



Universidade Federal do Amazonas
Faculdade de Tecnologia

Programa de Pós-Graduação em Engenharia de
Produção - PPGE



CIBELLE LIMA PEREIRA NERY

APLICAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA NA PREDIÇÃO
DA MATURIDADE *LEAN* COM BASE NO MODELO LESAT

MANAUS

2026

CIBELLE LIMA PEREIRA NERY

**APLICAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA NA PREDIÇÃO
DA MATURIDADE *LEAN* COM BASE NO MODELO LESAT**

Dissertação de Mestrado em Engenharia de Produção
apresentada ao Programa de Pós-Graduação *Stricto
Sensu*, em Engenharia de Produção da Universidade
Federal do Amazonas como pré-requisito para obtenção
do título de Mestre em Engenharia de Produção pela
Universidade Federal do Amazonas - UFAM.

Área de Concentração: Gestão da Produção e Operações

Linha de Pesquisa: Gestão de Operações e Processos da
Produção e Serviços

Orientador: Marcelo Albuquerque de Oliveira, Ph.D

MANAUS

2026

Ficha Catalográfica

Elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

N456a Nery, Cibelle Lima Pereira
Aplicação de técnicas de aprendizado de máquina na predição da maturidade lean com base no modelo LESAT / Cibelle Lima Pereira Nery. - 2026.
87 f. : il., color. ; 31 cm.

Orientador(a): Marcelo Albuquerque de Oliveira.
Dissertação (mestrado) - Universidade Federal do Amazonas, Programa de Pós-Graduação em Engenharia de Produção, Manaus, 2026.

1. Maturidade enxuta. 2. LESAT - LAI Self-Assessment Tool. 3. Aprendizado de máquina. 4. Modelo preditivo. 5. Diagnóstico organizacional. I. Oliveira, Marcelo Albuquerque de. II. Universidade Federal do Amazonas. Programa de Pós-Graduação em Engenharia de Produção. III. Título

CIBELLE LIMA PEREIRA NERY

**APLICAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA NA PREDIÇÃO
DA MATURIDADE LEAN COM BASE NO MODELO LESAT**

Dissertação de Mestrado em Engenharia de Produção
apresentada ao Programa de Pós-Graduação *Stricto
Sensu*, em Engenharia de Produção da Universidade
Federal do Amazonas como pré-requisito para obtenção
do título de Mestre em Engenharia de Produção pela
Universidade Federal do Amazonas - UFAM.

Área de Concentração: Gestão da Produção e
Operações

Linha de Pesquisa: Gestão de Operações e Processos da
Produção e Serviços

Orientador: Marcelo Albuquerque de Oliveira, Ph.D.

BANCA EXAMINADORA

Prof. Dr. Marcelo Albuquerque de Oliveira
Universidade Federal do Amazonas
Orientador e Presidente

Prof. Dr. Antônio do Nascimento Silva Alves
Universidade Federal do Amazonas
Membro Interno

Profª. Dra. Sara Raquel Gomes de Sousa
Instituto de Tecnologia da Amazônia (INTECAM)
Membro Externo

Manaus, 28 de agosto de 2026

AGRADECIMENTOS

Ao Ser maior que nos rege, pela força, proteção e direção ao longo desta caminhada.

Em memória de minha mãe, a quem devo grande parte de quem sou e de tudo o que alcancei. Sem ela, nada disso seria possível. Hoje reconheço os inúmeros esforços, muitos deles invisíveis para mim na época, que me permitiram chegar até aqui. Mesmo distante fisicamente, sinto sua presença em todos os momentos, seu amor, seu cuidado e seu apoio continuam me acompanhando.

Ao meu pai e às minhas irmãs, que são meus pilares e minha base. Mesmo sem perceberem, vocês me sustentam e tornam possível que eu continue buscando meus objetivos. Agradeço especialmente por todo o apoio silencioso do dia a dia, pelo cuidado com a nossa casa, pelas responsabilidades assumidas e por compreenderem minhas ausências durante esse período de trabalho, estudo e escrita. Muito do que conquisto também é resultado do suporte de vocês.

Ao meu amor, Vinícius, agradeço por todas as palavras de incentivo, pelo carinho e pela paciência nos momentos em que eu duvidei de mim mesma e pensei em desistir. Seu apoio foi essencial para que eu continuasse, mesmo nos dias mais difíceis.

Aos meus amigos, agradeço pela compreensão, pela paciência e por entenderem minhas ausências e recusas a tantos convites durante o processo de construção desta dissertação. O apoio e a torcida de vocês também fizeram parte desta conquista.

Aos professores que contribuíram para minha formação, em especial ao meu orientador, Prof. Dr. Marcelo Oliveira, pela orientação, confiança, apoio e pelos conselhos ao longo desta trajetória. Sua contribuição foi fundamental para o desenvolvimento deste trabalho.

À banca de qualificação, composta pela Profa. Dra. Sara Gomes e pelo Prof. Dr. Antônio do Nascimento, pelas contribuições, observações e sugestões que auxiliaram no aprimoramento desta pesquisa.

À Universidade Federal do Amazonas (UFAM), pela oportunidade de formação e por possibilitar a realização deste mestrado, que representa uma etapa tão importante da minha trajetória acadêmica e profissional.

RESUMO

A avaliação da maturidade *lean* em organizações industriais é frequentemente conduzida por meio de instrumentos de autoavaliação qualitativa, sujeitos a subjetividade, variabilidade de interpretação e baixa replicabilidade. O presente trabalho propõe uma abordagem metodológica para a predição do nível de maturidade *lean* a partir de dados qualitativos estruturados e técnicas de aprendizado de máquina supervisionado. O modelo visa estruturar e padronizar a subjetividade inerente às abordagens tradicionais de avaliação da maturidade enxuta, promovendo maior escalabilidade e confiabilidade nos diagnósticos. O instrumento de coleta foi desenvolvido com base nas dimensões do LESAT 2.0, composto por 41 itens distribuídos em práticas organizacionais *lean* e adoção de ferramentas, aplicado a 43 profissionais de organizações industriais brasileiras via questionário. A variável-alvo foi construída por meio de um *score* composto ponderado e dividida em três classes de maturidade: Inicial, Em desenvolvimento e Avançado. Os níveis de maturidade atribuídos serviram de rótulo para o treinamento de dois algoritmos supervisionados: Árvore de Decisão e Floresta Aleatória. A Árvore de Decisão, com acurácia de 0,674 no LOOCV, gerou regras de classificação cuja hierarquia de divisões espelha a progressão teórica do LESAT 2.0. O modelo Floresta Aleatória alcançou acurácia de 0,907 e F1-macro de 0,905 no LOOCV, com a análise de importância de variáveis identificando as dimensões de estrutura organizacional, plano de transformação, implementação e nutrição da transformação como as principais determinantes do nível de maturidade. Em suma, a abordagem proposta demonstra viabilidade metodológica e oferece um instrumento de diagnóstico mais objetivo, escalável e reproduzível, com contribuições para a integração entre Engenharia de Produção e Ciência de Dados.

Palavras-Chave: Maturidade Enxuta; LESAT; Aprendizado de Máquina; Modelo Preditivo; Diagnóstico Organizacional.

ABSTRACT

Lean maturity assessment in industrial organizations is frequently conducted through qualitative self-assessment instruments, which are subject to subjectivity, interpretive variability, and low replicability. This study proposes a methodological approach for predicting lean maturity levels from structured qualitative data and supervised machine learning techniques. The model aims to structure and standardize the subjectivity inherent in traditional lean maturity assessment approaches, promoting greater scalability and reliability in organizational diagnostics. The data collection instrument was developed based on the LESAT 2.0 dimensions, comprising 41 items distributed across lean organizational practices and tool adoption, applied to 43 professionals from Brazilian industrial organizations via structured questionnaire. The target variable was constructed through a weighted composite score and divided into three maturity classes: Initial, Developing, and Advanced. The assigned maturity levels served as labels for training two supervised classification algorithms: Decision Tree and Random Forest. The Decision Tree, with an accuracy of 0.674 in the LOOCV, generated classification rules whose decision hierarchy mirrors the theoretical progression of the LESAT 2.0 framework. The Random Forest model achieved an accuracy of 0.907 and a macro F1-score of 0.905 in the Leave-One-Out Cross-Validation, with variable importance analysis identifying the dimensions of organizational structure, transformation planning, implementation, and transformation nurturing as the main determinants of maturity level. In summary, the proposed approach demonstrates methodological feasibility and offers a more objective, scalable, and reproducible diagnostic instrument, contributing to the integration between Production Engineering and Data Science.

Key-words: Lean Maturity; LESAT; Machine Learning; Predictive Model; Organizational Diagnosis.

Lista de Figuras

Figura 1 - 5 Princípios Fundamentais do <i>lean</i>	19
Figura 2 - Pirâmide 4P do STP	22
Figura 3 - Representação da Árvore de Decisão	37
Figura 4 - Etapas da Pesquisa	39
Figura 5 - Perfil dos respondentes	52
Figura 6 - Distribuição do score composto e separação por classe de maturidade	54
Figura 7 - <i>Score</i> médio por subseção do LESAT	55
Figura 8 - Perfil por dimensão LESAT por classe de maturidade.....	57
Figura 9 - Nível médio de adoção das ferramentas	Erro! Indicador não definido.
Figura 10 - Mapa de correlação entre subseções do LESAT	62
Figura 11 - Distribuição do índice de consistência entre respondentes.....	64
Figura 12 - Acurácia por dobra na validação cruzada k=5.....	67
Figura 13 - Matrizes de confusão (LOOCV).....	69
Figura 14 - F1-score por classe de maturidade (LOOCV)	70
Figura 15 - Importância das variáveis: Dimensões LESAT, Ferramentas e de Contexto	72
Figura 16 - Estrutura da árvore de decisão	75

Lista de Quadros

Quadro 1 - Principais ferramentas <i>lean manufacturing</i>	20
Quadro 2 - Grade de Maturidade de Gestão de Qualidade.....	24
Quadro 3 - Comparativo de modelos de maturidade <i>lean</i>	28
Quadro 4 - Estrutura LESAT.....	33
Quadro 5 - Organização das Práticas de Maturidade do LESAT 2.0	33
Quadro 6 - Níveis de Maturidade do LESAT 2.0.....	34
Quadro 7 - Perfil dos respondentes	42
Quadro 8 - Estrutura do instrumento de coleta de dados.....	45
Quadro 9 - Mapeamento das questões do instrumento baseados no LESAT 2.0.....	46
Quadro 10 - Codificação ordinal para as questões de adoção de ferramentas	47
Quadro 11 - Alfa de Cronbach por subseção do LESAT	48
Quadro 12 - Definição das classes de maturidade <i>lean</i> e distribuição amostral.....	50
Quadro 13 - 10 variáveis mais importantes (RF)	73

Lista de Tabelas

Tabela 1 - Comparação De Métricas De Desempenho.....	66
Tabela 2 - Desempenho por classe de maturidade no modelo <i>Random Forest</i> LOOCV	67

