

TENDÊNCIAS E AVANÇOS DO *MACHINE LEARNING* NA PREDIÇÃO DE INADIMPLÊNCIA NO SETOR AUTOMOTIVO

ALISSON RIBEIRO DA SILVA

Universidade Católica de Brasília

PAULO FERNANDO MARSCHNER

Universidade Católica de Brasília

EDUARDO AMADEU MORESI

Universidade Católica de Brasília

Resumo

Este estudo realizou uma análise bibliométrica da literatura internacional sobre o uso de técnicas de *machine learning* na predição de inadimplência, com foco no setor automotivo. Foram examinados 1.026 documentos publicados entre 2010 e 2025 na base Scopus, com o objetivo de identificar *clusters* temáticos, tendências emergentes e desafios metodológicos. Os resultados indicam um campo científico em rápida consolidação, caracterizado por expansão internacional, diversificação temática e amadurecimento metodológico. As evidências encontradas se organizam em quatro eixos principais: (i) consolidação do aprendizado de máquina como eixo central da modelagem de risco de crédito, substituindo gradualmente abordagens estatísticas tradicionais; (ii) ampliação metodológica, com destaque para redes neurais, aprendizado por reforço e modelos *ensemble*; (iii) crescente valorização da interpretabilidade e transparência algorítmica; e (iv) integração de múltiplas fontes de dados, combinando informações financeiras, textuais e tecnológicas. Além disso, observou-se a ausência de investigações sistemáticas sobre a aplicação de modelos de *machine learning* à predição de inadimplência especificamente no setor automotivo, o que evidencia uma lacuna relevante na literatura. As implicações dessas descobertas incluem a construção de um panorama estruturado das principais tendências, autores e metodologias, oferecendo subsídios teóricos e empíricos para o avanço das investigações futuras e o aperfeiçoamento de modelos preditivos de risco de crédito.

Palavras-chave: *Machine learning*, Inadimplência, Setor automotivo.

1 Introdução

O avanço das algoritmos de *Machine Learning* (ML) transformou profundamente o modo como as organizações tratam o risco de crédito, ampliando a capacidade de previsão e a tomada de decisão orientada por dados. Essa transformação acompanha a evolução dos sistemas empresariais integrados (ERP) e a disponibilidade de bases externas de crédito providas por *bureaus* especializados. No campo da modelagem preditiva de inadimplência, tradicionalmente sustentado por regressões logísticas, observa-se uma expansão para algoritmos capazes de lidar com não linearidades, desbalanceamento e variáveis heterogêneas (Brown & Mues, 2012; Wang *et al.*, 2011).

A inadimplência é um dos principais desafios da gestão de risco de crédito, com forte impacto na sustentabilidade financeira das empresas. No setor automotivo, essa questão se acentua pelo peso das vendas a prazo e dos financiamentos. A digitalização dos processos e o volume crescente de dados transacionais impulsionam o uso de técnicas de ML como alternativa aos métodos estatísticos tradicionais, permitindo decisões de crédito baseadas em padrões históricos e múltiplas fontes de dados.

Em 2025, o setor automotivo brasileiro enfrenta retração do crédito e aumento da inadimplência, atingindo 5,7% no primeiro trimestre, ante 3,6% no mesmo período de 2024. O volume de crédito para financiamento de veículos caiu 4,3%, totalizando R\$ 57,7 bilhões, reflexo de juros elevados e maior seletividade das instituições financeiras. A taxa Selic em 15% ao ano, o maior patamar desde 2006, elevou o custo do crédito e limitou a capacidade de pagamento de famílias e empresas (Anfavea; Anef; Reuters, 2025). Esse contexto reforça a necessidade de ferramentas analíticas capazes de antecipar riscos e orientar decisões de financiamento com maior precisão.

O aumento da inadimplência nesse setor compromete o fluxo de caixa e restringe o crédito em toda a cadeia automotiva. Compreender os fatores determinantes do não pagamento é, portanto, essencial para formular estratégias de mitigação e aprimorar os mecanismos de avaliação de crédito. Em termos conceituais, a inadimplência corresponde ao não cumprimento das obrigações financeiras no prazo contratual (Silva & Neves, 2020), enquanto o risco de crédito representa a probabilidade de que uma contraparte deixe de honrar suas obrigações, gerando perdas financeiras (Saunders & Allen, 2021). Ambos os conceitos fundamentam a necessidade de mensuração e previsão precisas para garantir estabilidade financeira e eficiência operacional.

Embora o uso de técnicas de ML na modelagem de risco de crédito venha crescendo, pouco se sabe sobre como esse movimento se manifesta no contexto do setor automotivo. A produção científica nessa interface parece dispersa entre diferentes áreas (finanças, ciência de dados e engenharia de produção), o que suscita a necessidade de compreender sua estrutura e evolução. Dado esse contexto, o objetivo deste estudo foi realizar uma análise bibliométrica da literatura internacional sobre o uso de técnicas de ML na predição de inadimplência, com foco no setor automotivo. Foram analisados 1.026 documentos, publicados entre janeiro/2010 e setembro/2025 e extraídos da base Scopus, para identificar clusters temáticos, tendências emergentes e desafios metodológicos.

Entre os principais achados, destacam-se: i) a consolidação do ML como eixo central da predição de inadimplência, substituindo gradualmente os modelos estatísticos tradicionais por abordagens mais flexíveis e autoadaptativas; ii) a ampliação da dimensão metodológica, com ênfase em redes neurais, aprendizado por reforço e modelos *ensemble*, que aumentam a precisão e a capacidade de generalização; iii) a valorização crescente da interpretabilidade e da transparência algorítmica, indicando uma preocupação com a rastreabilidade e a confiança nos modelos aplicados; e iv) a integração de múltiplas fontes de dados, combinando informações financeiras, textuais e tecnológicas para aprimorar a robustez das previsões e expandir o uso em diferentes contextos, como pequenas empresas e cadeias de suprimentos. Adicionalmente, identificou-se a ausência de investigações sistemáticas sobre a aplicação de modelos de ML especificamente à predição de inadimplência no setor automotivo, revelando uma lacuna relevante e uma oportunidade para o avanço de pesquisas futuras nesse domínio.

Esses resultados contribuem, teórica e empiricamente, para o avanço da compreensão sobre a evolução da modelagem de risco de crédito, ao evidenciar a convergência da literatura em torno de frameworks híbridos, explicáveis e justos, que buscam equilibrar precisão, adaptabilidade e equidade nas decisões de crédito. Do ponto de vista teórico, essa convergência representa uma transformação epistemológica do campo, que passa a integrar dimensões técnicas e éticas na concepção dos modelos preditivos. Sob a perspectiva empírica, destaca-se a consolidação de práticas orientadas por transparência, interpretabilidade e responsabilidade algorítmica, refletindo a maturação científica e aplicada do ML na gestão de risco financeiro.

2 Revisão de Literatura

O estudo da inadimplência e do risco de crédito tem origem nos esforços para mensurar e prever o comportamento de tomadores de recursos, buscando reduzir a incerteza associada às decisões financeiras. Desde as primeiras formulações econométricas, a preocupação central foi desenvolver instrumentos quantitativos que apoiassem o julgamento dos analistas e das instituições financeiras. O modelo Z-Score de Altman (1968) representou um marco histórico nesse processo, ao combinar múltiplos indicadores contábeis em uma função discriminante capaz de estimar a probabilidade de falência. Essa abordagem inaugurou uma lógica de avaliação baseada em evidências empíricas e mensuração objetiva do risco, permitindo que a análise de crédito se consolidasse como um campo científico autônomo dentro das finanças corporativas.

