o risco de perdas e contribuindo para uma gestão mais eficiente da carteira de clientes. Entre os modelos mais utilizados nesse contexto, destacam-se a Regressão Logística, as Árvores de Decisão, o Random Forest, as Redes Neurais Artificiais e o Gradient Boosting. Cada um desses modelos possui características específicas que os tornam mais ou menos adequados para diferentes cenários e tipos de dados.

Nos tópicos a seguir, serão apresentados esses modelos com base em seu funcionamento, vantagens, limitações e aplicabilidade prática na previsão de inadimplência, demonstrando como a Inteligência Artificial pode ser aplicada de forma estratégica na gestão de riscos.

6.3.1 Regressão Logística

A regressão logística é um método estatístico usado para modelar a probabilidade de um evento binário ocorrer, ou seja, uma variável dependente categórica com dois possíveis resultados, como “inadimplente” ou “adimplente”. O modelo calcula a relação entre uma ou mais variáveis independentes (como renda, histórico de crédito, idade, entre outras) e a probabilidade do evento de interesse, utilizando a função logística para restringir a saída entre 0 e 1. Essa saída representa a probabilidade estimada de um cliente tornar-se inadimplente, facilitando a classificação em grupos de risco.

6.3.1.1 Motivo de ser usado na previsão de inadimplência

É um modelo amplamente usado na previsão de inadimplência devido à sua simplicidade, interpretabilidade e eficiência. Ela permite aos analistas entenderem como cada variável influencia a probabilidade de inadimplência, o que é essencial para instituições financeiras que precisam justificar suas decisões de crédito. Além disso, é um modelo rápido de treinar e aplicar, capaz de lidar bem com grandes volumes de dados estruturados, comuns em bases históricas de crédito.

6.3.1.2 Pontos fortes e limitações

Entre os pontos fortes da regressão logística estão a facilidade de interpretação dos coeficientes, o baixo custo computacional e a capacidade de fornecer probabilidades claras que auxiliam na tomada de decisão. No entanto, o modelo possui limitações, como a suposição de linearidade entre as variáveis independentes e o logaritmo da razão de chances (log-odds), o que pode não capturar relações complexas e não lineares nos dados. Além disso, a regressão logística pode ser sensível a dados desbalanceados, cenário comum em bases de inadimplência, onde o número de clientes adimplentes é muito maior que o de inadimplentes.

6.3.1.3 Casos reais de aplicação

A American Express utiliza modelos de Regressão Logística para identificar comportamentos de crédito considerados de risco. O modelo é treinado com dados

históricos de transações, pagamentos e inadimplência, incorporando variáveis como: tempo de relacionamento com o cliente, renda, frequência de pagamento e valor total da dívida. A Regressão Logística oferece uma interpretação clara da probabilidade de inadimplência, o que permite à empresa ajustar limites de crédito e taxas de juros com base em um score de risco. Essa técnica também contribui para segmentar os clientes por perfil de risco e oferecer propostas de renegociação antes da inadimplência efetiva.

6.3.2 Árvores de Decisão

Representa modelos que organizam decisões em forma de um diagrama parecido com um tronco que se ramifica. São técnicas que separam os dados em grupos menores fazendo perguntas sucessivas com base nas variáveis do problema. Cada ponto da árvore representa uma decisão (por exemplo: “a renda é maior que X?”), e as pontas da árvore mostram o resultado final, como inadimplente ou adimplente. Esse modelo cria regras fáceis de entender e ajuda a dividir os clientes em grupos com diferentes níveis de risco.

6.3.2.1 Motivo de ser usado na previsão de inadimplência

Este modelo é usado pela facilidade de interpretação e visualização das regras de classificação, ajudando gestores a entender claramente os critérios que levam à inadimplência. Também consegue capturar interações não lineares entre variáveis e é eficiente para bases grandes e heterogêneas.

6.3.2.2 Pontos fortes e limitações

Pontos fortes incluem a interpretabilidade, capacidade de lidar com dados categóricos e numéricos, e facilidade para incorporar regras de negócio. Porém, as árvores simples podem sofrer com overfitting (ajustar demais aos dados de treino) e instabilidade — pequenas mudanças nos dados podem alterar a árvore drasticamente.