LISTA DE SIGLAS E ABREVIATURAS

DT - *Decision Tree*

IA - *Inteligência Artificial*

IoT - *Internet of Things*

JIT - *Just in time*

KNN - *K-Nearest Neighbour*

KPMMM - *Kerzner Project Management Maturity Model*

LAI - *Lean Advancement Initiative*

LCMMO - *Lean Construction Maturity Model for Organizations*

LESAT - *Lean Advancement Initiative Enterprise Self-Assessment Tool*

LM - *Lean Manufacturing*

LMMM - *Lean Manufacturing Maturity Model*

LOOCV - *Leave-One-Out Cross-Validation*

LSCM - *Lean Supply Chain Management*

MES - *Manufacturing Execution System*

MIT - *Massachusetts Institute of Technology*

ML - *Machine Learning*

OEE - *Overall Equipment Effectiveness*

QMMG - *Quality Management Maturity Grid*

RF - *Random Forest*

SMED - *Single Minute Exchange of Die*

STP - *Sistema Toyota de Produção*

SVM - *Support Vector Machine*

TPM - *Total Productive Maintenance*

VSM - *Value Stream Mapping*

SUMÁRIO

1. INTRODUÇÃO	12
1.1. CONTEXTUALIZAÇÃO	12
1.2. FORMULAÇÃO DO PROBLEMA	14
1.3. OBJETIVOS.....	15
1.3.1. OBJETIVO GERAL	15
1.3.2. OBJETIVOS ESPECÍFICOS	15
1.4. JUSTIFICATIVA	16
1.5. ESTRUTURA DO PROJETO	17
2. ENQUADRAMENTO TEÓRICO	17
2.1. PENSAMENTO ENXUTO OU <i>LEAN THINKING</i>	17
2.1.1. ORIGEM E EVOLUÇÃO	17
2.1.2. PRINCÍPIOS <i>LEAN</i>	18
2.1.3. FERRAMENTAS <i>LEAN</i>	19
2.1.4. CULTURA E SUSTENTABILIDADE <i>LEAN</i>	21
2.2. MODELOS DE MATURIDADE	23
2.2.1. MODELO DE MATURIDADE EM <i>LEAN</i>	26
2.2.1.1. MODELO LESAT.....	32
2.3. MACHINE LEARNING	34
2.3.1. DECISION TREE.....	36
2.3.2. <i>RANDOM FOREST</i>	37
2.3.3. APLICAÇÕES DE APRENDIZADO DE MÁQUINAS	38
3. METODOLOGIA.....	39
3.1. ETAPAS DA PESQUISA.....	39
3.2. NATUREZA DA PESQUISA	40
3.3. FORMA DE ABORDAGEM DO PROBLEMA	40
3.4. CLASSIFICAÇÃO DA PESQUISA QUANTO AOS PROCEDIMENTOS	41
3.5. UNIVERSO E AMOSTRA DA PESQUISA	42
3.6. PROCEDIMENTOS PARA A COLETA DE DADOS	44
3.7. PROCEDIMENTOS PARA A ANÁLISE DOS DADOS	45
3.7.1. MAPEAMENTO DAS PRÁTICAS COM AS DIMENSÕES DO LESAT	45
3.7.2. PRÉ-PROCESSAMENTO E TRANSFORMAÇÃO DOS DADOS	47

3.7.3. VALIDADE INTERNA DO INSTRUMENTO E ÍNDICE DE CONSISTÊNCIA.....	48
3.8. CONSTRUÇÃO DA VARIÁVEL-ALVO	50
4. DESENVOLVIMENTO.....	50
4.1. ANÁLISE EXPLORÁTORIA DOS DADOS	50
4.1.1. PERFIL DOS RESPONDENTES	51
4.1.2. DISTRIBUIÇÃO DO <i>SCORE</i> E DA VARIÁVEL-ALVO.....	53
4.1.3. ANÁLISE POR DIMENSÃO DO LESAT	55
4.1.4. ADOÇÃO DAS FERRAMENTAS <i>LEAN</i>	58
4.1.5. CORRELAÇÃO ENTRE DIMENSÕES	61
4.1.6. ÍNDICE DE CONSISTÊNCIA.....	63
4.2. CONSTRUÇÃO DO PIPELINE DE MACHINE LEARNING	64
4.2.1. CONFIGURAÇÃO DAS VARIÁVEIS DE ENTRADA.....	65
4.2.2. VARIÁVEL-ALVO	65
4.2.3. ALGORITMOS SELECIONADOS	65
4.2.4. ESTRATÉGIA DE VALIDAÇÃO.....	65
4.3. TREINAMENTO DOS MODELOS	66
5. RESULTADOS E DISCUSSÃO	66
5.1. DESEMPENHO COMPARATIVO DOS MODELOS	66
5.2. ANÁLISE POR CLASSE DE MATURIDADE	67
5.3. ANÁLISE DE IMPORTÂNCIA DAS VARIÁVEIS	71
5.4. ESTRUTURA DOS MODELOS.....	74
6. CONCLUSÃO.....	76
6.1. PRINCIPAIS CONTRIBUIÇÕES E IMPACTOS	78
6.1.1. IMPACTOS ACADÊMICOS.....	78
6.1.2. IMPACTOS ECONÔMICOS.....	79
6.1.3. IMPACTOS SOCIAIS.....	79
6.2. LIMITAÇÕES DA PESQUISA	80
6.3. SUGESTÃO PARA TRABALHOS FUTUROS	81
REFERÊNCIAS	81

1. INTRODUÇÃO

1.1. CONTEXTUALIZAÇÃO

O aumento contínuo da competitividade global, associado à ampliação do poder de escolha dos consumidores tem exigido das organizações níveis elevados de qualidade, eficiência operacional e excelência de classe mundial como condição para sua sobrevivência e sustentabilidade. Nesse contexto, o *lean manufacturing* (LM) consolidou-se como uma das principais abordagens de gestão voltadas à melhoria do desempenho organizacional, especialmente após a disseminação causada pela obra “A Máquina que Mudou o Mundo” (Womack; Jones; Roos, 1990).

As origens do pensamento enxuto remontam ao Sistema Toyota de Produção (STP), desenvolvido no Japão no pós-guerra como resposta a restrições daquele contexto, tais como mercado fragmentado, baixa escala produtiva, limitação de capital e elevada variabilidade de demanda. Diferentemente do modelo de produção em massa ocidental da época, o STP estruturou-se com base na eliminação de desperdícios, na estabilização dos processos, na produção puxada e no desenvolvimento contínuo das pessoas (Dennis, 2015). Esse sistema tornou-se referência internacional ao demonstrar superioridade consistente em qualidade, custo e confiabilidade, impulsionando a disseminação global dos princípios enxutos ao longo das décadas de 1980 e 1990 (Liker, 2021).

Com o tempo, o *lean* deixou de ser interpretado exclusivamente como um conjunto de ferramentas voltadas à eliminação de desperdícios na manufatura e passou a ser compreendido como uma filosofia organizacional abrangente, incorporando dimensões estratégicas, culturais e sistêmicas (Bhasin, 2015). Essa evolução favoreceu sua expansão para além do ambiente industrial, alcançando setores como saúde, serviços, setor público, educação e finanças. Na área da saúde, por exemplo, ferramentas como SMED e Mapeamento do Fluxo de Valor foram utilizadas para reduzir tempos de troca entre procedimentos e otimizar fluxos hospitalares (Amati et al., 2022; Pellini et al., 2021). Em serviços, bibliotecas aplicaram o mapeamento de processos para melhorar a aquisição de recursos (Yeh; Arthaud-Day; Turvey-Welch, 2021), enquanto organizações filantrópicas utilizaram princípios enxutos para aprimorar a coordenação logística em contextos de desastres naturais (Mogotsi; Saruchera, 2023).

Apesar de sua consolidação teórica e ampla disseminação prática, a implementação sustentável do *lean* ainda representa um desafio significativo. Estudos indicam que, embora diversas empresas obtenham ganhos relevantes com a adoção de práticas enxutas, há também um número expressivo de organizações que enfrentam dificuldades em sustentar seus resultados

ao longo do tempo (Yadav et al., 2020). Agus e Iteng (2013) demonstrou que empresas com adoção de longo prazo apresentam melhor desempenho comercial e maior participação de mercado quando comparadas a organizações em estágio inicial de implementação, sugerindo que a consolidação do pensamento enxuto depende de um processo evolutivo e contínuo.

Um dos fatores que contribuem para tais dificuldades é a interpretação limitada do *lean* como um conjunto isolado de ferramentas operacionais. Conforme argumenta Liker (2021), muitas empresas implementam práticas como células de produção, *kanban* ou redução de *setup* acreditando que tais iniciativas caracterizam, por si só, uma transformação enxuta. Entretanto, o verdadeiro *lean* reside na integração coerente entre filosofia de longo prazo, desenvolvimento de pessoas, estabilidade operacional e cultura de melhoria contínua. Sem essa base sistêmica e cultural, as melhorias tendem a ser superficiais e insustentáveis.

Nesse contexto, a maturidade organizacional assume papel central. A maturidade em *lean* pode ser compreendida como o grau de internalização sistêmica de seus princípios, refletindo não apenas a aplicação de ferramentas, mas a incorporação do pensamento enxuto na estratégia, liderança, cultura e processos da organização. A literatura destaca que a cultura organizacional influencia diretamente o comportamento dos indivíduos e a aceitação de mudanças, sendo elemento determinante para a consolidação da transformação enxuta (Bhasin, 2015). Assim, a sustentabilidade do *lean* depende da capacidade da organização em evoluir estruturalmente, superando resistências internas e promovendo aprendizado contínuo.

Diante dessa complexidade, a avaliação da maturidade *lean* torna-se fundamental para identificar lacunas, direcionar esforços de melhoria e apoiar a tomada de decisão estratégica. Como resposta a essa necessidade, diversos modelos de maturidade foram propostos na literatura científica, apresentando diferentes dimensões, níveis e critérios de avaliação com o objetivo de mensurar o grau de adoção das práticas enxutas.

Todavia, estudos apontam limitações relevantes nessas abordagens. Lameijer, De Mast e Does (2017) destacam que muitos modelos carecem de orientações operacionais claras, o que favorece interpretações subjetivas e dificulta sua aplicação em diferentes contextos organizacionais. Bataglia et al. (2018) evidenciam a presença de vieses nas respostas, podendo gerar índices de maturidade superestimados devido ao desconhecimento dos respondentes sobre o que caracteriza, de fato, um estágio avançado de *lean*. Jayanetti et al. (2023) alertam que modelos baseados exclusivamente em autoavaliação interna tendem a produzir resultados tendenciosos, especialmente quando restringem a coleta de dados a um número limitado de profissionais. Complementarmente, Galhardi; Tabeta (2021) observam que a predominância de

avaliações qualitativas pode comprometer a capacidade de mensurar de forma consistente o desempenho real do sistema enxuto.

Diante desse cenário, evidencia-se uma lacuna relacionada à necessidade de modelos de avaliação de maturidade que apresentem maior robustez metodológica, reduzam vieses de interpretação e sejam sensíveis às especificidades organizacionais, especialmente em ambientes industriais complexos e dinâmicos.

1.2. FORMULAÇÃO DO PROBLEMA

A intensificação da competitividade global, somada a eventos recentes como tensões geopolíticas, pandemia de Covid-19 e instabilidades nas cadeias de suprimentos, ampliou a pressão por eficiência, flexibilidade e capacidade adaptativa nas organizações. No contexto brasileiro, esse cenário revela fragilidades estruturais relevantes. Segundo a Confederação Nacional da Indústria (CNI, 2022), o Brasil ocupa posição inferior no ranking de competitividade entre as economias analisadas, indicando limitações que comprometem sua capacidade de reação e posicionamento internacional.

Diante desse ambiente, práticas voltadas à eficiência operacional e à eliminação sistemática de desperdícios tornam-se estratégicas. O *lean manufacturing*, fundamentado no STP, propõe a realização de mais com menos recursos, promovendo racionalização de esforços, materiais, tempo e capital (Dennis, 2015; Womack; Jones, 2003). Contudo, apesar de sua consolidação teórica e ampla difusão, a implementação sustentável do *lean* permanece um desafio significativo.

Estudos indicam que apenas 30% das empresas nos Estados Unidos e 25% no Reino Unido alcançam os benefícios esperados com a adoção do *lean*, principalmente em razão da ausência de mecanismos estruturados para sustentação das práticas enxutas (Yadav et al., 2020). No cenário brasileiro, Neto et al. (2018), ao investigarem 351 profissionais da área de produção, constataram que práticas que demandam maior integração sistêmica, como mapeamento do fluxo de valor e redução de custos, apresentam baixa disseminação, colaborando para a manutenção de um conjunto de práticas enxutas isoladas. Complementarmente, Dos Santos, Cordeiro e Da Silva (2021) identificaram como principais problemas encontrados na aplicação do *lean*: falta de monitoramento; controle e continuação do método; dificuldades culturais; dificuldades no uso e controle das ferramentas do *lean*; e a falta de envolvimento e comprometimento.

Por esse conjunto de evidências apresentadas, nota-se que a presença de ferramentas não assegura, por si só, a consolidação do *lean* como modelo de gestão. Torna-se, portanto,

essencial avaliar o grau de maturidade organizacional como forma de compreender o estágio de internalização dos princípios enxutos, identificar lacunas estruturais e orientar decisões estratégicas.