Nas décadas seguintes, a prática evoluiu com o surgimento dos modelos de *credit scoring*, que ampliaram o uso de variáveis cadastrais e comportamentais para estimar o risco individual de cada tomador. Esses modelos, originalmente fundamentados em regressões lineares e técnicas estatísticas clássicas, tornaram-se a espinha dorsal das políticas de crédito bancário e do mercado de consumo. Conforme Thomas, Crook e Edelman (2017), a consolidação do *credit scoring* representou não apenas um avanço técnico, mas também uma transição epistemológica, de uma abordagem baseada na intuição e no julgamento subjetivo para uma fundamentada em evidências e probabilidades. Esse movimento delineou a identidade do campo como uma vertente aplicada da modelagem estatística, voltada ao equilíbrio entre precisão preditiva e interpretabilidade, estabelecendo as bases sobre as quais se desenvolveriam as abordagens contemporâneas de ML aplicadas ao risco de crédito.

Com o avanço da capacidade computacional e da disponibilidade de dados, a modelagem preditiva de inadimplência expandiu-se para técnicas de ML, superando limitações dos modelos lineares tradicionais (Brown & Mues, 2012; Rubing *et al.*, 2011). Essa mudança reflete uma transição metodológica: os modelos passam a aprender padrões complexos em bases desbalanceadas e a capturar interações não lineares entre variáveis financeiras, cadastrais e comportamentais, elevando a precisão da previsão de inadimplência.

Lessmann *et al.* (2015) realizaram um estudo de *benchmarking* abrangente que comparou o desempenho de diversos algoritmos de classificação aplicados ao *credit scoring*, consolidando um marco de referência metodológica no campo. Os autores demonstraram que modelos baseados em ML (como *Random Forest* e *Gradient Boosting*) superaram significativamente a regressão logística tradicional em termos de acurácia e robustez, sobretudo em bases de dados complexas. Esse estudo impulsionou uma nova agenda de pesquisa voltada à experimentação e à comparação de métodos de classificação em contextos reais de crédito.

A literatura recente aponta o uso crescente de algoritmos como *Random Forest*, *Gradient Boosting* e *Redes Neurais Artificiais* (Xiao *et al.*, 2025; Wu *et al.*, 2025; Goldmann & Machado, 2025). Embora a regressão logística ainda seja amplamente empregada, métodos baseados em *ensemble learning* apresentam desempenho superior em bases complexas e volumosas. Zhu *et al.* (2025) propuseram uma arquitetura de rede neural profunda voltada ao crédito automotivo, obtendo resultados expressivos na classificação de clientes inadimplentes, reforçando o potencial das abordagens baseadas em *deep learning*.

O uso de dados híbridos, estruturados e não estruturados, tem ampliado o poder discriminatório dos modelos preditivos. Wu *et al.* (2025) exploraram variáveis textuais em relatórios de crédito, enquanto Zhang *et al.* (2025) e Liu *et al.* (2025) destacaram o potencial da adaptação de domínio (*domain adaptation*) e da engenharia de atributos para ajustar modelos a contextos corporativos específicos. Tais avanços indicam um movimento de integração entre abordagens quantitativas e heurísticas, combinando desempenho preditivo e interpretabilidade.

Apesar do progresso, persiste um *gap* científico relevante: a integração efetiva entre dados internos corporativos (como registros de ERP, histórico de pagamentos e limites de crédito) e indicadores externos, como *scores* de *bureaus* e variáveis macroeconômicas. Essa lacuna é particularmente evidente em estudos aplicados ao setor automotivo, cuja estrutura operacional combina crédito, logística e serviços de pós-venda, exigindo modelagens adaptadas à complexidade das operações empresariais. Essa fragmentação teórico-empírica reforça a necessidade de mapear sistematicamente o campo, identificando como a literatura tem evoluído em termos de métodos, dados e fundamentos conceituais.

Assim, as mudanças metodológicas observadas não apenas ampliam a precisão e a adaptabilidade dos modelos, mas também configuram uma transformação epistemológica na compreensão do risco de crédito, que passa a articular desempenho técnico, transparência e justiça algorítmica como dimensões complementares. Diante disso, uma investigação bibliométrica se justifica por permitir mapear a evolução teórica e empírica do campo, destacando tendências, lacunas e oportunidades de integração entre finanças e inteligência artificial.

3 Metodologia

A pesquisa adota uma abordagem integrada entre análise quantitativa e qualitativa, adequada a revisões sistemáticas e estudos bibliométricos. Essa combinação une rigor estatístico e interpretação contextual, possibilitando mapear tendências científicas e identificar lacunas teóricas no campo da predição de inadimplência (Moresi, Pinho & Costa, 2021). A coleta foi realizada na base Scopus, entre agosto e setembro de 2025, utilizando a expressão de busca apresentada na Tabela 1. A estratégia abrangeu três eixos temáticos: (i) inadimplência e risco de crédito, (ii) técnicas de ML e (iii) contexto empresarial e automotivo. Foram considerados documentos publicados entre 2010 e 2025, em inglês ou português, incluindo artigos, revisões e trabalhos de conferência. Os metadados foram refinados para assegurar consistência e reprodutibilidade, contemplando: (i) exclusão de duplicidades e registros incompletos; (ii) padronização de nomes de autores e instituições; e (iii) elaboração de um tesouro para unificar sinônimos e variações linguísticas (por exemplo, *credit risk*, *credit-risk assessment*). O processo seguiu as recomendações metodológicas de Zupic e Cater (2014).

Tabela 1 - Expressão de busca inicial.

```
( TITLE-ABS-KEY ( ( "payment delinquen*" OR "credit risk*" OR "commercial credit" OR "customer default*" OR "credit analysis" OR "credit default" OR "loan default" OR "default prediction" OR "non-performing loan*" OR "creditworthiness" OR "credit scoring" OR "delinquency prediction" OR "trade credit" OR "corporate credit risk" ) AND ( "machine learning" OR "artificial intelligence" OR "predictive model*" OR "data mining" OR "neural network*" OR "deep learning" OR "random forest" OR "support vector machine*" OR "gradient boosting" OR "xgboost" OR "ensemble learning" OR "logistic regression" OR "explainable AI" OR "feature selection" OR "classification algorithm*" OR "Knowledge Discovery in Databases" OR "KDD" ) AND ( "retail" OR "consumer" OR "B2B" OR "B2C" OR "wholesale" OR "business" OR "SME*" OR "dealer" OR "supplier" OR "service industry" OR "commercial credit" OR "trade receivables" OR "accounts receivable" OR "supply chain finance" OR "ERP system" OR "enterprise resource planning" OR "automotive" OR "automotive aftermarket" OR "auto parts" OR "spare parts" OR "tire*" OR "tyre*" OR "vehicle maintenance" OR "dealer*" OR "distributor*" OR "fleet management" OR "trucking" OR "road freight" OR "logistics" OR "sale*" ) ) AND NOT TITLE-ABS-KEY ( "bank*" OR "credit card" OR "mortgage" ) ) AND PUBYEAR > 2009 AND PUBYEAR < 2026 AND ( LIMIT-TO ( LANGUAGE , "English" ) OR LIMIT-TO ( LANGUAGE , "Portuguese" ) )
```

Fonte: elaborado pelos autores.

A *string* de busca foi elaborada para garantir precisão e abrangência na recuperação dos estudos. A estratégia combina três blocos temáticos conectados por operadores booleanos: (i)

risco de crédito e inadimplência (*paymentdelinquency, credit risk, loan default*); (ii) métodos de inteligência artificial e modelagem preditiva (*machine learning, neural network, random forest, XGBoost, explainable AI*); e (iii) contexto empresarial e automotivo (*retail, automotive, ERP system, dealer, logistics*). Foram excluídos estudos sobre crédito bancário e pessoal por meio do operador NOT, assegurando a relevância dos resultados ao tema da pesquisa.