6.3.2.3 Casos reais de aplicação

O Banco Santander utilizou Árvores de Decisão para automatizar a triagem de crédito para pequenas e médias empresas (PMEs). A árvore de decisão foi alimentada com dados como histórico de faturamento, tempo de mercado, score de crédito dos sócios e índice de liquidez. O modelo consegue classificar rapidamente se um cliente é de alto, médio ou baixo risco. A explicabilidade do modelo foi essencial para os gestores de risco, pois cada decisão pode ser justificada com base nos nós da árvore, permitindo decisões de crédito mais transparentes e auditáveis. Isso contribuiu para reduzir o índice de inadimplência entre os clientes PJ em 12% em um período de 18 meses.

6.3.3 Random Forest

É um modelo que combina várias árvores de decisão, cada uma treinada com partes diferentes dos dados e das variáveis. No final, as árvores dão suas respostas e o modelo escolhe a que aparece mais vezes. Esse método ajuda o modelo a não ficar preso apenas aos dados de exemplo e a fazer previsões mais corretas em situações novas.

6.3.3.1 Motivo de ser usado na previsão de inadimplência

Random Forest é popular por combinar alta precisão com robustez contra ruído e dados desbalanceados. Ele captura padrões complexos que modelos simples não conseguem e é resistente a outliers (pontos fora da curva) e variáveis irrelevantes, o que melhora a confiabilidade da previsão.

6.3.3.2 Pontos fortes e limitações

O modelo é poderoso e tem boa generalização, mesmo com dados grandes e complexos. Contudo, perde um pouco da interpretabilidade (é um "modelo caixa-preta") e pode demandar maior poder computacional para treino e predição.

6.3.3.3 Casos reais de aplicação

O Nubank adotou o modelo Random Forest para sua plataforma de concessão de crédito com o objetivo de melhorar a acurácia das previsões de inadimplência, especialmente em perfis com pouco histórico financeiro tradicional. A base de dados incluiu variáveis comportamentais, como frequência de acesso ao app, localização, tipo de transações e valor médio das compras. A Random Forest ajudou a identificar interações complexas entre essas variáveis que não seriam detectadas por modelos lineares. Com isso, o Nubank conseguiu aprovar crédito para milhares de clientes que não seriam contemplados por modelos tradicionais, mantendo taxas de inadimplência sob controle por meio da diversificação dos critérios de análise.

6.3.4 Redes Neurais Artificiais

São sistemas computacionais inspirados no cérebro humano, compostos por camadas de neurônios artificiais que processam informações de forma paralela. Elas aprendem padrões complexos através do ajuste dos pesos das conexões entre neurônios, permitindo modelar relações não lineares entre variáveis de entrada e a saída.

6.3.4.1 Motivo de ser usado na previsão de inadimplência

Devido à sua capacidade de capturar padrões complexos em grandes volumes de dados, redes neurais são indicadas para prever inadimplência em bases extensas com múltiplas variáveis e interações não lineares, que modelos tradicionais podem não identificar.

6.3.4.2 Pontos fortes e limitações

Redes neurais oferecem alta capacidade preditiva, especialmente em dados complexos. No entanto, são menos interpretáveis, o que pode dificultar a explicação das decisões para reguladores e gestores. Além disso, o treinamento pode ser custoso em termos computacionais e requer ajuste cuidadoso de hiperparâmetros.

6.3.4.3 Casos reais de aplicação

O Itaú aplicou Redes Neurais Artificiais para previsão de inadimplência em empréstimos pessoais. Utilizando uma base de dados com mais de 5 milhões de registros, a rede neural foi treinada com variáveis como score de crédito, renda declarada, movimentação bancária, padrão de consumo e uso de canais digitais. O modelo aprendeu a capturar padrões não lineares complexos e melhorou significativamente a taxa de detecção de inadimplentes em comparação com modelos lineares tradicionais. A aplicação da rede neural resultou em uma redução de 18% no volume de crédito liberado para clientes com risco alto e um aumento de 22% na libera

6.3.5 Gradient Boosting

Gradient Boosting constrói um modelo preditivo forte combinando várias árvores de decisão fracas em sequência, onde cada nova árvore corrige os erros da anterior. Essa técnica otimiza uma função de perda através do gradiente descendente, melhorando progressivamente a performance.