Contudo, os modelos de maturidade *lean* disponíveis na literatura apresentam limitações metodológicas relevantes. Entre elas, destacam-se a elevada subjetividade nos critérios avaliativos, a dependência de autoavaliação, os custos de aplicação e a baixa escalabilidade dos instrumentos (Jayanetti et al., 2023). Tais restrições comprometem a confiabilidade e a comparabilidade dos diagnósticos, dificultando sua utilização sistemática em organizações industriais.

Paralelamente, avanços em técnicas de análise de dados, incluindo métodos de aprendizado de máquina, ampliam as possibilidades de estruturação e tratamento de informações qualitativas de forma mais consistente. Entretanto, ainda não há consenso metodológico sobre como integrar dados qualitativos estruturados a modelos de avaliação capazes de reduzir vieses de interpretação e ampliar a robustez da previsão do nível de maturidade.

Dessa forma, configura-se uma lacuna científica e prática relacionada à necessidade de métodos mais confiáveis e estruturados para avaliação da maturidade *lean* em organizações industriais brasileiras. Diante desse cenário, formula-se o seguinte problema de pesquisa: Como estruturar e padronizar a avaliação subjetiva de maturidade *lean*, reduzindo as diferenças de interpretações e aumentando a confiabilidade na previsão do nível de maturidade em organizações industriais brasileiras a partir de dados qualitativos estruturados?

1.3.OBJETIVOS

1.3.1. OBJETIVO GERAL

Desenvolver uma abordagem metodológica para previsão do nível de maturidade *lean* em organizações industriais brasileiras a partir de dados qualitativos estruturados.

1.3.2. OBJETIVOS ESPECÍFICOS

- (i) Analisar os principais modelos de maturidade *lean* presentes na literatura, identificando suas dimensões, critérios avaliativos e limitações metodológicas;
- (ii) Estruturar um instrumento padronizado de coleta de dados qualitativos alinhado às dimensões de maturidade *lean* identificadas;
- (iii) Construir um modelo de previsão do nível de maturidade *lean* a partir dos dados coletados;

- (iv) Validar a abordagem metodológica proposta por meio de métricas de desempenho e procedimentos de verificação estatística;
- (v) Avaliar a contribuição da abordagem desenvolvida em relação a métodos tradicionais de avaliação da maturidade *lean*.

1.4. JUSTIFICATIVA

A avaliação da maturidade enxuta vem sendo utilizada como instrumento para compreender o grau de consolidação dos princípios enxutos nas organizações. No entanto, a literatura evidencia que os modelos atualmente disponíveis ainda apresentam limitações, especialmente relacionadas à subjetividade dos critérios avaliativos, à dependência de autoavaliações e à dificuldade de padronização dos diagnósticos. Como consequência, decisões estratégicas podem ser tomadas com base em análises pouco consistentes ou excessivamente dependentes da interpretação do avaliador.

Paralelamente, o cenário industrial atual é marcado pelo avanço das tecnologias digitais e pelo uso crescente de Inteligência Artificial (IA) e técnicas de Aprendizado de Máquina, *machine learning* (ML), como suporte à tomada de decisão. Estudos recentes já demonstram o potencial dessas abordagens na avaliação de níveis de maturidade organizacional. Ali et al. (2024), por exemplo, exploraram a aplicação de ML na previsão da maturidade da Indústria 4.0, evidenciando ganhos na capacidade analítica e no processo decisório. Da mesma forma, Sekhar, Solke e Shah (2023) utilizaram dados operacionais para prever o nível de manufatura *lean* em empresas automotivas, considerando variáveis produtivas como flexibilidade de volume, utilização de recursos e fluxo de materiais.

Essas pesquisas indicam que métodos analíticos podem contribuir para tornar avaliações organizacionais mais estruturadas e menos dependentes de julgamentos subjetivos. Entretanto, ainda há uma lacuna relevante quando se trata da integração de dados qualitativos, especialmente aqueles obtidos por meio de entrevistas estruturadas, com abordagens preditivas aplicadas especificamente à maturidade do pensamento enxuto.

Nesse sentido, este estudo se justifica pela proposta de desenvolver uma abordagem metodológica que integre dados qualitativos estruturados a técnicas de aprendizado de máquina, utilizando um modelo de maturidade *lean* consolidado como referência para classificação. O objetivo não é substituir a análise qualitativa, mas estruturá-la de forma mais consistente, reduzindo a subjetividade, aumentando a reprodutibilidade dos diagnósticos e ampliando a escalabilidade do processo de avaliação.

Do ponto de vista científico, a pesquisa contribui ao avançar metodologicamente na avaliação da maturidade *lean*, aproximando o campo do pensamento enxuto com as possibilidades oferecidas por métodos quantitativos de análise de dados. Assim, a pesquisa apresenta relevância acadêmica e aplicada, ao propor uma forma mais estruturada, confiável e alinhada às demandas para avaliação da maturidade *lean* em ambientes industriais.

1.5. ESTRUTURA DO PROJETO

O presente trabalho está organizado em cinco capítulos. No primeiro capítulo, Introdução, foram apresentados a contextualização do tema, a formulação do problema, a justificativa da pesquisa e os objetivos geral e específicos que orientam o desenvolvimento do estudo.

O segundo capítulo corresponde ao Referencial Teórico, no qual são discutidos os principais conceitos que fundamentam a pesquisa. Inicialmente, aborda-se o LM, sua origem, princípios e evolução ao longo do tempo. Em seguida, são apresentados os modelos de maturidade organizacional, com foco nos modelos de maturidade *lean* e nas limitações metodológicas identificadas na literatura. Por fim, são introduzidos fundamentos de métodos analíticos aplicados à gestão, com destaque para técnicas de ML, como *Decision Tree* e *Random Forest*, que dão suporte à proposta metodológica do estudo.

O terceiro capítulo apresenta a Metodologia, detalhando a natureza da pesquisa, a abordagem adotada, a classificação do estudo, a caracterização do universo e da amostra, além dos procedimentos de coleta, estruturação e análise dos dados. Também são descritos os critérios de validação da abordagem proposta. No quarto capítulo, é apresentado o Desenvolvimento com foco na análise exploratória dos dados dos respondentes, construção sistemática dos algoritmos de ML e treinamentos. No quinto e sexto capítulo, são apresentados os Resultados e Discussão, respectivamente, contemplando a análise dos dados coletados, o desempenho do modelo desenvolvido e sua comparação com métodos tradicionais de avaliação da maturidade *lean*. Por fim, o sétimo capítulo reúne as Conclusões do estudo, destacando as contribuições teóricas e práticas, as limitações da pesquisa e sugestões para trabalhos futuros. Ao final, são apresentadas as referências bibliográficas utilizadas no desenvolvimento do trabalho.

2. ENQUADRAMENTO TEÓRICO

2.1. PENSAMENTO ENXUTO OU *LEAN THINKING*

2.1.1. ORIGEM E EVOLUÇÃO

Ao longo das décadas, os sistemas de manufatura vêm presenciando uma transição entre diferentes formas de organização da produção. Inicialmente predominava o sistema artesanal, baseado principalmente no conjunto de habilidades da força de trabalho. Posteriormente, consolidou-se o sistema de produção em massa, caracterizado por altos volumes de produção e linhas dedicadas. E mais recentemente, surgiu o sistema enxuto, no qual os processos são simplificados por meio da eliminação de desperdícios, maior flexibilidade produtiva e produção baseada na demanda do cliente (Vinodh, 2023).

O pensamento enxuto, ou *lean thinking*, foi denominado em 1990 pelos pesquisadores do Massachusetts Institute of Technology (MIT) James P. Womack, Daniel T. Jones e Daniel Roos, no livro “A Máquina que Mudou o Mundo”, para descrever o Sistema Toyota de Produção (Larman; Vodde, 2009). Antes do surgimento desse modelo, o sistema de produção em massa predominava nos Estados Unidos. Em meados da década de 1950, Eiji Toyoda, engenheiro japonês e membro da Toyota Motor Company, visitou a planta da Ford em Detroit com o objetivo de estudar o sistema produtivo considerado, na época, o mais eficiente do mundo. Após retornar ao Japão, Eiji Toyoda e Taiichi Ohno concluíram que o modelo observado não poderia ser simplesmente replicado na Toyota, mas poderia ser adaptado e aprimorado de acordo com a realidade japonesa (Dennis, 2015).

O Sistema Toyota de Produção, que inspirou o LM, foi desenvolvido como resposta aos desafios enfrentados pela indústria japonesa no período pós-guerra. Nesse contexto, as empresas lidavam com restrições de capital, mercados fragmentados e necessidade de produzir diferentes modelos em volumes menores. O pensamento enxuto passou então a representar um novo paradigma produtivo, no qual a produção de classe mundial exige menos de tudo em comparação à produção em massa, incluindo menor esforço humano, menor espaço fabril, menor investimento em ferramentas, menos horas de engenharia para desenvolvimento de produtos, menores estoques e menor incidência de defeitos, além de maior capacidade para produzir variedade de produtos (Black, 2008).

2.1.2. PRINCÍPIOS *LEAN*

A filosofia LM baseia-se na distinção entre valor e desperdício. Valor corresponde às atividades que atendem às necessidades do cliente, enquanto desperdício refere-se a todas as atividades que não agregam valor ao produto ou serviço. Dessa forma, o *lean* busca constantemente eliminar desperdícios ao longo dos processos, mantendo apenas as atividades que efetivamente agregam valor (Stone, 2012 apud Ikeziri et al., 2020). Nesse sentido, o principal objetivo de Taiichi Ohno era aumentar a eficiência da produção por meio da

eliminação sistemática dos desperdícios, classificados tradicionalmente como: superprodução, espera, transporte, superprocessamento, excesso de estoque, movimento e defeitos (Ledbetter, 2018).

Os cinco princípios do pensamento enxuto, Figura 1, são: valor, relacionado ao entendimento das necessidades do cliente; fluxo de valor, que representa todas as etapas necessárias para transformar um pedido em produto entregue; fluxo contínuo, que busca garantir que os produtos avancem pelo processo sem interrupções; produção puxada, baseada na demanda real do cliente; e busca pela perfeição, que representa o esforço contínuo pela eliminação de desperdícios e melhoria constante dos processos (Rich et al., 2006; Womack; Jones; Roos, 1990).

Figura 1 - 5 Princípios Fundamentais do *lean*



Fonte: Adaptado de al., 2006; Womack; Jones; Roos, 1990)

2.1.3. FERRAMENTAS LEAN

Segundo Vinodh (2023), o sistema enxuto inclui quatro ferramentas básicas: 5S, *Total Productive Maintenance* (TPM), *Value Stream Mapping* (VSM) e células de trabalho, porém não são as únicas. Existem também ferramentas complementares que auxiliam na melhoria dos processos e no aprofundamento da análise das causas dos problemas. Entre essas ferramentas secundárias destacam-se *poka-yoke*, *Single Minute Exchange of Die* (SMED), *just in time* (JIT) e Método *Kanban*, entre outras. Com o objetivo de sistematizar essas ferramentas, Piaia (2019) reuniu as principais práticas do pensamento enxuto identificadas na literatura, incluindo *Kanban*, *Kaizen*, 5S, SMED, TPM, *Andon*, gestão visual, *poka-yoke* e *Heijunka*.

O Quadro 1 apresenta a relação entre as principais ferramentas do LM e suas respectivas definições, conforme a classificação proposta por Vinodh (2023).

Quadro 1 - Principais ferramentas *lean manufacturing*

DIVISÃO CONFORME Vinodh (2023)	FERRAMENTA	DESCRIÇÃO
PRIMÁRIA	5S	Conjunto de práticas, que ajuda organizações a garantir um local de trabalho organizado, através de 5 conceitos: utilização; organização; limpeza; padronização; e autodisciplina (Black, 2008).
	TPM	Chave para estabilidade e eficácia das máquinas, onde busca eliminar todas as perdas relacionadas à, com zero paradas (Dennis, 2015).
	VSM	Todas as ações, com ou sem valor agregado, necessárias para levar um produto da produção até o cliente (Rother; Shook, 2012).
	CÉLULA DE TRABALHO	Agrupamento produtivo de máquinas/equipamentos, ferramentas, pessoas treinadas na produção, a fim de garantir o mínimo movimento, setup, com aproveitamento máximo (Vinodh, 2023).
SECUNDÁRIA	<i>POKA-YOKE</i>	Implementar soluções ou dispositivos a prova de erro e de baixo custo, que detectam situações de erro (Dennis, 2015).
	SMED	A técnica consiste em realizar operações de setup em menos de dez minutos, ou seja, em até um dígito de minuto. Normalmente realizado através da conversão de setup interno, onde é necessário parar a máquina, para setup externo (Shingo, 1985).
	JIT	É um sistema que consiste em utilizar a quantidade mínima de estoque, equipamentos, mão de obra e espaço para entregar produtos na hora certa para o cliente, criando fluxo e usando um sistema puxado (Protzman; Whiton; Protzman, 2019).