A análise quantitativa foi conduzida com os softwares VOSviewer (v.1.6.20), Bibliometrix/Biblioshiny (RStudio, v.4.3.3) e Gephi (v.0.10.1). No VOSviewer, aplicou-se o algoritmo Leiden (resolução = 1.0; mínimo de 5 ocorrências por palavra-chave), com normalização por *association strength* e agrupamento segundo a centralidade de autovetor (Callon *et al.*, 1983). O Bibliometrix foi empregado para gerar indicadores bibliométricos clássicos, número de publicações por ano, taxa de crescimento, colaboração internacional, fontes mais produtivas, citações médias e *Three-Field Plot* (autores–instituições–países). Por fim, o Gephi foi utilizado para calcular métricas de rede (*degree, betweenness centrality e modularityclass*), permitindo identificar comunidades e relações de coautoria e cocitação. O uso combinado dessas ferramentas garante complementaridade: o VOSviewer oferece visualização semântica, o Bibliometrix fornece estatísticas descritivas e o Gephi evidencia a estrutura relacional das redes.

Com base nos resultados quantitativos, procedeu-se à análise qualitativa dos *clusters* identificados. Essa etapa seguiu o princípio de triangulação metodológica (Denzin, 1978), associando métricas de centralidade e frequência à leitura contextual dos estudos mais citados e recentes. Tal procedimento assegura uma interpretação integrada das tendências, contribuindo para a identificação de lacunas teóricas e oportunidades de pesquisa futura.

4 Resultados

Os metadados foram exportados em formato CSV e processados no Bibliometrix (RStudio) para o cálculo dos principais indicadores bibliométricos. A Tabela 2 apresenta um panorama sintético do conjunto analisado, permitindo visualizar a distribuição de documentos, fontes, autores e métricas de impacto.

Tabela 2 – Indicadores gerais da amostra bibliográfica (2010–2025).

Indicador	Valor	Interpretação
Período de análise	2010–2025	15 anos de produção científica
Total de documentos	1.026	Corpo de pesquisa moderado e coeso
Fontes (revistas, conferências etc.)	377	Alta diversidade de canais de publicação
Taxa de crescimento anual	12,81%	Expansão contínua do interesse acadêmico
Idade média dos documentos	4,48 anos	Produção recente e dinâmica
Citações médias por documento	16,66	Bom impacto e visibilidade
Referências citadas	6.515	Base bibliográfica densa e interconectada
Total de autores	1.940	Comunidade científica expressiva
Média de coautores por artigo	6,01	Forte colaboração interdisciplinar
Colaboração internacional	17,64%	Nível moderado de intercâmbio global

Fonte: elaborado pelos autores.

As principais áreas de publicação foram *Computer Science* (42%), *Business, Management & Accounting* (28%) e *Engineering* (18%), evidenciando o caráter multidisciplinar do campo. A predominância de artigos e trabalhos de conferência reforça o dinamismo e a rápida disseminação de resultados, enquanto a presença de revisões sistemáticas indica certo grau de maturidade teórica. O uso combinado dos softwares VOSviewer e Gephi possibilitou identificar palavras-chave com maior centralidade de autovetor (Callon *et al.*, 1983) e mapear redes de coocorrência entre conceitos fundamentais, como *credit risk*

modeling, default prediction, data integration e explainable AI. Essas redes revelam os núcleos conceituais e as conexões estruturais que sustentam a literatura sobre predição de inadimplência. Foram identificadas 3.437 palavras-chave do tipo *Keywords Plus* e 2.134 fornecidas pelos autores, refletindo um vocabulário consolidado, embora com variações entre indexadores e pesquisadores. Essa diferença sugere nuances conceituais e potenciais tendências emergentes a serem exploradas em análises de coocorrência. Por fim, destaca-se o perfil colaborativo da comunidade científica, caracterizado pela ausência de publicações individuais e pela intensa cooperação institucional. Esse padrão indica a natureza interdisciplinar e aplicada do campo, que combina técnicas computacionais e aplicações empresariais.

A nuvem de palavras (Figura 1) gerada a partir das palavras-chave dos artigos, visualizando os termos mais frequentes e relevantes na literatura analisada. O tamanho de cada termo reflete sua ocorrência e importância relativa no *corpus*, destacando conceitos centrais como *machine learning*, *credit scoring*, *credit risk*, *logistic regression* e *default prediction*, que constituem o núcleo temático da pesquisa sobre predição de inadimplência com algoritmos de ML. Termos adicionais, como *ensemble learning*, *deep learning*, *feature selection* e *explainable artificial intelligence*, evidenciam a tendência contemporânea de aplicação de modelos híbridos e interpretáveis na análise de risco de crédito. Assim, a nuvem fornece uma representação intuitiva e exploratória da estrutura conceitual do campo, permitindo identificar os principais focos de investigação e as linhas metodológicas emergentes.


Figura 1 - Nuvem de palavras.



Fonte: elaborado pelos autores.

A Figura 2 apresenta a evolução das publicações entre 2010 e 2025. Verifica-se um crescimento gradual até 2018, seguido de uma expansão acentuada a partir de 2019, evidenciando a consolidação do interesse acadêmico no uso de técnicas de ML e inteligência artificial aplicadas à predição de inadimplência e risco de crédito. O ápice ocorre em 2024, com 167 publicações, refletindo o auge da produção científica sobre o tema, possivelmente impulsionado pelos avanços em modelagem preditiva e pela difusão de algoritmos como *XGBoost*, redes neurais profundas e aprendizado explicável. Em 2025, nota-se uma leve retração para 128 estudos, possivelmente refletindo um ajuste natural na produção anual, a consolidação do campo ou o fato de o ano ainda estar em curso, o que pode limitar o número de publicações indexadas. De forma geral, a tendência revela um processo de maturação temática, especialmente após 2020, quando a integração entre dados empresariais, algoritmos preditivos e gestão de risco passou a ocupar posição central na literatura científica.


Figura 2 - Evolução de publicações.



Fonte: elaborado pelos autores.

O VOSviewer foi utilizado para construir a rede de coocorrência de palavras-chave (Figura 3). Essa visualização permite identificar relações temáticas, bem como a intensidade das conexões entre os termos mais recorrentes, revelando clusters interconectados que refletem os principais eixos de pesquisa. Para garantir consistência e precisão nos resultados, elaborou-se um tesauro destinado à padronização de sinônimos, à eliminação de duplicidades e à unificação de variações linguísticas, por exemplo, tratando como equivalentes *credit risk*, *credit risks* e *credit-risk assessment*. Essa padronização previne a fragmentação temática, reduz distorções na interpretação da centralidade conceitual e assegura a fidelidade das redes de coocorrência, ampliando a comparabilidade entre estudos e a confiabilidade das análises produzidas pelo VOSviewer e por ferramentas complementares, como Gephi e Bibliometrix.

Figura 3 - Rede de coocorrência de palavras-chave.



Fonte: elaborado pelos autores a partir do VOSviewer.

O *cluster* vermelho concentra termos ligados à modelagem preditiva e ao pré-processamento de dados, como *credit scoring*, *data mining*, *feature selection* e *imbalanced datasets*, indicando atenção recorrente ao desempenho e à qualidade das bases utilizadas. O *cluster* azul destaca o eixo metodológico clássico, centrado em *logistic regression*, *decision trees* e *default prediction*, representando os fundamentos estatísticos ainda amplamente empregados na modelagem de risco de crédito. O *cluster* verde reúne os avanços em *machine learning* e *deep learning*, com ênfase em *artificial intelligence*, *ensemble models* e *interpretability*, sinalizando a evolução para métodos mais sofisticados e explicáveis. Já o *cluster* amarelo está relacionado às aplicações corporativas, conectando termos como *supply chain*, *small and medium enterprises* e *credit risk forecasting*, o que reflete o interesse crescente em expandir essas abordagens para contextos empresariais e operacionais. De forma geral, a rede evidencia elevada densidade e interconexão entre os termos, ressaltando a natureza interdisciplinar do campo e a integração progressiva entre técnicas, aplicações e fundamentos teóricos na pesquisa sobre inadimplência e risco de crédito.