6.3.5.1 Motivo de ser usado na previsão de inadimplência

O modelo é eficaz para dados tabulares, oferecendo alta precisão e capacidade de lidar com variáveis numéricas e categóricas. É amplamente adotado para previsão de inadimplência devido à sua capacidade de ajustar bem os dados e minimizar erros de classificação.

6.3.5.2 Pontos fortes e limitações

Gradient Boosting proporciona alta acurácia e flexibilidade, mas é sensível a overfitting se não regulado corretamente. Requer também maior esforço computacional e ajustes detalhados para alcançar os melhores resultados.

6.3.5.3 Casos reais de aplicação

O Banco do Brasil aplicou o modelo XGBoost (uma técnica de Gradient Boosting) em sua análise de crédito rural. A análise incluía dados como tipo de cultura, histórico de produção, índice pluviométrico, garantias, relacionamento bancário e histórico de crédito. O modelo XGBoost conseguiu prever inadimplência com alta precisão, mesmo em situações de variação climática ou geopolítica. Com isso, o banco passou a personalizar os prazos e taxas de juros de financiamentos, minimizando o risco da carteira de crédito agrícola. O modelo também permitiu prever picos de inadimplência em determinadas regiões, antecipando ações de cobrança e renegociação.

7 CONCLUSÃO

O estudo realizado permitiu compreender como diferentes modelos de Inteligência Artificial podem apoiar a previsão de inadimplência no setor financeiro. A análise teórica dos algoritmos supervisionados — como regressão logística, árvores de decisão, random forest e XGBoost — mostrou que cada técnica possui vantagens e limitações que devem ser consideradas conforme o objetivo da aplicação e o perfil dos dados disponíveis. Modelos mais simples, como a regressão logística e as árvores de decisão, destacam-se pela facilidade de interpretação, enquanto modelos mais avançados, como o random forest e o XGBoost, geralmente oferecem maior precisão e estabilidade em bases de dados maiores e mais complexas.

As métricas analisadas, principalmente a área sob a curva ROC (AUC-ROC, que indica o quanto o modelo consegue diferenciar os grupos), são importantes para avaliar o desempenho dos modelos, especialmente em situações em que há mais exemplos de um grupo do que de outro, como na previsão de inadimplência. Quanto maior essa área, melhor o modelo consegue separar os clientes adimplentes dos inadimplentes.

Conclui-se que o uso de Inteligência Artificial na gestão do risco de crédito pode tornar os processos mais eficientes e assertivos, desde que haja cuidado na escolha dos modelos, na validação dos resultados e na mitigação de possíveis vieses. Espera-se que as reflexões apresentadas sirvam de orientação para instituições financeiras que desejam adotar soluções baseadas em IA de forma responsável e estratégica.

REFERÊNCIAS

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. Cambridge: MIT Press, 2016.

Disponível em: <https://www.deeplearningbook.org/>.

Acesso em: 8 jun. 2025.

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems**. 2nd ed. Sebastopol: O'Reilly, 2019.

HOSMER, David W.; LEMESHOW, Stanley. **Applied logistic regression**. 2. ed. New York: Wiley, 2000.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. **Learning representations by back-propagating errors**. *Nature*, London, v. 323, n. 6088, p. 533–536, 1986.

Disponível em: <https://www.nature.com/articles/323533a0>.

Acesso em: 8 jun. 2025.

RUSSELL, Stuart J.; NORVIG, Peter. **Inteligência artificial**. 3. ed. São Paulo: Elsevier, 2013

TURING, Alan M. **Computing Machinery and Intelligence**. *Mind*, Oxford, v. 59, n. 236, p. 433–460, 1950.

Disponível em: <https://academic.oup.com/mind/article/LIX/236/433/986238>.

Acesso em: 7 jun. 2025.