DIVISÃO CONFORME Vinodh (2023)	FERRAMENTA	DESCRIÇÃO
	<i>KANBAN</i>	É um tipo de gerenciamento visual para sinalizar um evento puxado, como uma solicitação de reabastecimento, normalmente realizado por meio de cartões (Larman; Vodde, 2009).
	<i>KAIZEN</i>	É melhoria contínua, que consiste em um processo dinâmico e em constante mudança. Uma vez que cada etapa incremental no processo de melhoria aproxima o processo do estado ideal (Stewart, 2011).
	<i>HEIJUNKA</i>	Significa carregamento nivelado ou suavização da produção ao longo do tempo, proporcionando equilíbrio e estratégia para tratar de variações na demanda de produtos (Ledbetter, 2018).
	<i>ANDON</i>	É um dispositivo de controle visual de paradas de linha, que notifica quando há um problema e em que linha, estação ocorreu o problema (Protzman; Whiton; Protzman, 2019).

Fonte: Adaptado de Vinodh (2023)

2.1.4. CULTURA E SUSTENTABILIDADE *LEAN*

A cultura organizacional é um elemento fundamental para a implementação e, principalmente, para a sustentação do pensamento enxuto. Trata-se de um processo cumulativo, que se desenvolve ao longo do tempo à medida que as pessoas compartilham experiências e se adaptam a contextos semelhantes. Nesse sentido, iniciativas *lean* exigem não apenas a adoção de práticas operacionais, mas a revisão contínua do ambiente de trabalho, das demandas e das necessidades organizacionais (Bhasin, 2015).


Nesse contexto, a implementação do *lean* envolve mudanças comportamentais significativas, especialmente no que se refere ao engajamento das pessoas, ao papel da liderança e ao desenvolvimento de capacidades de resolução de problemas. Assim, o *lean* deve ser compreendido como uma filosofia de gestão baseada no aprendizado organizacional e na melhoria contínua, e não apenas como um conjunto de ferramentas operacionais. Mann (2014) argumenta que cerca de 20% do esforço da transformação enxuta esteja de fato nas ferramentas

e configurações técnicas e físicas de produção, estando a maior parte dos ganhos sustentáveis associada à cultura organizacional, que se manifesta por meio do sistema de gestão adotado pela liderança, controles, processos de responsabilidade diária e disciplina.

Conforme argumenta Liker (2021), muitas organizações falham em sustentar iniciativas *lean* justamente por concentrarem seus esforços na aplicação de ferramentas técnicas, geralmente no nível do processo, sem desenvolver a base cultural necessária para sua continuidade. Como consequência, são geradas melhorias pontuais que, embora apresentem resultados iniciais positivos, tendem a se deteriorar ao longo do tempo.

Nesse contexto, Liker (2021) apresenta o modelo dos 4Ps do STP, estruturado como uma pirâmide, Figura 2. Na base encontra-se a Filosofia, orientada pelo pensamento de longo prazo e pela visão da organização como um sistema de aprendizado contínuo. Em seguida, na pirâmide, o Processo, no qual se concentram práticas como fluxo contínuo, nivelamento e padronização. O terceiro nível corresponde a Pessoas e Parceiros, enfatizando o desenvolvimento humano e a colaboração organizacional. No topo está a Resolução de Problemas, que reflete a consolidação de uma cultura voltada à melhoria contínua.

Figura 2 - Pirâmide 4P do STP



Fonte: Adaptado de Liker (2021)

Apesar da ampla disseminação do LM, a literatura aponta que muitas organizações ainda enfrentam dificuldades em sustentar os resultados obtidos com sua implementação. Isso ocorre, principalmente, quando as práticas enxutas são adotadas de forma isolada, sem integração com

a cultura e a estratégia organizacional, o que compromete a manutenção dos ganhos no longo prazo (Bhasin, 2015).

Dessa forma, a sustentação do *lean* está diretamente relacionada à capacidade da organização de internalizar seus princípios e incorporá-los de maneira sistêmica à sua estratégia, cultura e processos. Nesse contexto, emerge o conceito de maturidade organizacional, que busca avaliar o grau de desenvolvimento e integração das práticas *lean*, refletindo a capacidade da organização de sustentar melhorias de forma contínua.

2.2. MODELOS DE MATURIDADE

Modelo de maturidade pode ser definido como um conjunto de características, atributos, indicadores ou padrões que representam o nível de desenvolvimento e domínio de uma organização em determinada área. Esses modelos permitem que processos e métodos organizacionais sejam avaliados a partir de um conjunto estruturado de critérios de referência, possibilitando a identificação do estágio atual de capacidade organizacional. Dessa forma, as organizações podem utilizar modelos de maturidade para determinar seus níveis atuais de desempenho e, posteriormente, aplicá-los ao longo do tempo como instrumentos para orientar melhorias e evoluções (Caralli; Knight; Montgomery, 2012).

Ao identificar o nível atual da capacidade organizacional, os modelos de maturidade possibilitam a formulação de estratégias e podem ser utilizados como ferramentas de apoio à gestão e no processo decisório. Nesse contexto, iniciativas relacionadas à gestão da qualidade e à busca pela excelência organizacional impulsionaram o desenvolvimento de normas, regulamentos e *frameworks* voltados à melhoria de processos. Esses *frameworks*, frequentemente classificados como modelos de maturidade, buscam avaliar as capacidades organizacionais e orientar ações para o aprimoramento do desempenho (Maier; Moultrie; Clarkson, 2012).

Os primeiros vestígios da concepção de um modelo de maturidade surgiram em 1973, quando Richard L. Nolan, da Universidade de Harvard, propôs um modelo de estágios evolutivos para organizações de tecnologia da informação (Nolan, 1973 apud Gil, 2021). Posteriormente, em 1979, Philip Crosby desenvolveu de forma mais estruturada aquele que é amplamente reconhecido como um dos primeiros modelos de maturidade organizacional: o Quality Management Maturity Grid (QMMG). Esse modelo, possível visualizar no Quadro 2, aplicado à gestão da qualidade, categoriza práticas organizacionais em cinco estágios de maturidade e é considerado um marco na sistematização da evolução gerencial das organizações (Wendler, 2012).

Quadro 2 - Grade de Maturidade de Gestão de Qualidade

Categorias de Medição	Estágio 1: A Incerteza	Estágio 2: O Despertar	Estágio 3: O Esclarecimento	Estágio 4: A Sabedoria	Estágio 5: A Certeza
Compreensão e atitude da gestão	Sem compreensão da qualidade como uma ferramenta de gestão.	Reconhecer que a gestão da qualidade pode ser de valor, mas não está disposto a gastar recursos.	Ao passar pelo programa de melhoria da qualidade, aprenda mais sobre gestão da qualidade;	Participando. Compreender os absolutos da gestão da qualidade. Reconheça seu papel pessoal na ênfase contínua.	Considere a gestão da qualidade uma parte essencial do sistema da empresa.
Status da organização de qualidade	Qualidade está oculta nos departamentos de produção ou engenharia, provavelmente sem inspeção.	Um líder de qualidade é nomeado, mas a ênfase principal ainda está na avaliação e na movimentação do produto.	O departamento de qualidade se reporta à alta administração. Toda avaliação é incorporada e o gestor tem papel na gestão da empresa.	O gerente de qualidade é um diretor da empresa; Relatórios eficazes sobre a situação e ações preventivas.	Gerente de qualidade ligado Conselho Administrativo. A prevenção é principal preocupação.
Tratamento de problemas	Problemas são combatidos à medida que ocorrem.	Times são destinados para atacar problemas maiores.	Comunicação de ação corretiva. Os problemas são enfrentados abertamente e resolvidos de forma ordenada.	Os problemas são identificados no início do seu desenvolvimento. Todas as funções estão abertas a sugestões e melhorias.	Exceto nos casos mais incomuns, os problemas são evitados.

Categorias de Medição	Estágio 1: A Incerteza	Estágio 2: O Despertar	Estágio 3: O Esclarecimento	Estágio 4: A Sabedoria	Estágio 5: A Certeza
Custo da qualidade em % das vendas	Relatado: Desconhecido Atual: 20%	Relatado: 3% Atual: 18%	Relatado: 8% Atual: 12%	Relatado: 6,5% Atual: 8%	Relatado: 2,5% Atual: 2,5%
Ações de melhoria da qualidade	Atividades não organizadas e sem entendimento.	Tentativas de esforços óbvios “motivacionais” de curto prazo.	Implementação do programa de 14 etapas com profundo entendimento e estabelecimento de cada etapa.	Continuando o programa de 14 etapas e iniciando o Make Certain.	A melhoria da qualidade é uma atividade normal e contínua.
Resumo da postura de qualidade da organização	“Não sabemos porque temos problemas de qualidade.”	“É absolutamente necessário sempre ter problemas de qualidade?”	“Através da gestão e compromisso com a melhoria da qualidade, nós estamos identificando e resolvendo problemas.”	“Prevenção de defeitos faz parte da nossa rotina de operação.”	“Nós sabemos porque não temos problemas de qualidade.”

Fonte: Adaptado de Crosby (1980)

No mesmo período, Nolan expandiu sua proposta inicial ao apresentar um modelo de maturidade para o processamento de dados baseado em seis estágios de crescimento organizacional. Embora abordem domínios distintos, Nolan e Crosby compartilham a ideia central de evolução organizacional por estágios. Nolan enfatiza a progressão temporal das organizações ao longo do tempo, enquanto Crosby foca no potencial organizacional associado a cada nível de maturidade. Entre os diversos modelos desenvolvidos posteriormente, o modelo de Crosby é frequentemente citado como uma das bases conceituais mais consolidadas para a construção de modelos de maturidade organizacional (Wendler, 2012 apud Gil, 2021)

Diversos modelos de maturidade foram desenvolvidos ao longo das últimas décadas, sendo aplicados em diferentes áreas organizacionais, como tecnologia da informação, gestão da qualidade, gerenciamento de projetos e manufatura. Em um mapeamento sistemático de 237 artigos sobre o tema, Wendler (2012) identificou que os modelos de maturidade são aplicáveis em mais de 20 domínios distintos, com forte predominância nos setores de engenharia de *software*, setor público e gestão de projetos.

Na área de gestão urbana e transformação digital, Ajoudanian e Aboutalebi (2025) propuseram um modelo de maturidade voltado à avaliação das capacidades de transformação digital de empresas e instituições governamentais, com foco na transição para cidades inteligentes. De forma semelhante, Tanriverdi e Sencer (2024) investigaram a possibilidade de um modelo de maturidade em transformação digital aplicável tanto à indústria de manufatura quanto ao setor de serviços de informação, evidenciando o esforço recente da literatura em desenvolver modelos mais abrangentes.

No campo da gestão de projetos, De Souza, Salomon e Da Silva (2023) utilizaram o modelo *Kerzner Project Management Maturity Model* (KPMMM) para mensurar a maturidade em gerenciamento de projetos e analisar sua relação com as taxas de sucesso dos empreendimentos. Já na área de manutenção industrial, Chemweno et al. (2015) desenvolveram um modelo voltado à gestão de ativos, oferecendo um guia estruturado para a melhoria dos processos de manutenção. Complementarmente, De Oliveira (2017) propôs um modelo de maturidade para apoiar decisões estratégicas na gestão da manutenção, baseado na avaliação das práticas atuais e na classificação das organizações em diferentes níveis de maturidade.

2.2.1. MODELO DE MATURIDADE EM *LEAN*

Dentre os diferentes domínios nos quais os modelos de maturidade são aplicados, destaca-se a avaliação da implementação do LM nas organizações. Nesse contexto, diversos

modelos foram desenvolvidos com o objetivo de mensurar o grau de adoção das práticas enxutas e apoiar as organizações na identificação de seu estágio atual de desenvolvimento *lean*.