A partir dessa estrutura conceitual mapeada, torna-se possível interpretar não apenas os núcleos temáticos consolidados, mas também as ausências e os vazios da rede, que indicam oportunidades promissoras de investigação. A análise detalhada da configuração revela que a literatura sobre predição de inadimplência e risco de crédito concentra-se majoritariamente em contextos bancários, de cartões de crédito e de financiamento ao consumidor, sem a ocorrência explícita de termos ou coocorrências associadas ao setor automotivo. Embora esse setor apareça pontualmente como campo de aplicação implícito, ele ainda não foi tematizado de forma autônoma, permanecendo diluído em estudos mais amplos sobre cadeia de suprimentos ou crédito comercial. Tal padrão evidencia um predomínio de pesquisas voltadas às instituições financeiras, com escassa ênfase nos mecanismos de crédito interempresarial, cuja estrutura de risco difere substancialmente do crédito bancário tradicional. Assim, a análise bibliométrica sustenta a identificação de uma lacuna relevante na literatura: a ausência de investigações sistemáticas sobre a aplicação de modelos de ML à predição de inadimplência no setor automotivo.


Complementando a análise da rede de coocorrência de palavras-chave, a investigação bibliométrica amplia a compreensão da estrutura conceitual e institucional do campo “ML Aplicado à Predição de Inadimplência”. Os resultados evidenciam um domínio científico em franca expansão, caracterizado por alta colaboração, relevância crescente e impacto moderado, embora significativo. Essa configuração confirma que se trata de uma área jovem e dinâmica, ainda em processo de consolidação, mas já marcada por sinais consistentes de maturação e reconhecimento internacional.

A análise integrada das relações entre países, instituições e palavras-chave, representada no *Three-Field Plot* (Figura 4), reforça essa percepção. O diagrama ilustra como termos específicos se conectam a determinados contextos geográficos e institucionais, permitindo identificar polos de produção e especialização temática. Observa-se que a produção científica se concentra majoritariamente na China, seguida por Índia e Estados Unidos, com participações relevantes de Espanha, Reino Unido, Indonésia, Itália, França, Coreia, Japão, Brasil, Canadá e Alemanha, um cenário que revela predominância asiática, embora com expressiva presença europeia.

No eixo das palavras-chave, sobressaem “*machine learning*” e “*credit scoring*”, acompanhadas por termos como “*credit risk*”, “*logistic regression*”, “*deep learning*”, “*artificial intelligence*”, “*supply chain finance*”, “*random forest*”, “*data mining*” e “*fintech*”, indicando ênfase nas aplicações de ML e análise de dados para a gestão de risco financeiro.

Quanto às instituições, destacam-se a Dalian University of Technology, a Hefei University of Technology e a Southwestern University of Finance and Economics, com colaborações internacionais envolvendo universidades como a Università degli Studi di Cagliari (Itália) e a Universidad Complutense de Madrid (Espanha). A categoria “not reported” refere-se a afiliações ausentes ou não padronizadas.

Figura 4 - relações entre país, universidades e palavras-chave.



Fonte: elaborado pelos autores.

A ligação predominante entre China e os termos “*machine learning*” e “*credit scoring*” evidencia a ênfase temática de pesquisadores e instituições chinesas, reforçada por vínculos com diversas universidades do país. A dispersão dos demais termos entre diferentes países e instituições indica interesse global e possíveis especializações institucionais, como a forte associação a “*supply chain finance*”, que sugere grupos consolidados nessa área. Esse panorama permite mapear atores-chave (países, universidades e autores), acompanhar tendências, identificar potenciais colaboradores e posicionar a pesquisa no cenário internacional, além de subsidiar políticas e financiamentos que explicam concentrações geográficas.

A análise dos artigos mais citados permite compreender o impacto científico e a influência estrutural das pesquisas no campo de ML aplicado à predição de inadimplência. O predomínio do periódico *Expert Systems with Applications* confirma seu papel como principal veículo de divulgação da área, evidenciando uma comunidade consolidada e um escopo voltado a sistemas inteligentes e aplicações analíticas. Entre os estudos de maior destaque, observa-se que os trabalhos com altos índices de citações locais (LC) e globais (GC) configuram o núcleo de influência tanto no recorte temático quanto no panorama internacional. O artigo de Brown e Mues (2012), com LC = 34 e GC = 557, representa uma referência seminal, enquanto Dumitrescu *et al.* (2022) (LC = 13; GC = 269), consolida a aplicação de métodos não lineares à modelagem de crédito.

Por outro lado, estudos com alta LC e baixa GC, como Bequé e Lessmann (2017), destacam-se pela relevância intrínseca dentro do campo, embora ainda não tenham alcançado ampla difusão internacional, o que pode estar associado ao foco temático restrito ou ao tempo de circulação. Já trabalhos com baixa LC e alta GC, como Wang *et al.* (2012) demonstram impacto global expressivo, mas menor aderência ao recorte específico desta análise. As

métricas normalizadas (NLC e NGC) permitem relativizar diferenças temporais e identificar tendências emergentes. Nesse sentido, Belhadi *et al.* (2025) apresenta desempenho elevado em ambas as métricas, sinalizando um potencial de impacto crescente, ainda que recente.

Tabela 3 - Documentos mais citados.

	Autores	Título	Revista	LC	GC
1	Brown, I.; Mues, C.	<i>An experimental comparison of classification algorithms for imbalanced credit scoring data sets</i>	Expert Systems with Applications	34	557
2	Bequé, A.; Lessmann, S.	<i>Extreme Learning Machines for Credit Scoring: An Empirical Evaluation</i>	Expert Systems with Applications	16	127
3	Dumitrescu, E.; Hué, S.; Hurlin, C.; Tokpavi, S.	<i>Machine learning for credit scoring: Improving logistic regression with non-linear decision-tree effects</i>	European Journal of Operational Research	13	269
4	Bahnsen, A. C.; Aouada, D.; Ottersten, B.	<i>Example-Dependent Cost-Sensitive Logistic Regression for Credit Scoring</i>	ICMLA Proceedings	12	124
5	Chang, Y.-C.; Chang, K.-H.; Wu, G.-J.	<i>Application of eXtreme Gradient Boosting Trees in the Construction of Credit Risk Assessment Models for Financial Institutions</i>	Applied Soft Computing	11	250
6	Blanco, A.; Pino-Mejías, R.; Lara-Rubio, J.; Rayo, S.	<i>Credit Scoring Models for the Microfinance Industry Using Neural Networks: Evidence from Peru</i>	Expert Systems with Applications	10	153
7	Bücker, M.; Szepannek, G.; Gosiewska, A.; Biecek, P.	<i>Transparency, Auditability, and Explainability of Machine Learning Models in Credit Scoring</i>	Journal of the Operational Research Society	9	106
8	Ariza-Garzón, M. J.; Arroyo, J.; Caparrini, A.; Segovia-Vargas, M. J.	<i>Explainability of a Machine Learning Granting Scoring Model in Peer-to-Peer Lending</i>	IEEE Access	7	113
9	Chang, Y.-C.; Chang, K.-H.; Chu, H.-H.; Tong, L.-I.	<i>Decision Tree-Based Short-Term Default Credit Risk Assessment Models</i>	Communications in Statistics – Theory and Methods	7	26
10	Belhadi, A.; Kamble, S. S.; Mani, V.; Benkhathi, I.; Touriki, F. E.	<i>An Ensemble Machine Learning Approach for Forecasting Credit Risk of Agricultural SMEs' Investments in Agriculture 4.0 through Supply Chain Finance</i>	Annals of Operations Research	5	50


Fonte: elaborado pelos autores.