No contexto do pensamento enxuto, é possível identificar diversos modelos de maturidade voltados à medição do nível de implementação das práticas enxutas nas organizações. O Quadro 3 apresenta um comparativo dos principais modelos de maturidade *lean* identificados na literatura.

Quadro 3 - Comparativo de modelos de maturidade *lean*

Modelo (autor/ano)	Foco / objetivo	Níveis de maturidade	Dimensões avaliadas	Abordagem	Limitações
<i>Lean Manufacturing Maturity Model - LMMM</i> (Bento; Tontini, 2018)	Avaliar a maturidade das práticas de <i>lean manufacturing</i> e sua relação com o desempenho operacional.	5 níveis: Não implementado; Formalmente implementado; Implantado e documentado com falhas; Implementado e documentado sob controle; Implementado, controlado e em melhoria contínua.	8 dimensões: Planejamento Estratégico, Qualidade na Fonte, Processos e Ferramentas, Resolução de Problemas, Pessoas, Melhoria Contínua, Integração com Fornecedores e Foco no Cliente.	Quantitativa. Questionário em escala Likert e modelagem de equações estruturais.	Aplicável apenas ao ambiente industrial; não contempla explicitamente a cultura organizacional e gestão da mudança; instrumento extenso (38 itens) pode dificultar resposta completa.
<i>Lean Construction Maturity Model for Organizations - LCMMO</i> (Nesensohn, 2017)	Oferecer uma visão sistêmica e holística da maturidade <i>lean</i> em organizações da construção civil.	5 níveis: Incerto, Despertando, Sistemático, Integrando e Desafiador.	11 atributos: Liderança <i>lean</i> , Foco no cliente, Modo de pensar, Cultura e comportamento, Competências, Habilitadores de melhoria, Processos e ferramentas, Mudança, Ambiente de trabalho, Resultados de negócio, Aprendizagem e Desenvolvimento de competências.	Qualitativa. Autoavaliação em duas etapas: coleta de evidências e comparação com “declarações ideais”, baseada em comportamentos e atributos.	Específico ao setor de construção civil. Abordagem puramente qualitativa, sem indicadores quantitativos. A maturidade de cada fator-chave é definida pelo menor valor obtido entre seus itens, o que pode penalizar e subdimensionar a pontuação. Ponderação subjetiva, definida pela organização.

Modelo (autor/ano)	Foco / objetivo	Níveis de maturidade	Dimensões avaliadas	Abordagem	Limitações
<i>Lean Advancement Initiative Enterprise Self-Assessment Tool - LESAT</i> (Nightingale et al., 2012a)	Autoavaliação executiva da transformação <i>lean</i> no nível corporativo, com origem no setor aeroespacial.	5 níveis: Alguma consciência, atividades esporádicas; Consciência geral, abordagem informal; Abordagem sistemática, implantada na maioria das áreas; Refinamento contínuo e melhoria sustentada em toda a empresa; Abordagem excepcional e inovadora, totalmente implementada.	3 seções: (I) Liderança / Transformação <i>Lean</i> , (II) Processos do Ciclo de Vida e (III) Infraestrutura Habilitadora.	Qualitativa. Autoavaliação baseada em descrições de capacidade dos processos.	Aplicação complexa, pois exige a análise simultânea de dois cenários (atual e futuro/estratégico), além de evidências para cada prática; organizações podem estagnar na ausência de uma visão global da empresa. Avaliação qualitativa sem critérios quantitativos para validação; resultados dependem da percepção dos respondentes.
<i>Lean, Simulation and Optimization Maturity Model</i> (Uriarte et al., 2017)	Integrar <i>lean</i> , simulação e otimização para identificar o estágio atual e direcionar melhorias na tomada de decisão.	3 níveis por dimensão (Baixo, Médio, Alto) combinados em 6 estados: Novato, Iniciante, Iniciante Avançado, Intermediário, Competente, Especialista.	2 dimensões cruzadas: práticas <i>lean</i> e maturidade em Simulação e Otimização.	Qualitativa. <i>Grid</i> de maturidade descritivo, usado como modelo de posicionamento.	Restringe-se ao <i>lean</i> , excluindo métodos como <i>Six Sigma</i> ; o domínio de simulação foca em eventos discretos, podendo não atender a outros métodos; empresas menores podem carecer de recursos e expertise para a parte de otimização.

Modelo (autor/ano)	Foco / objetivo	Níveis de maturidade	Dimensões avaliadas	Abordagem	Limitações
<i>Lean Maturity Model for Operational Level Planning</i> (Maasouman, 2014)	Mensurar a maturidade <i>lean</i> em células de produção, no nível operacional.	4 níveis: Entendimento (padronização), Implementação (eficácia), Melhoria (eficiência) e Sustentabilidade (autonomia).	7 eixos: Pessoas, Instalações, Condições de Trabalho, Processos de Produção, Qualidade, JIT e Liderança.	Híbrida (qualitativa e quantitativa). Listas de verificação, análise de indicadores e lógica <i>fuzzy</i> para índice de aderência.	Escopo restrito a células de produção, não avalia a organização como um todo; customização para outros setores é sugerida, mas não é estruturada no próprio modelo.
Modelo de Avaliação da Maturidade em <i>Lean</i> nas Organizações (De Moraes, 2020)	Avaliar a maturidade a partir da cultura e dos princípios <i>lean</i> , e não apenas das ferramentas.	5 níveis: Incerta, Desperta, Sistemática, Integrada e Desafiante.	4 elementos estruturais (adaptados do Modelo Toyota/Shingo): Filosofia, Processos, Pessoas e Parceiros, e Resolução de Problemas / Melhoria Contínua. Além dos 17 princípios do Toyota <i>Way</i> .	Qualitativa. Avaliação da percepção comportamental e cultural, com base em 17 princípios e ponderação por nível hierárquico.	Depende de percepção subjetiva, sujeita a viés ou má compreensão dos temas; exige amostragem mínima rigorosa por nível hierárquico.
Modelo de Avaliação da Maturidade da Implementação do <i>Lean Manufacturing</i> com Abordagem Multicritério Linguística (Piaia, 2019)	Mensurar o grau de implementação do <i>lean manufacturing</i> e classificar empresas de diferentes setores.	3 níveis de classificação das empresas: Básico, Intermediário e Avançado.	5 critérios principais: Qualidade, Recursos Humanos, Cliente, Fornecedor e Sistema Produtivo.	Quantitativa com abordagem multicritério linguística (<i>Fuzzy</i> -TOPSIS com metodologia linguística 2-Tuple), convertendo variáveis	Diferenças de porte e de tempo de implementação entre as empresas dificultam a comparação direta; avaliadores de áreas específicas podem enviesar a percepção sistêmica; procedimento de avaliação

Modelo (autor/ano)	Foco / objetivo	Níveis de maturidade	Dimensões avaliadas	Abordagem	Limitações
				linguísticas em dados numéricos.	pode ter alto custo e longa duração. Exigência de conhecimento técnico para implementação e interpretação.
<i>Fuzzy Maturity-Based Method for Lean Supply Chain Management Assessment - LSCM Maturity Model</i> (Soares et al., 2021)	Avaliar a maturidade da gestão da cadeia de suprimentos <i>lean</i> , relacionando desperdícios e práticas.	5 níveis de maturidade, definidos pela pontuação de desenvolvimento das práticas.	8 pilares: Gestão de TI, Gestão de Fornecedores, Eliminação de Desperdício, JIT, Relacionamento com o cliente, Logística, Comprometimento da Alta Gestão e Melhoria Contínua.	Híbrida. Método <i>Fuzzy Delphi</i> para priorizar desperdícios e matriz de relacionamento entre práticas <i>lean</i> e mitigação de desperdícios.	As relações entre práticas e desperdícios dependem do julgamento de um número limitado de pessoas, permitindo viés e limitações. Diagnostica, mas não gera um plano de ação.

Fonte: Adaptado de De Moraes (2020)

Os modelos analisados compartilham o mesmo objetivo de diagnosticar o estágio de adoção das práticas enxutas e orientar a evolução das organizações, mas divergem quanto ao escopo, estrutura de níveis e abordagem metodológica, variando no atendimento do nível operacional ao corporativo. O modelo de Maasouman (2014) concentra-se nas células de produção e o LMMM (Bento; Tontini, 2018) no chão de fábrica, enquanto o LESAT (Nightingale et al., 2012a) e o modelo do autor De Moraes (2020) atuam no plano estratégico, e propostas como o LCMMO (Nesensohn, 2017) e o LSCM (Soares et al., 2021) agregam a avaliação à construção civil e à cadeia de suprimentos.

Na estrutura de níveis predomina o formato de cinco estágios, ainda que a nomenclatura oscile entre escalas numéricas e descrições qualitativas. No plano metodológico, identificam-se abordagens: quantitativas, como o LMMM, com questionários Likert e equações estruturais; qualitativas, como o LCMMO, o LESAT e o modelo de Moraes, baseadas em declarações ideais e na percepção cultural; e híbridas, que recorrem à lógica *fuzzy* e a métodos multicritério, como o de Maasouman (2014), Piaia (2019) e Soares et al. (2021), para lidar com a subjetividade da avaliação.

As limitações revelam desafios como a dependência de percepções subjetivas, a extensão dos instrumentos, a dificuldade de obter dados sensíveis de desempenho e as restrições à generalização decorrentes de amostras reduzidas, evidenciando que a adequação de cada modelo depende do nível organizacional, do setor e dos objetivos da avaliação.

2.2.1.1. MODELO LESAT

O *Lean Enterprise Self-Assessment Tool* (LESAT) é uma ferramenta de autoavaliação da maturidade organizacional desenvolvida pela *Lean Advancement Initiative* (LAI) do MIT para apoiar organizações em processos de transformação enxuta. O modelo foi desenvolvido em colaboração com representantes da indústria, governo e academia, com forte participação da indústria aeroespacial dos Estados Unidos e do Reino Unido, mas logo se notou ampla aplicabilidade em diferentes setores industriais e organizacionais (Nightingale; Mize, 2002).

Uma característica central do modelo é a avaliação simultânea do estado atual da organização e do estado futuro desejado. Essa abordagem permite identificar lacunas entre o desempenho atual, de tal forma a identificar os principais pontos fortes, fracos e os objetivos estratégicos da organização, auxiliando na priorização de iniciativas de melhoria (Nightingale; Mize, 2002).

O LESAT está organizado em três seções, Quadro 4, que refletem a arquitetura de processos da empresa enxuta (Nightingale et al., 2012b): Seção I - Transformação Empresarial e Liderança; Seção II - Processos do Ciclo de Vida; e Seção III - Infraestrutura Habilitadora.

Quadro 4 - Estrutura LESAT

Seção	Descrição
Transformação Empresarial e Liderança	Avalia o papel da liderança na condução da transformação organizacional e na definição da estratégia de mudança.
Processos do Ciclo de Vida	Avalia os processos relacionados ao desenvolvimento de produtos, geração de valor e atendimento aos <i>stakeholders</i> .
Infraestrutura Organizacional Habilitadora	Avalia os sistemas organizacionais que suportam a execução das atividades empresariais, como processos administrativos e de apoio.

Fonte: Adaptado de Nightingale et al. (2012b)

Além de ser organizado por seção, o modelo é composto por 43 práticas organizacionais que representam processos essenciais para o funcionamento e transformação de uma organização, Quadro 5. A primeira seção é composta por oito grupos de práticas relacionadas à condução da transformação organizacional, o foco está na definição estratégica de mudança, compreender o estado atual, projetar a empresa futura e implementação do plano de transformação. A segunda seção trata dos processos que entregam valor diretamente ao cliente, diferente das outras seções, suas práticas são avaliadas ao longo das etapas do ciclo de vida. A terceira seção abrange os processos de apoio que viabilizam as operações da empresa, que por vezes são negligenciados como fonte de desperdício.

Quadro 5 - Organização das Práticas de Maturidade do LESAT 2.0

Grupo	Descrição	Nº de práticas
Seção I - Transformação/Liderança Empresarial		
I.A.	Determinar o Imperativo Estratégico	3 práticas
I.B.	Engajar a Liderança Empresarial na Transformação	3 práticas
I.C.	Compreender o Estado Atual da Empresa	2 práticas
I.D.	Visualizar e Projetar a Empresa Futura	2 práticas
I.E.	Desenvolver a Estrutura e o Comportamento da Empresa	8 práticas
I.F.	Criar o Plano de Transformação	2 práticas
I.G.	Implementar e Coordenar o Plano de Transformação	4 práticas
I.H.	Nutrir a Transformação e Incorporar o Pensamento Empresarial	6 práticas
Seção II - Processos do Ciclo de Vida		

Grupo	Descrição	Nº de práticas
Seção I - Transformação/Liderança Empresarial		
II.A.	Adquirir, Desenvolver e Alavancar as Capacidades da Empresa	-
II.B.	Otimizar o Desempenho de Toda a Rede	-
II.C.	Incorporar o Valor do Cliente a Jusante na Cadeia de Valor da Empresa	-
II.D.	Engajar Ativamente os <i>Stakeholders</i> a Montante para Maximizar a Criação de Valor	-
II.E.	Prover Capacidade para Monitorar e Gerenciar Risco e Desempenho	-
Seção III - Infraestrutura Habilitadora		
III.A.	Habilitadores Organizacionais	5 práticas
III.B.	Habilitadores de Processo	3 práticas

Fonte: Adaptado de Nightingale et al. (2012b)

Para cada prática, são definidos cinco níveis de maturidade ou capacidade, Quadro 6, que representam estágios progressivos de desenvolvimento da organização, do menos capaz, Nível 1, ao desempenho de classe mundial, Nível 5.

Quadro 6 - Níveis de Maturidade do LESAT 2.0

Nível	Descrição
1 - Inicial	Existe apenas reconhecimento limitado da prática e iniciativas isoladas de melhoria.
2 - Consciência	A prática é conhecida na organização e algumas iniciativas começam a ser implementadas.
3 - Estruturado	A prática é aplicada de forma sistemática em diferentes áreas da organização.
4 - Gerenciado	A prática é gerenciada de forma integrada e suportada por processos de melhoria contínua.
5 - Excelência	A prática está totalmente integrada à organização e representa um padrão de excelência.

Fonte: Adaptado de Nightingale et al. (2012a)

2.3. MACHINE LEARNING

O aprendizado de máquina, *machine learning* (ML), é uma abordagem da ciência da computação cujo objetivo é permitir que sistemas computacionais aprendam a partir de dados sem a necessidade de programação explícita para cada tarefa (Samuel, 1957 apud Shalev-Shwartz; Ben-David, 2014). Em termos mais amplos, o ML pode ser definido como a ciência de programar computadores para que aprendam a partir de dados, sendo amplamente utilizado em problemas cuja solução exige adaptação constante, envolvem elevada complexidade ou apresentam grande volume de informações (Géron, 2019).

Nesse contexto, o processo de aprendizado pode ser compreendido como a transformação de experiências, dados de entrada e resultados observados em conhecimento capaz de apoiar a tomada de decisão. Para isso, utilizam-se técnicas de reconhecimento de

padrões e descoberta automatizada de regularidades nos dados por meio de algoritmos capazes de classificar, prever ou agrupar informações em diferentes categorias.

O aprendizado de máquinas refere-se frequentemente a mudanças em sistemas computacionais capazes de executar atividades associadas à inteligência artificial, como reconhecimento de padrões, diagnósticos, planejamento, controle automatizado e previsão de resultados (Nilsson, 1998). Essas mudanças podem ocorrer tanto na melhoria de sistemas existentes quanto no desenvolvimento de novos sistemas capazes de aprender com dados. Nas últimas décadas, o uso dessas técnicas tem crescido significativamente em função da crescente complexidade dos problemas organizacionais e do aumento do volume de dados disponíveis, o que torna necessário o uso de ferramentas computacionais mais robustas e autônomas. Nesse sentido, a base do aprendizado de máquinas consiste no treinamento de algoritmos capazes de identificar padrões em dados históricos e utilizar essas informações para melhorar seu desempenho em tarefas futuras. Assim, computadores são programados para adquirir habilidades a partir de experiências passadas, aprendendo com os dados para aprimorar continuamente sua capacidade de previsão e decisão.

“A capacidade de aprendizado é considerada essencial para um comportamento inteligente. Atividades como memorizar, observar e explorar situações para aprender fatos, melhorar habilidades motoras/cognitivas por meio de práticas e organizar conhecimento novo em representações apropriadas podem ser consideradas atividades relacionadas ao aprendizado.”
(Faceli et al., 2025)

Os sistemas de ML podem ser classificados de acordo com o tipo de supervisão utilizado durante a fase de treinamento. Entre as abordagens mais comuns destacam-se o aprendizado supervisionado e o aprendizado não supervisionado.

No aprendizado supervisionado, os dados de treinamento são apresentados ao algoritmo juntamente com as respostas corretas esperadas, denominadas *labels*. O objetivo é que o algoritmo identifique uma regra capaz de mapear as entradas para as saídas desejadas, aprendendo a reproduzir esse comportamento em novos dados (Géron, 2019). Entre os principais algoritmos dessa categoria destacam-se regressão linear, regressão logística, máquinas de suporte vetorial, árvores de decisão, florestas aleatórias e redes neurais (Alpaydin, 2010).

No aprendizado não supervisionado, por sua vez, não há a presença de respostas previamente definidas. Nesse caso, o algoritmo recebe apenas os dados de entrada e deve identificar automaticamente padrões ou estruturas presentes nos dados. Entre os algoritmos

mais utilizados nessa abordagem estão K-means, DBSCAN, agrupamento hierárquico, Kernel PCA e Eclat (Alpaydin, 2010).

2.3.1. DECISION TREE


Uma árvore de decisão, *Decision Tree* (DT), é um algoritmo supervisionado amplamente utilizado em tarefas de classificação e regressão. Seu funcionamento baseia-se na divisão sucessiva do conjunto de dados em subconjuntos menores, de acordo com critérios definidos a partir dos atributos das instâncias. Cada divisão busca maximizar a pureza dos subconjuntos gerados, resultando em uma estrutura hierárquica que representa o processo de tomada de decisão (Molnar, 2019).

A estrutura de uma árvore é composta por diferentes tipos de nós: os nós internos, ou de decisão, representam testes aplicados aos atributos de entrada; nós-folha, ou terminais, representam as saídas finais, correspondentes às previsões do modelo. Durante o treinamento, o algoritmo aprende quais atributos e valores de divisão que ao utilizar métricas otimizam a separação das classes, ou minimizam o erro, no caso de regressão (Molnar, 2019).

A árvore pode ser compreendida como uma função que mapeia um vetor de atributos de entrada para um único valor de saída, chegando à sua decisão executando uma sequência de testes. O processo inicia-se na raiz da árvore e percorre os ramos de acordo com os valores dos atributos da instância, até atingir um nó terminal, que define a predição final. Cada nó interno está associado a um atributo específico, e seus ramos são rotulados com os possíveis valores ou condições associadas a esse atributo. Os nós-folha determinam o valor a ser retornado, seja uma classificação ou um valor numérico, regressão (Russell; Norvig, 2022).

Os nós internos são testes de padrões de entrada e os nós-folha ou terminais são categorias de padrões. Uma árvore de decisão atribui um número de classe ou saída a um padrão de entrada, filtrando o padrão pelos testes na árvore, cada teste tem resultados mutuamente exclusivos e exaustivos, Figura 3 (Nilsson, 1998).

Figura 3 - Representação da Árvore de Decisão



Fonte: Nilsson (1998)

2.3.2. *RANDOM FOREST*

O algoritmo *Random Forest* (RF), ou floresta aleatória, é uma técnica de aprendizado supervisionado baseada no conceito de *ensemble learning*, na qual múltiplas DT são construídas e combinadas para formar um modelo mais robusto e preciso. Cada árvore individual é treinada a partir de um subconjunto aleatório dos dados de treinamento, utilizando também uma seleção aleatória de atributos em cada divisão, o que promove diversidade entre as árvores e reduz a correlação entre elas (Salman; Kalakech; Steiti, 2024).

Durante o processo de predição, o modelo gera uma resposta individual de cada árvore, e a decisão final é tomada por votação majoritária, no caso de classificação, ou pela média das saídas, em regressão. Esse mecanismo de agregação torna o modelo menos suscetível a overfitting, um problema comum em DT individuais, além de melhorar a capacidade de generalização (Géron, 2019).

Segundo Breiman (2001), o erro de generalização de uma RF tende a convergir para um limite conforme o número de árvores na floresta aumenta. Esse erro depende de dois fatores principais: a força preditiva das árvores individuais e o grau de correlação entre elas. Quanto mais fortes e menos correlacionadas forem as árvores, melhor será o desempenho do modelo coletivo.

Portanto, a RF é considerada um classificador poderoso e versátil, especialmente eficaz em problemas com grande quantidade de variáveis e relações complexas, sendo amplamente utilizada em aplicações industriais, biomédicas, financeiras e organizacionais.

2.3.3. APLICAÇÕES DE APRENDIZADO DE MÁQUINAS

Aprendizado de máquinas possuem diversas aplicações, como no estudo de Beaulac e Rosenthal (2019), que através de um conjunto de dados buscou prever através do algoritmo de RF o sucesso acadêmico dos estudantes de graduação, a partir dos primeiros semestres cursados e a área de especialização escolhida para os estudantes que concluíram, com base nas primeiras matérias cursadas. O autor coletou mais de 1,6 milhões de notas de mais de 65.000 estudantes entre 2000 e 2010 da Universidade de Toronto para treinar seu ML, que atingiu uma precisão de 78,84% para prever a conclusão da graduação e uma precisão de 47,41% para previsão da área de especialização.

Orji e Vassileva (2022) também aplicam na área acadêmica, para prever o desempenho dos alunos e as estratégias de estudo dos alunos, com a construção de cinco modelos de ML usando DT, *K-Nearest Neighbour* (KNN), RF, regressão linear e *Support Vector Machine* (SVM). A pesquisa investiga a influência combinada de várias dimensões, como motivação intrínseca e extrínseca, necessidades psicológicas básicas do tipo relacionamento, competência e autoestima. Os modelos de DT e RF obtiveram os melhores resultados em termos de precisão e de menor erro absoluto médio.

Al-Barrak e Al-Razgan (2016) utilizam mineração de dados educacionais para prever a média final dos estudantes com base em suas notas em cursos anteriores através do algoritmo de DT. O processamento dos dados contou com a remoção de atributos irrelevantes, a seleção de cursos obrigatórios e a discretização de notas numéricas, uma vez que o sistema de notas da King Saud University é por meio de conceitos, excelente a ruim, A+ a F.

Há também aplicações no âmbito da manutenção, Jiang, Li e Cheng (2024) investigam a tomada de decisão em manutenção para veículos de fontes alternativas e renováveis, como elétricos e híbridos, através da aplicação de DT e técnicas de aprendizado de máquinas. A necessidade do estudo surgiu devido à preocupação com a segurança desses veículos que já houve relatos de incidentes de combustão na China.

No aspecto industrial, Ali et al. (2024), visa avaliar o nível de maturidade da Indústria 4.0 em empresas utilizando ML, com árvore de decisão, floresta aleatória e SVM, destacando o impacto da metodologia *lean* na transformação digital. O nível de maturidade geral da indústria 4.0 foi calculado como uma média ponderada de 6 tecnologias: Internet das coisas (IoT), análise industrial, interface homem-máquina avançada, manufatura em nuvem, manufatura aditiva e automação avançada.


Já Sekhar, Solke e Shah (2023) buscaram desenvolver sensores baseados em aprendizado de máquina, explorando 29 modelos diferentes, para prever os níveis de manufatura enxuta em indústrias automotivas, com base em suas flexibilidades de manufatura, como volume, produto, mão de obra, máquina e manuseio de materiais. Os dados coletados através de questionários para avaliar os níveis de manufatura enxuta de 46 empresas foram divididos em conjuntos de treinamento, 67,39%, validação, 21,74%, e teste 10,86%. Os modelos de melhor desempenho foram redes neurais de três camadas e árvores de decisão.

3. METODOLOGIA

3.1. ETAPAS DA PESQUISA

Para atingir o objetivo proposto, o estudo foi estruturado em nove etapas sequenciais, apresentadas na Figura 4 e detalhadas ao longo deste capítulo.