De modo geral, a análise dos artigos mais citados vai além da contagem de referências: ela revela os vetores intelectuais e temáticos que estruturam o campo, destacando contribuições de alto impacto teórico e aplicado. Compreender por que determinados estudos se tornaram centrais, seja pela inovação metodológica, pela aplicabilidade prática ou pela aderência a temas estratégicos, oferece subsídios valiosos para posicionar novas pesquisas e fortalecer a inserção científica no ecossistema internacional.

A compreensão da estrutura conceitual se aprofunda quando se examina também a dimensão intelectual do campo, que revela as bases teóricas e as trajetórias de evolução dos principais temas. Essa dimensão evidencia não apenas a consolidação das abordagens estatísticas e computacionais, mas também a incorporação gradual de técnicas de inteligência artificial à gestão de risco de crédito, um movimento que, embora ainda concentrado no contexto financeiro tradicional, começa a se expandir para aplicações setoriais específicas, como o setor automotivo. Nesse sentido, a análise dos *Trend Topics* complementa e aprofunda

essa leitura ao evidenciar a dinâmica temporal dos temas dominantes em *credit scoring* e áreas correlatas. O gráfico (Figura 5) mostra a evolução dos tópicos de pesquisa e a consolidação de eixos temáticos, em que o tamanho das bolhas e a amplitude do intervalo interquartil indicam, respectivamente, a popularidade e a consistência dos temas em cada período analisado.

Figura 5 - Trend Topics.



Nota: a gráfico de Trend Topics cobre o período de 2018 a 2024.


Fonte: elaborado pelos autores.

Observa-se, a partir de 2022, a ascensão de temas ligados à inteligência artificial e ao ML, com destaque para *artificial intelligence*, *machine learning*, *deep learning*, *explainable AI* e *XGBoost*. Esse avanço reflete a difusão global das tecnologias de IA e sua aplicação crescente em contextos analíticos e decisórios. Paralelamente, persistem termos associados ao risco de crédito e às finanças (*credit risk model*, *risk assessment*, *credit default* e *credit rating*), evidenciando a continuidade do interesse científico em modelos de previsão e gestão de risco financeiro.

A convergência entre IA e finanças consolida-se como eixo dominante, incorporando algoritmos de ML em avaliação de crédito, detecção de fraudes e modelagem preditiva. O destaque para *explainable AI* reforça a preocupação com transparência e auditabilidade. Também emerge o termo *supply chain*, associado a estudos sobre resiliência logística, enquanto *artificial neural networks* demonstram a permanência de abordagens clássicas. Em síntese, o campo revela amadurecimento científico e interdisciplinar, orientado à busca por modelos mais precisos, interpretáveis e aplicáveis a contextos econômicos complexos.

Por fim, o mapa estratégico (Figura 6) organiza os temas de pesquisa em um plano bidimensional combinando centralidade, indicador de relevância e interconexão, e densidade, que expressa o desenvolvimento interno de cada tema. Essa configuração identifica quatro quadrantes: temas motores (altamente centrais e desenvolvidos), básicos (centrais, pouco desenvolvidos), de nicho (bem desenvolvidos, mas periféricos) e emergentes ou declinantes (pouco centrais e pouco desenvolvidos).

Figura 6 - Mapa estratégico



Fonte: elaborado pelos autores a partir do Bibliometrix.

No quadrante inferior direito, o *cluster* “Credit Scoring, Logistic Regression e Default Prediction” constitui o núcleo clássico e central, baseado em técnicas estatísticas consolidadas. Entre os quadrantes de temas básicos e motores, o *cluster* “Machine Learning, Credit Risk e Artificial Intelligence” emerge como o eixo mais dinâmico, com alta centralidade e densidade. No centro do mapa, o *cluster* “Bayesian Network, Reinforcement Learning e Decision Making” integra inferência probabilística e políticas adaptativas de decisão. Na parte superior esquerda, temas de nicho como “BP Neural Network, Green Supply Chain Finance e Model Interpretability” e “Cost-Sensitive Learning, Customer Credit Scoring e Deep Q-Network” exibem alta densidade e menor centralidade, refletindo especialização metodológica em contextos específicos. O *cluster* “Factor Analysis” atua como técnica complementar de diagnóstico e redução de variáveis, sem papel central na evolução do campo. A Tabela 4 apresenta artigos, achados e direções de cada *cluster*.

Tabela 4 - Análise dos artigos.

Cluster	Artigo	Principais achados	Desafios	Direções futuras
1. Bayesian Network, Reinforcement Learning e Decision Making	Credit risk scoring with Bayesian network models (Leong, 2016)	Modelos probabilísticos e adaptativos avançam na previsão de inadimplência e decisão de crédito. Redes bayesianas tratam bem desequilíbrio, censura e escalabilidade, superando regressão logística e redes neurais em precisão. O aprendizado de transferência bayesiano melhora a adaptação entre domínios, enquanto o aprendizado por reforço ajusta dinamicamente limiares de aceitação, ampliando a lucratividade.	Persistem desafios de adaptação e generalização a ambientes dinâmicos. O equilíbrio entre desempenho e interpretabilidade é limitado pela complexidade dos modelos. Integração em tempo real e validação com dados heterogêneos seguem essenciais à aplicação prática.	As pesquisas sugerem modelos híbridos que combinem redes bayesianas, aprendizado por reforço e transferência adaptativa, aliados a métodos explicáveis que mantenham rastreabilidade e desempenho. O feedback contínuo e o aprendizado online despontam como tendências para decisões mais ágeis.
	Bayesian network oriented transfer learning method for credit scoring model (Iwai, Akiyoshi & Hamagami, 2021)			
	Using reinforcement learning to optimize the acceptance threshold of a credit scoring model (Herasymovych, Märka & Lukason, 2019)			
2. BP Neural Network, Green Supply Chain Finance e Model Interpretability	Exploration on the financing risks of enterprise supply chain using back propagation neural network (Cai <i>et al.</i> 2020).	Redes neurais, como a BPNN (Rede Neural de Retropropagação), são eficazes na avaliação de riscos financeiros e ambientais em cadeias de suprimentos, lidando com relações não lineares. O modelo LMBP (<i>Levenberg-Marquardt Back Propagation</i>) superou o BPNN convencional em precisão, eficiência e generalização na certificação de materiais verdes. Modelos de aprendizado profundo em dois estágios melhoraram a métrica de desempenho, resolvendo problemas de desequilíbrio de dados e múltiplas fontes no financiamento verde.	Persistem dificuldades na interpretação dos modelos, no tratamento de dados assimétricos e escassos e na integração prática entre sustentabilidade e finanças. A complexidade das relações entre empresas e a falta de padronização de indicadores verdes afetam a confiabilidade. O ajuste de hiperparâmetros e a escalabilidade em bases reais permanecem desafiadores.	Recomenda-se aprimorar a transparência e interpretabilidade com técnicas de explicabilidade e validação cruzada. Expansão de modelos híbridos e multietapas, combinando aprendizado profundo e métodos estatísticos, pode aumentar a estabilidade. Fortalecer bases de dados ambientais e financeiras e desenvolver métricas padronizadas de risco verde são essenciais para aumentar a aplicabilidade prática.
	Assessing the risk of green building materials certification using the back-propagation neural network (Zhang, Zhang & Jiang, 2022)			
	Research on green supply chain finance risk identification based on two-stage deep learning (Liu <i>et al.</i> , 2024)			
3. Cost-Sensitive Learning, Learning, Customer Credit Scoring e Deep Q-Network	Cost-sensitive boosted tree for loan evaluation in peer-to-peer lending (Xia, Liu & Liu, 2017).	Abordagens avançadas de modelagem têm aprimorado a pontuação de crédito e a avaliação de risco em contextos de dados desbalanceados e ambientes dinâmicos. Esses métodos ajustam parâmetros e recompensas conforme o comportamento do sistema, promovendo maior lucratividade, precisão na identificação de inadimplentes, convergência mais rápida e maior estabilidade em comparação às abordagens tradicionais.	Lidar com dados desbalanceados, mudanças dinâmicas e métricas de lucratividade além de precisão é complexo. Modelos como DQN exigem grande volume de dados e podem ser sensíveis a parametrizações. Garantir robustez e interpretabilidade em diferentes contextos de crédito continua sendo um desafio.	Pesquisas futuras devem combinar aprendizado sensível a custos, ensembles dinâmicos e aprendizado por reforço, equilibrando precisão e adaptação. Funções de recompensa ajustáveis, métricas econômicas realistas e validação em múltiplos contextos podem tornar os sistemas de pontuação mais robustos e eficientes.
	Dynamic classifier ensemble model for customer classification with imbalanced class distribution (Xiao <i>et al.</i> , 2012)			
	Deep reinforcement learning with confusion-matrix-based dynamic reward function for customer credit scoring (Wang <i>et al.</i> 2022)			