Figura 4 - Etapas da Pesquisa



Fonte: Elaborado pela autora (2026)

Na Etapa 1, a pesquisa compreende a revisão da literatura com bases conceituais sobre modelos de maturidade de pensamento enxuto, explorando livros e artigos de referência nos últimos anos, bem como de estudos que integram aprendizado de máquina na avaliação organizacional. Na Etapa 2, consiste na seleção do modelo de maturidade de referência para servir como base de rotulagem dos dados das empresas. Na Etapa 3, corresponde a elaboração e aplicação do instrumento de coleta, construído com base nas dimensões do LESAT 2.0, com 29 questões Likert e 12 questões sobre adoção de ferramentas.

Na Etapa 4, trata a estruturação da base de dados, com mapeamento das questões às subseções do LESAT, codificação das variáveis categóricas, normalização das respostas, cálculo do Alfa de Cronbach por dimensão e geração do índice de consistência. A Etapa 5, refere-se à construção da variável-alvo, a partir do *score* composto ponderado e dividida em três classes de maturidade. Na Etapa 6, compreende o desenvolvimento e treinamento dos algoritmos supervisionados de aprendizado de máquinas com validação cruzada estratificada. A Etapa 7, corresponde a validação e avaliação de desempenho dos modelos por meio de métricas de acurácia, precisão, recall, F1-*score* e análise de importância de variáveis. Por fim, nas Etapas 8 e 9, tratam, respectivamente, a análise dos resultados obtidos e da discussão e propostas para estudos futuros. As seções seguintes detalham cada uma dessas etapas.

3.2. NATUREZA DA PESQUISA

A pesquisa é classificada como aplicada, uma vez que tem como finalidade gerar conhecimento voltado à solução de problemas específicos (Prodanov; Freitas, 2013). No contexto deste estudo, essa aplicação está relacionada ao desenvolvimento de uma abordagem para avaliação da maturidade *lean* em organizações, com potencial de contribuir para a melhoria dos processos de tomada de decisão.

Quanto aos objetivos, a pesquisa é caracterizada como exploratória, pois busca aprofundar o entendimento sobre a avaliação da maturidade enxuta e propor uma abordagem alternativa baseada na integração de dados qualitativos e técnicas de aprendizado de máquina. Esse tipo de pesquisa permite maior familiaridade com o problema investigado, contribuindo para o refinamento de conceitos e construção de soluções metodológicas (Botelho; Cruz, 2013).

3.3.FORMA DE ABORDAGEM DO PROBLEMA

O estudo adota uma abordagem mista, combinando métodos qualitativos e quantitativos, com o objetivo de proporcionar uma análise mais abrangente da avaliação de maturidade. A abordagem qualitativa está relacionada à compreensão das práticas organizacionais e à coleta de dados por meio de questionários estruturados, permitindo identificar percepções, padrões e

dimensões relevantes do problema investigado. Esse tipo de abordagem possibilita maior flexibilidade na análise, permitindo que categorias e interpretações sejam construídas de forma indutiva a partir dos dados (Creswell, 2010).

Já a abordagem quantitativa está associada à mensuração e tratamento dos dados coletados, permitindo a análise estruturada das informações. Conforme Bryman, 1989 apud Miguel et al. (2012), as preocupações mais recorrentes da abordagem quantitativa são mensurabilidade, causalidade, generalização e replicação dos resultados.

No presente estudo, a integração dessas abordagens ocorre de forma complementar. Inicialmente, os dados qualitativos são estruturados a partir das respostas obtidas nos questionários, sendo posteriormente transformados em variáveis quantitativas. Em seguida, esses dados são utilizados na construção de um modelo preditivo, por meio da aplicação de algoritmos de aprendizado de máquina supervisionado, com o objetivo de classificar o nível de maturidade *lean* das organizações analisadas.

Dessa forma, a abordagem mista permite estruturar e sistematizar a subjetividade das avaliações, ao mesmo tempo em que amplia a capacidade de análise dos dados, fornecendo suporte mais robusto para a tomada de decisão (Creswell, 2010; Miguel et al., 2012).

Cabe destacar uma limitação metodológica inerente à abordagem proposta relacionada ao uso do instrumento LESAT 2.0. Por se tratar de um instrumento de autoavaliação qualitativa, seus resultados estão sujeitos a percepção e a interpretação dos respondentes. Como os algoritmos de aprendizado supervisionado são treinados a partir dos rótulos atribuídos a esses dados, o modelo tende a aprender e reproduzir tanto os padrões identificados quanto eventuais vieses presentes na avaliação subjetiva original, não representando, portanto, uma medida objetiva e independente de maturidade *lean*. Dessa forma, a contribuição da abordagem não está em eliminar a subjetividade do LESAT 2.0, mas em estruturá-la de forma sistemática, reproduzível e escalável, reduzindo a variabilidade das interpretações entre avaliações e tornando o processo de diagnóstico mais consistente ao longo do tempo.

3.4.CLASSIFICAÇÃO DA PESQUISA QUANTO AOS PROCEDIMENTOS

Quanto aos procedimentos, a pesquisa é classificada primariamente como levantamento, *survey*, uma vez que os dados serão coletados por meio de questionários estruturados aplicados a múltiplos respondentes em organizações que utilizam práticas de pensamento enxuto. Esse tipo de abordagem permite a coleta padronizada de informações, possibilitando a análise de padrões e relações entre as variáveis investigadas (Prodanov; Freitas, 2013).

A etapa da modelagem preditiva, por sua vez, caracteriza-se como pesquisa experimental, pois apresenta propriedades de manipulação de pelo menos uma das características dos elementos estudados, controle e distribuição aleatória, com natureza computacional, na qual diferentes algoritmos de aprendizado de máquinas são testados e avaliados sistematicamente por meio de métricas de desempenho (Gil, 2002).

3.5.UNIVERSO E AMOSTRA DA PESQUISA

O universo da pesquisa é composto por empresas brasileiras que adotam práticas enxutas, independentemente do seu porte ou segmento de atuação. A amostra é caracterizada como não probabilística por conveniência e intencionalidade, direcionada a organizações com disponibilidade e acessibilidade para participação, priorizando aquelas com conhecimento ou experiência prévia em *lean*.

Os dados foram coletados junto a profissionais atuantes nas organizações, tais como engenheiros, analistas, líderes de produção ou gestores, que possuam conhecimento sobre os processos produtivos e práticas adotadas. A fase inicial de coleta resultou em 43 respondentes válidos, distribuídos entre 15 segmentos industriais distintos, Quadro 7. Embora o instrumento não tenha coletado o nome da empresa de origem dos respondentes por razões de anonimato, a diversidade de segmentos, 15 distintos, hierarquias, 3 níveis, e áreas funcionais, 12 distintas, observada entre os 43 respondentes sugere que a amostra represente entre 20 a 25 organizações distintas.

Quadro 7 - Perfil dos respondentes

Característica	Categoria	N (%)
Segmento	Indústria de Manufatura	15 (34,9%)
	Automotivo / Duas Rodas	6 (14,0%)
	Eletroeletrônico	5 (11,6%)
	Químico / Farmacêutico	4 (9,3%)
	Demais segmentos	13 (30,2%)
Nível hierárquico	Operacional	29 (67,4%)
	Tático	8 (18,6%)
	Estratégico	6 (14,0%)
Conhecimento <i>lean</i>	Avançado	17 (39,5%)

Característica	Categoria	N (%)
	Intermediário	14 (32,6%)
	Básico	11 (25,6%)
	Nenhum	1 (2,3%)

Fonte: Elaborado pela autora (2026)

O dimensionamento de amostras em pesquisas que combinam instrumentos de autoavaliação com técnicas de aprendizado de máquina supervisionado envolve considerações que vão além dos critérios estatísticos clássicos. Forster (2002) reflete sobre como o tamanho da amostra afeta a seleção de modelos estatísticos e a precisão das previsões. Segundo o autor amostras grandes favorecem a precisão preditiva interpolativa, previsão de novos valores dentro do mesmo intervalo, porém para a precisão preditiva extrapolativa, previsão de fenômenos fora do intervalo dos dados originais pode ser um problema. Além disso, amostras muito pequenas ocorrem o chamado *overfitting*, fenômeno em que o modelo se ajusta perfeitamente às peculiaridades e aos ruídos daquela amostra específica, dificultando a generalização.

Peduzzi et al. (1996) concluíram por meio de simulações com dados reais que um mínimo de 10 eventos por variável é necessário para manter a validade do modelo estatístico. O estudo simulou ainda os riscos de amostras pequenas, violação da regra mínima de 10 eventos, como viés nos resultados, associações paradoxais, falhas de convergência estatística, intervalos de confiança não confiáveis e testes conservadores demais.

De forma prática, Probst, Wright e Boulesteix (2019) abordam o tamanho amostral como um hiperparâmetro interno que pode ser ajustado para otimizar o algoritmo de aprendizado RF. O conceito de dimensionamento de amostra referido pelo estudo indica quantas observações do banco de dados serão extraídas para treinar cada árvore individual dentro da floresta. Ou seja, caso sejam dimensionadas amostras menores por árvore faz com que elas fiquem mais diversas e menos correlacionadas entre si, além de reduzir o tempo de processamento, porém a precisão de cada árvore diminui, pois aprendem com menos dados. No entanto, esse estudo aponta que usar uma quantidade de amostras menor do que o padrão frequentemente resulta em desempenhos melhores, mas ressalta que o tamanho ideal da amostra por árvore é dependente de cada problema.

Hair et al. (2019) detalha sobre o dimensionamento de amostras em diversas técnicas estatísticas diferentes, onde amostras pequenas perdem a capacidade de identificar relações e aumentam o risco de *overfitting*, enquanto amostras muito grandes tornam os testes estatísticos

sensíveis a qualquer efeito. Para regressão simples, uma variável, 20 observações é satisfatório, mas para a regressão múltipla, é necessário um mínimo de 50 observações, sendo 100 o valor preferível para manter os níveis adequados. De forma geral, deve-se manter 5 observações para cada variável, idealmente e recomendado seriam 15 a 20 observações para cada.

O objetivo primário do estudo é investigar a viabilidade metodológica de aplicar técnicas de ML à predição de maturidade *lean*, porém a pesquisa se insere no paradigma das pesquisas exploratórias. Nesse contexto, tamanhos amostrais menores são academicamente aceitos, desde que as limitações sejam claramente reconhecidas e as análises estejam adequadamente alinhadas ao volume de dados disponível (Forster, 2002; Hair et al., 2019).

Considerando os critérios apresentados, reconhece-se que a amostra atual de 43 respondentes é inferior ao dimensionamento ideal recomendado para a aplicação plena de modelos de aprendizado de máquina supervisionado com 28 variáveis preditoras. Diante disso, o presente estudo posiciona-se como uma prova de conceito metodológica, cujo objetivo é investigar a viabilidade da abordagem proposta e identificar padrões iniciais nos dados, e não produzir um modelo preditivo com garantias de generalização ampla. Para desenvolver um modelo preditivo com tais garantias a continuidade da coleta de dados, idealmente de 150 a 200 respondentes, torna-se necessária.

Contudo, para mitigar os riscos associados ao tamanho amostral reduzido, foram adotadas algumas estratégias. A primeira foi a redução da granularidade da variável-alvo de cinco para três classes, elevando o número médio de amostras por classe para aproximadamente 14 respondentes e tornando o problema de classificação mais tratável para o volume disponível. A segunda foi a agregação das 29 variáveis Likert em 13 variáveis dimensionais, reduzindo o número de variáveis e melhorando a razão, observações e variável, de 1,5 para 3,3. A terceira foi a validação cruzada estratificada com $k = 5$ dobras, que oferece balanço ideal entre viés e variância. Como estratégia complementar, empregou-se o *Leave-One-Out Cross-Validation* (LOOCV), que utiliza praticamente todos os dados disponíveis para o treinamento de cada modelo, gerando estimativas quase sem viés, característica especialmente útil em amostras restritas (James et al., 2021; Kohavi, 1995).

3.6. PROCEDIMENTOS PARA A COLETA DE DADOS

A coleta de dados foi realizada por meio de questionários estruturados, aplicado por formulário eletrônico via Google Forms, a profissionais responsáveis pela implementação e acompanhamento de práticas de *lean* nas organizações. O formulário foi disponibilizado de forma padronizada e ampla, sem direcionamento a nenhuma organização específica, sendo

divulgado por meio de redes profissionais e grupos ligados à comunidade lean, de modo que cada respondente participou de forma independente, o que explica a diversidade de segmentos, hierarquias e áreas funcionais observada na amostra. O instrumento de coleta foi elaborado com base nas dimensões do modelo de maturidade selecionado como referência, o LESAT, garantindo alinhamento teórico e consistência na avaliação das práticas organizacionais.