4. Credit Scoring, Logistic Regression e Default Prediction	An experimental comparison of classification algorithms for imbalanced credit scoring data sets (Brown & Mues, 2012)	Técnicas de ensemble superam classificadores individuais na previsão de inadimplência, mostrando maior robustez a desequilíbrios de classe. A regressão logística mantém popularidade por sua simplicidade e interpretabilidade. Conjuntos de modelos apresentam desempenho superior, enquanto o aprendizado profundo, apesar do potencial, ainda é pouco explorado.	O desequilíbrio de classes ainda reduz a acurácia de alguns modelos, enquanto a baixa explicabilidade de técnicas complexas dificulta decisões financeiras. Os trade-offs entre erros tipo I e II afetam a avaliação de risco, e o uso do aprendizado profundo em contextos reais de crédito permanece limitado.	Pesquisas futuras devem priorizar métodos robustos a desequilíbrios e frameworks híbridos que aliem desempenho e interpretabilidade. A aplicação de aprendizado profundo explicável e a avaliação de modelos considerando métricas financeiras e custos de erro são direções promissoras.
	A comparative assessment of ensemble learning for credit scoring (Wang <i>et al.</i> , 2011)			
	Statistical and machine learning models in credit scoring: a systematic literature survey (Dastile, Celik & Potsane, 2020)			
5. Factor Analysis	Technology credit scoring model considering both SME characteristics and economic conditions: the Korean case (Moon & Sohn, 2010)	A análise fatorial reduz indicadores financeiros e não financeiros em modelos de previsão de risco de crédito. Aplicações em cadeias de suprimentos online com redes neurais profundas mostram alta precisão, superando SVM e regressão logística. Combinar variáveis financeiras e textuais melhora a previsão de inadimplência. Em PMEs tecnológicas, incluir atributos empresariais e condições econômicas aumenta a capacidade preditiva e apoia a gestão de crédito.	Integrar dados financeiros, textuais e tecnológicos em modelos coerentes é complexo. Redes profundas exigem grande volume de dados e têm baixa interpretabilidade, limitando sua aplicabilidade prática. A generalização dos modelos para diferentes setores e contextos econômicos, especialmente para PMEs e cadeias de suprimentos, permanece um desafio.	Pesquisas futuras devem integrar análise fatorial e aprendizado de máquina avançado, combinando múltiplas fontes de dados para aprimorar precisão e interpretabilidade. Explorar variáveis textuais, scorecards adaptativos e testes de estresse em diferentes cenários econômicos pode gerar modelos mais robustos e confiáveis para apoio à decisão de crédito.
	Application of deep learning neural network in online supply chain financial credit risk assessment (Xu & He, 2020)			
	Research on enterprise credit risk prediction based on text information (Zhang, 2021)			
6. Machine Learning, Credit Risk e Artificial Intelligence	A multiobjective weighted voting ensemble classifier based on differential evolution algorithm for text sentiment classification (Onan <i>et al.</i> , 2016)	Técnicas de ML como ensembles ponderados multiobjetivo, podem melhorar a previsão de risco de crédito, superando métodos tradicionais. Além disso, incorporar preocupações de justiça social e remover vieses indiretos por meio de regularizadores em modelos discriminativos, como regressão logística, aumenta a imparcialidade sem comprometer a acurácia.	Equilibrar desempenho preditivo e imparcialidade é complexo, pois vieses indiretos podem persistir mesmo sem variáveis sensíveis. Há também desafios de escalabilidade e adaptação a diferentes contextos de crédito, além da integração de métricas de justiça com métricas tradicionais de desempenho.	Pesquisas futuras devem desenvolver frameworks que integrem precisão e justiça de forma sistemática, explorando ensembles e regularização adaptativa. A incorporação de métricas sociais e jurídicas, combinada com validação em cenários reais com dados diversificados, permitirá modelos de crédito mais transparentes e éticos.
	Fairness-aware classifier with prejudice remover regularizer (Kamishima, <i>et al.</i> , 2012)			
	Fairness-aware learning through regularization approach (Kamishima, Akaho & Sakuma, 2011)			

Fonte: elaborado pelos autores.

A Tabela 4 evidencia a consolidação e diversificação das abordagens de modelagem no campo da previsão de inadimplência e decisão de crédito. Nota-se um movimento de transição entre técnicas estatísticas clássicas, como a regressão logística, e métodos avançados baseados em ML, reforço e redes neurais. Os clusters revelam um campo em amadurecimento: enquanto os modelos probabilísticos e adaptativos (*Cluster 1*) e as redes neurais aplicadas à cadeia de suprimentos verde (*Cluster 2*) ampliam a capacidade de generalização e precisão, emergem também preocupações com interpretabilidade, transparência e integração prática. As abordagens sensíveis a custos e ensembles dinâmicos (*Cluster 3*) introduzem métricas econômicas mais realistas e adaptabilidade a dados desbalanceados, e a persistência da regressão logística como referência conceitual (*Cluster 4*) mostra a busca por equilíbrio entre desempenho e explicabilidade.

Em paralelo, observa-se o avanço de estudos que incorporam múltiplas fontes de dados e dimensões éticas. A integração de dados financeiros, textuais e tecnológicos (*Cluster 5*) amplia a robustez e a relevância dos modelos para pequenas e médias empresas e cadeias de suprimentos. Já as pesquisas orientadas à justiça algorítmica (*Cluster 6*) apontam para uma virada normativa e social no uso do ML em crédito, com foco na mitigação de vieses e na equidade das decisões. De modo geral, a literatura converge para a construção de frameworks híbridos, interpretáveis e justos, capazes de equilibrar precisão, adaptabilidade e responsabilidade ética, desafios centrais para a próxima geração de modelos de risco de crédito.

5 Conclusão

O presente estudo teve como objetivo realizar uma análise bibliométrica da literatura internacional sobre o uso de técnicas de ML na predição de inadimplência, com ênfase no setor automotivo. Foram examinados 1.026 documentos publicados entre janeiro de 2010 e setembro de 2025, extraídos da base Scopus, a fim de identificar *clusters* temáticos, tendências emergentes e desafios metodológicos. Os resultados revelam um campo em rápida consolidação, caracterizado por expansão internacional, diversificação temática e amadurecimento metodológico.

As principais descobertas podem ser sintetizadas em quatro eixos: i) a consolidação do ML como núcleo da predição de inadimplência, substituindo gradualmente os modelos estatísticos tradicionais por abordagens mais flexíveis e autoadaptativas; ii) a ampliação da dimensão metodológica, com destaque para redes neurais, aprendizado por reforço e modelos *ensemble*, que aumentam a precisão e a capacidade de generalização; iii) o fortalecimento da agenda de interpretabilidade e transparência algorítmica, refletindo a preocupação crescente com a rastreabilidade e a confiança nos modelos; e iv) a integração de múltiplas fontes de dados, que aprimora a robustez das previsões e amplia as possibilidades de aplicação em diferentes contextos. Além desses achados, identificou-se a ausência de investigações sistemáticas voltadas à aplicação de modelos de ML na predição de inadimplência especificamente no setor automotivo, evidenciando uma lacuna relevante na literatura e um potencial promissor para o desenvolvimento de pesquisas futuras.

Esses achados oferecem contribuições teóricas e práticas relevantes. Do ponto de vista científico, o panorama bibliométrico delineado permite compreender a evolução das abordagens e das redes de produção que estruturam o campo. Para a prática gerencial, fornece subsídios estratégicos para o aprimoramento de modelos preditivos e para a adoção de políticas de crédito mais transparentes, explicáveis e alinhadas às exigências regulatórias. Assim, o estudo contribui para consolidar o ML como eixo técnico e epistemológico da inovação em gestão de risco de crédito.

Como desdobramentos futuros, recomenda-se aprofundar a análise qualitativa dos *clusters* mais influentes, com foco nos estudos que integram dados corporativos internos (histórico de pagamentos, registros ERP) e indicadores externos (scores de crédito, variáveis macroeconômicas). Sugere-se, ainda, a aplicação empírica de modelos híbridos no setor automotivo, de modo a avaliar sua acurácia e interpretabilidade em contextos reais. Por fim, a proposição de um *framework* operacional de apoio à decisão de crédito, baseado nos achados bibliométricos e nas técnicas mais eficazes de ML, representa uma via promissora para o avanço científico e a inovação gerencial no campo.

Reconhece-se, contudo, que a base Scopus, embora abrangente, pode apresentar viés de cobertura, sobretudo em relação à literatura técnica e a relatórios corporativos. A ausência de uniformidade terminológica entre autores também exige o uso de *tesauros* e revisões manuais complementares. Além disso, a análise de redes é sensível aos parâmetros utilizados (como limiares, algoritmos e períodos de coleta), o que requer que os resultados sejam interpretados dentro desses limites.

Referências

- Alonso, J. V., & Escot, L. (2025). Robust cross-validation of predictive models used in credit default risk. *Applied Sciences*, 15(10). <https://doi.org/10.3390/app15105495>
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589–609.
- Amarnadh, V., & Moparthi, N. R. (2024). Range control-based class imbalance and optimized granular elastic net regression feature selection for credit risk assessment. *Knowledge and Information Systems*, 66(9), 5281–5310. <https://doi.org/10.1007/s10115-024-02103-9>
- Associação Nacional dos Fabricantes de Veículos Automotores. (2025, agosto). Coletiva de Imprensa – Agosto 2025: Desempenho da Indústria Automotiva Brasileira. Anfavea.
- Associação Nacional dos Fabricantes de Veículos Automotores. (2025, setembro). Coletiva de Imprensa – Setembro 2025: Desempenho da Indústria Automotiva Brasileira. Anfavea.
- AutoIndústria. (2025, 26 de maio). Crédito cai e inadimplência no setor automotivo sobe para 5,7%. AutoIndústria. <https://www.autoindustria.com.br/2025/05/26/credito-cai-e-inadimplencia-no-setor-automotivo-sobe-para-57/>
- Bao, F., Liu, T., & Chen, F. (2025). Blockchain-driven double feedback fuzzy neural network for enhanced supply chain financial risk management. *Journal of Circuits, Systems and Computers*, 34(16). <https://doi.org/10.1142/S0218126625502573>
- Belhadi, A., Kamble, S. S., Venkatesh, V., Benkhathi, I., & Touriki, F. E. (2025). An ensemble machine learning approach for forecasting credit risk of agricultural SMEs' investments in agriculture 4.0 through supply chain finance. *Annals of Operations Research*, 345(2), 779–807. <https://doi.org/10.1007/s10479-021-04366-9>
- Breeden, J. L. (2021). A survey of machine learning in credit risk. *Journal of Credit Risk*, 17(3), 1–62. <https://doi.org/10.21314/JCR.2021.008>
- Brown, I., & Mues, C. (2012). An experimental comparison of classification algorithms for imbalanced credit scoring data sets. *Expert Systems with Applications*, 39(3), 3446–3453. <https://doi.org/10.1016/j.eswa.2011.09.033>
- Cai, X., Qian, Y., Bai, Q., & Liu, W. (2020). Exploration on the financing risks of enterprise supply chain using back propagation neural network. *Journal of Computational and Applied Mathematics*, 367, 112457. <https://doi.org/10.1016/j.cam.2019.112457>

- Callon, M., Courtial, J. P., Turner, W. A., & Bauin, S. (1983). From translations to problematic networks: An introduction to co-word analysis. *Social Science Information*, 22(2), 191–235. <https://doi.org/10.1177/053901883022002003>
- Costa, A. P., & Amado, J. (2018). Análise de conteúdo suportada por software (2ª ed.). Lisboa: Ludomedia.
- Dhaigude, R., & Lawande, N. (2022). Impact of artificial intelligence on credit scores in lending process. <https://doi.org/10.1109/IRT54583.2022.9791511>
- Dumitrescu, E., Hué, S., Hurlin, C., & Tokpavi, S. (2022). Machine learning for credit scoring: Improving logistic regression with non-linear decision-tree effects. *European Journal of Operational Research*, 302(1), 273–289. <https://doi.org/10.1016/j.ejor.2022.04.012>
- Ghoujdam, M., Chaabita, R., Elkhalfi, O., Zehraoui, K., Elalaoui, H., & Idamia, S. (2024). Consumer credit risk analysis through artificial intelligence: A comparative study between the classical approach of logistic regression and advanced machine learning techniques. *Cogent Economics and Finance*, 12(1). <https://doi.org/10.1080/23322039.2024.2414926>
- Goldmann, P., & Machado, M. (2025). Hybrid ensemble learning for credit default prediction in automotive finance. *Computational Economics*, 60(4), 1127–1145. <https://doi.org/10.1007/s10614-025-10962-9>
- Herasymovych, M., Märka, K., & Lukason, O. (2019). Using reinforcement learning to optimize the acceptance threshold of a credit scoring model. *Applied Soft Computing*, 84, 105697. <https://doi.org/10.1016/j.asoc.2019.105697>
- Iwai, K., Akiyoshi, M., & Hamagami, T. (2021). Bayesian network oriented transfer learning method for credit scoring model. *IEEE Transactions on Electrical and Electronic Engineering*, 16(9), 1195–1202. <https://doi.org/10.1002/tee.23417>
- Jorge, C. C., OgosiaAui, O. A. J., Guadalupe Mori, G., de Albuquerque, V., Pacheco, O., & Hugo, D. (2022). Machine learning for personal credit evaluation: A systematic review. *WSEAS Transactions on Computer Research*, 10, 62–73. <https://doi.org/10.37394/232018.2022.10.9>
- Kamishima, T., Akaho, S., & Sakuma, J. (2011). Fairness-aware learning through regularization approach. 2011 IEEE 11th International Conference on Data Mining Workshops (ICDMW), 643–650. <https://doi.org/10.1109/ICDMW.2011.83>
- Kamishima, T., Akaho, S., Asoh, H., & Sakuma, J. (2012). Fairness-aware classifier with prejudice remover regularizer. *Lecture Notes in Artificial Intelligence*, 7524, 35–50. https://doi.org/10.1007/978-3-642-33486-3_3
- Kruppa, J., Schwarz, A., Arminger, G., & Ziegler, A. (2013). Consumer credit risk: Individual probability estimates using machine learning. *Expert Systems with Applications*, 40(13), 5125–5131. <https://doi.org/10.1016/j.eswa.2013.03.019>
- Leong, C. K. (2016). Credit risk scoring with Bayesian network models. *Computational Economics*, 47(3), 423–446. <https://doi.org/10.1007/s10614-015-9505-8>
- Lessmann, S., Baesens, B., Seow, H.-V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, 247(1), 124–136.
- Liu, Y., Li, S., Yu, C., & Lv, M. (2024). Research on green supply chain finance risk identification based on two-stage deep learning. *Operations Research Perspectives*, 13, 100311. <https://doi.org/10.1016/j.orp.2024.100311>
- Liu, Y., Liu, S., & Lu, Y. (2025). Supply chain financial risk assessment: A modified graph attention neural network. *Finance Research Letters*, 86. <https://doi.org/10.1016/j.frl.2025.108285>

- Moon, T. H., & Sohn, S. Y. (2010). Technology credit scoring model considering both SME characteristics and economic conditions: The Korean case. *Journal of the Operational Research Society*, 61(4), 666–675. <https://doi.org/10.1057/jors.2009.7>
- Moresi, E. A. D., & Pinho, I. (2021). Proposta de abordagem para refinamento de pesquisa bibliográfica. *New Trends in Qualitative Research*, 9, 11–20. <https://doi.org/10.36367/ntqr.9.2021.11-20>
- Moresi, E. A. D., Pinho, I., & Costa, A. P. (2021). Análise bibliométrica: uma abordagem quantitativa e qualitativa. In 18th CONTECSI 2021 - Proceedings. <https://doi.org/10.5748/18CONTECSI/PSE/LIS/6736>
- Moresi, E. A. D., Pinho, I., & Costa, A. P. (2021). How to operate literature review through qualitative and quantitative analysis integration? In A. P. Costa, A. Moreira, M. C. Sánchez-Gómez, & S. Wa-Mbaleka (Eds.), *Computer Supported Qualitative Research* (pp. 194–210).
- Onan, A., Korukoğlu, S., & Bulut, H. (2016). A multiobjective weighted voting ensemble classifier based on differential evolution algorithm for text sentiment classification. *Expert Systems with Applications*, 62, 1–16. <https://doi.org/10.1016/j.eswa.2016.06.005>
- Reuters. (2025). Brazil interest rates must stay on hold until data converge, says CenBank director. Reuters. <https://www.reuters.com/world/americas/brazil-interest-rates-must-stay-hold-until-data-converge-says-cenbank-director-2025-10-16/>
- Saunders, A., & Allen, L. (2021). *Credit risk management in and out of the financial crisis: New approaches to value at risk and other paradigms* (4th ed.). Wiley.
- Sharma, A. K., Li, L.-H., & Ahmad, R. (2023). Default risk prediction using random forest and XGBoosting classifier. *Smart Innovation, Systems and Technologies*, 314, 91–101. https://doi.org/10.1007/978-3-031-05491-4_10
- Silva, J. P., & Neves, M. F. (2020). *Gestão de riscos corporativos: Teoria e prática*. Atlas.
- Sun, Y., Jian, W., Fu, Y., Sun, H., Zhu, Y., & Bai, Z. (2021). A new perspective of credit scoring for small and medium-sized enterprises based on invoice data. <https://doi.org/10.1109/CDS52072.2021.00088>
- Teles, G., Rodrigues, J. J. P. C., Kozlov, S. A., Rabêlo, R. A. L., & de Albuquerque, V. H. C. (2021). Decision support system on credit operation using linear and logistic regression. *Expert Systems*, 38(6). <https://doi.org/10.1111/exsy.12578>
- Thomas, L. C., Crook, J. N., & Edelman, D. B. (2017). *Credit scoring and its applications* (2nd ed.). Society for Industrial and Applied Mathematics (SIAM).
- Wang, G., Hao, J., Ma, J., & Jiang, H. (2011). A comparative assessment of ensemble learning for credit scoring. *Expert Systems with Applications*, 38(1), 223–230. <https://doi.org/10.1016/j.eswa.2010.06.048>
- Wang, Y., Jia, Y., Tian, Y., & Xiao, J. (2022). Deep reinforcement learning with the confusion-matrix-based dynamic reward function for customer credit scoring. *Expert Systems with Applications*, 200, 117013. <https://doi.org/10.1016/j.eswa.2022.117013>
- Wang, Y., Li, S., & Zhang, X. (2011). A comparative study on credit scoring models for small enterprise lending. *Expert Systems with Applications*, 38(4), 4762–4770. <https://doi.org/10.1016/j.eswa.2010.09.118>
- Weng, F., Zhu, M., Buckle, M. J., Hájek, P., & Abedin, M. Z. (2025). Class imbalance Bayesian model averaging for consumer loan default prediction: The role of soft credit information. *Research in International Business and Finance*, 74, 102722. <https://doi.org/10.1016/j.ribaf.2024.102722>
- Wei, L., Lin, J., & Cen, W. (2024). Stronger relationships higher risk? Credit risk evaluation based on SMEs network microstructure. *Emerging Markets Review*, 62. <https://doi.org/10.1016/j.ememar.2024.101189>

- Wu, Y. (2010). Research of credit sale risk evaluation based on BP neural network. <https://doi.org/10.1109/ICMSS.2010.5577091>
- Wu, Z., Wang, S., & Li, S. (2025). Advances in credit risk modeling using ensemble and deep learning methods. *European Journal of Operational Research*, 326(2), 357–373. <https://doi.org/10.1016/j.ejor.2025.04.020>
- Xia, Y., Liu, C., & Liu, N. (2017). Cost-sensitive boosted tree for loan evaluation in peer-to-peer lending. *Electronic Commerce Research and Applications*, 24, 30–49. <https://doi.org/10.1016/j.elerap.2017.06.004>
- Xiao, J., Li, S., Tian, Y., Huang, J., Jiang, X., & Wang, S. (2025). Example dependent cost-sensitive learning based selective deep ensemble model for customer credit scoring. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-89880-7>
- Xiao, J., Xie, L., He, C., & Jiang, X. (2012). Dynamic classifier ensemble model for customer classification with imbalanced class distribution. *Expert Systems with Applications*, 39(4), 3668–3675. <https://doi.org/10.1016/j.eswa.2011.09.059>
- Xu, R., & He, M. (2020). Application of deep learning neural network in online supply chain financial credit risk assessment. 2020 International Conference on Computer Information and Big Data Applications (CIBDA). IEEE. <https://doi.org/10.1109/CIBDA50819.2020.00058>
- Xue, X.-H., & Xue, X.-F. (2010). Research of electronic commercial credit rating based on neural network with principal component analysis. <https://doi.org/10.1109/ITAPP.2010.5566121>
- Yang, R., Zhou, X., & Wang, W. (2011). Is the small and medium-sized enterprises' credit default behavior affected by their owners' credit features? In Proceedings of the 2011 International Conference on Management and Service Science (ICMSS 2011) (pp. 1–4). IEEE. <https://doi.org/10.1109/ICMSS.2011.5998460>
- Yeh, I. C., & Lien, C. H. (2009). The comparisons of data mining techniques for the predictive accuracy of probability of default of credit card clients. *Expert Systems with Applications*, 36(2), 2473–2480. <https://doi.org/10.1016/j.eswa.2007.12.020>
- Zhang, C., Zhang, J., & Jiang, P. (2022). Assessing the risk of green building materials certification using the back-propagation neural network. *Environment, Development and Sustainability*, 24, 6925–6952. <https://doi.org/10.1007/s10668-021-01734-0>
- Zhang, H., Zhang, H., & Zhang, M. (2021). Research on enterprise credit risk prediction based on text information. *Journal of Risk Analysis and Crisis Response*, 11(4), 176–188. <https://doi.org/10.54560/jracr.v11i4.311>
- Zhou, L., Lai, K. K., & Yu, L. (2010). Least squares support vector machine ensemble models for credit scoring. *Expert Systems with Applications*, 37(1), 127–133. <https://doi.org/10.1016/j.eswa.2009.05.023>