O instrumento de coleta de dados é composto por 41 questões, distribuídas em dois grupos, Quadro 8. O primeiro grupo abrange 29 questões avaliadas em escala Likert de 1 a 5 pontos, cobrindo as três seções do LESAT. O segundo grupo compreende 12 questões sobre o nível de adoção de ferramentas *lean* específicas, avaliadas em escala ordinal de quatro categorias: Não utilizada, Utilização pontual, Moderada e Consolidada. Adicionalmente, foram coletadas variáveis de caracterização do respondente, como segmento de atuação, posição hierárquica, área de atuação e nível de conhecimento sobre *lean*, que serviram como variáveis de contexto no modelo.

Quadro 8 - Estrutura do instrumento de coleta de dados

Grupo	Seção do LESAT	Nº de questões	Conteúdo avaliado
1 - Likert	I - Transformação Empresarial e Liderança	20	Estratégia, liderança, visão de futuro, estrutura organizacional, plano de transformação e aprendizado;
	II - Processos do Ciclo de Vida	2	Valor ao cliente e gestão de desempenho ao longo do ciclo de vida;
	III - Infraestrutura Habilitadora	7	Medição de desempenho, sistemas de informação, padronização e redução de variação;
2 - Ferramentas	Adoção de ferramentas <i>lean</i>	12	Nível de utilização de 12 ferramentas: 5S, VSM, Kaizen, Trabalho Padronizado, Gestão Visual, Kanban, JIT, Poka-Yoke, TPM, SMED, Andon e Heijunka.

Fonte: Elaborado pela autora (2026)

3.7.PROCEDIMENTOS PARA A ANÁLISE DOS DADOS

A análise dos dados será conduzida em três fases principais: mapeamento, pré-processamento dos dados e modelagem preditiva.

3.7.1. MAPEAMENTO DAS PRÁTICAS COM AS DIMENSÕES DO LESAT

Para garantir que o instrumento siga o modelo LESAT 2.0 e permitir a análise por dimensões, cada uma das 29 questões Likert foi associada à sua respectiva prática e subseção do LESAT. Esse mapeamento cumpre duas finalidades: a agregação das respostas por dimensão conceitual, o que reduz a dimensionalidade do espaço de variáveis e preserva a estrutura teórica do instrumento; e o cálculo do Alfa de Cronbach, coeficiente estatístico para medir a confiabilidade de questionários por subseção. O Quadro 9 apresenta o mapeamento completo das questões as práticas e subseções do LESAT 2.0.

Quadro 9 - Mapeamento das questões do instrumento baseados no LESAT 2.0

Cód.	Seção	Subseção	Prática LESAT
Q01	I	I.A	I.A.1 - Integrar transformação ao planejamento estratégico
Q02	I	I.A	I.A.3 - Articular o caso para transformação
Q03	I	I.B	I.B.1 - Cultivar pensamento empresarial na liderança
Q04	I	I.B	I.B.2 - Obter comprometimento da alta liderança
Q05	I	I.C	I.C.1 - Analisar processos e interações
Q06	I	I.C	I.C.2 - Garantir estabilidade e fluxo
Q07	I	I.D	I.D.1 - Vislumbrar o estado futuro da empresa
Q08	I	I.D	I.D.2 - Arquitetar o futuro da empresa
Q09	I	I.E	I.E.1 - Reconciliar sistemas, políticas e visão
Q10	I	I.E	I.E.2 - Alinhar sistema de medição de desempenho
Q11	I	I.E	I.E.3 - Alinhar incentivos
Q12	I	I.E	I.E.4 - Capacitar agentes de mudança
Q13	I	I.F	I.F.1 - Criar plano de transformação empresarial
Q14	I	I.F	I.F.2 - Comunicar o plano de transformação
Q15	I	I.G	I.G.2 - Comprometer recursos para a transformação
Q16	I	I.G	I.G.3 - Prover educação e treinamento
Q17	I	I.G	I.G.4 - Acompanhar implementação detalhada
Q18	I	I.H	I.H.2 - Nutrir a transformação
Q19	I	I.H	I.H.3 - Capturar e difundir lições aprendidas

Cód.	Seção	Subseção	Prática LESAT
Q20	I	I.H	I.H.4 - Impactar o planejamento estratégico
Q21	II	II.C	II.C - Incorporar valor do cliente no fluxo de valor
Q22	II	II.E	II.E - Monitorar e gerenciar riscos e desempenho
Q23	III	III.A	III.A.1 - Sistema de medição de desempenho empresarial
Q24	III	III.A	III.A.4 - Habilitar com sistemas e ferramentas de informação
Q25	III	III.B	III.B.1 - Padronização de processos
Q26	III	III.B	III.B.2 - Ferramentas e sistemas comuns
Q27	III	III.B	III.B.3 - Redução de variação de processos
Q28	III	III	Operação estável e redução de paradas não planejadas
Q29	III	III	Gestão visual e identificação de anormalidades

Fonte: Elaborado pela autora (2026), com base em MIT (2012)

3.7.2. PRÉ-PROCESSAMENTO E TRANSFORMAÇÃO DOS DADOS

Antes da utilização como entrada para os modelos de aprendizado de máquina, os dados coletados passaram por um processo estruturado de pré-processamento composto pelas etapas descritas a seguir.

As 43 respostas obtidas no questionário, originalmente na escala de 1 a 5, foram padronizadas para o intervalo $[0,1]$ mediante divisão por 5. Essa padronização é necessária para garantir que todas as variáveis contribuam de forma proporcional para o modelo, evitando que a escala numérica introduza viés implícito (James et al., 2021). Já as respostas referentes ao nível de adoção das 12 ferramentas *lean* foram transformadas por meio de codificação ordinal, preservando a ordem natural das categorias, conforme apresentado no Quadro 10. Após a codificação, os valores foram padronizados para o intervalo $[0,1]$ com divisão por 3.

Quadro 10 - Codificação ordinal para as questões de adoção de ferramentas

Categoria original	Valor ordinal	Valor padronizado ($\div 3$)
Não utilizada	0	0,00
Utilização pontual	1	0,33
Utilização moderada	2	0,67

Categoria original	Valor ordinal	Valor padronizado ($\div 3$)
Utilização consolidada	3	1,00

Fonte: Elaborado pela autora (2026)

Em vez de utilizar os 29 itens Likert de forma isolada como variáveis independentes, as respostas foram agregadas por subseção do LESAT, calculando-se a média normalizada dos itens pertencentes a cada dimensão. Dessa forma, a redução do número de variáveis de 29 para 13 mitiga o risco associado à dimensionalidade em amostras pequenas. Além disso, aumenta a interpretabilidade dos resultados, permitindo identificar com maior clareza quais dimensões organizacionais mais impactam o nível de maturidade.

Com isso, o conjunto de dados final utilizado no modelo é composto por 13 variáveis de *scores* médios por subseção do LESAT, 12 variáveis de adoção de ferramentas *lean*, 2 variáveis de perfil do respondente e 1 índice de consistência das respostas.

3.7.3. VALIDADE INTERNA DO INSTRUMENTO E ÍNDICE DE CONSISTÊNCIA

Uma das limitações inerentes a instrumentos de autoavaliação é a presença de vieses de resposta, que podem comprometer a confiabilidade dos dados e, consequentemente, a qualidade do modelo preditivo. Para tratar esse problema, este estudo adota duas estratégias complementares.

Uma estratégia é o Alfa de Cronbach (Equação 1), que foi calculado para cada subseção do LESAT com dois ou mais itens, avaliando a consistência interna das respostas dentro de cada dimensão conceitual, Quadro 11. O coeficiente Alfa de Cronbach varia entre 0 e 1, sendo o valor de 0,70 considerado o limite inferior aceitável de consistência interna. Esse limite pode ser flexibilizado para 0,60 em pesquisas exploratórias, mas deve ser elevado sob maior rigor caso a escala possua um número grande de itens (Hair et al., 2019).

$$\alpha = \left(\frac{k}{k-1} \right) \times \left(1 - \frac{\sum \sigma_i^2}{\sigma_t^2} \right) \quad (1)$$

Onde k é o número de itens na dimensão, $\sum \sigma_i$ sendo a soma das variâncias individuais de cada item e σ_t a variância da soma total dos itens.

Quadro 11 - Alfa de Cronbach por subseção do LESAT

Subseção	Seção	N de itens	Alfa de Cronbach	Interpretação
I.A	I	2	0,674	Aceitável ($\geq 0,60$)
I.B	I	2	0,902	Excelente ($\geq 0,80$)

Subseção	Seção	N de itens	Alfa de Cronbach	Interpretação
I.C	I	2	0,713	Bom ($\geq 0,70$)
I.D	I	2	0,881	Excelente ($\geq 0,80$)
I.E	I	4	0,812	Excelente ($\geq 0,80$)
I.F	I	2	0,945	Excelente ($\geq 0,80$)
I.G	I	3	0,893	Excelente ($\geq 0,80$)
I.H	I	3	0,851	Excelente ($\geq 0,80$)
II.C	II	1	-	Item único - não calculável
II.E	II	1	-	Item único - não calculável
III	III	2	0,800	Excelente ($\geq 0,80$)
III.A	III	2	0,802	Excelente ($\geq 0,80$)
III.B	III	3	0,792	Bom ($\geq 0,70$)

Fonte: Elaborado pela autora (2026)

Os resultados demonstram consistência interna de boa a excelente na grande maioria das subseções. Os coeficientes mais elevados foram observados em I.F, I.B, I.D e I.G, indicando alta coerência interna entre as práticas desses grupos. A subseção I.A apresentou o menor coeficiente, classificado como aceitável, indicando que as práticas I.A.1 e I.A.3, embora pertençam ao mesmo grupo teórico, capturam aspectos parcialmente distintos da percepção dos respondentes.

Para cada respondente, foi calculado um índice de consistência global baseado no desvio-padrão das respostas dentro de cada subseção LESAT com dois ou mais itens. A lógica é que respondentes que atribuem valores muito díspares a práticas de um mesmo construto conceitual exibem sinais de inconsistência que podem refletir falta de familiaridade com o tema, interpretação equivocada dos itens ou viés de resposta. O índice de consistência de cada dimensão foi calculado conforme a Equação 2.

$$IC = 1 - \left(\frac{DP_{dim}}{DP_{max}} \right) \quad (2)$$

Onde DP_{dim} é o desvio-padrão das respostas do respondente nos itens da dimensão e $DP_{max} = 2,0$ representa o desvio-padrão máximo teórico para uma escala de 1 a 5. O índice de consistência global de cada respondente é a média dos índices por dimensão, variando entre 0, totalmente inconsistente, e 1, totalmente consistente. Os resultados indicam índice de

consistência médio de 0,725, com valores individuais variando entre 0,385 e 0,968. Treze dos 43 respondentes apresentaram índice abaixo de 0,65, o que representa 30,2% da amostra. O índice de consistência foi incluído como variável preditora adicional no modelo, permitindo que o algoritmo pondere, implicitamente, a confiabilidade das respostas de cada respondente.

3.8.CONSTRUÇÃO DA VARIÁVEL-ALVO

A variável-alvo do modelo supervisionado foi construída a partir de um *score* composto, que integra a média de duas dimensões principais do instrumento: as práticas organizacionais *lean*, Likert padronizado, e a adoção de ferramentas padronizado. O *score* composto foi calculado conforme a Equação 3:

$$score = (0,7 \times \bar{x}_{likert}) + (0,3 \times \bar{x}_{fer}) \quad (3)$$

A ponderação adota, 70% para a média das práticas organizacionais, $\bar{x}_{likert}$, e 30% para a média da adoção de ferramentas, $\bar{x}_{fer}$, refletindo a premissa do LESAT 2.0 de que a maturidade *lean* é determinada primordialmente pela transformação organizacional e de liderança, e secundariamente pelo uso de ferramentas operacionais. O *score* composto, que varia no intervalo [0,1], foi discretizado em três classes de maturidade, conforme o Quadro 12.

O *score* composto apresentou média de 0,600 e desvio-padrão de 0,211, com valores entre 0,174 e 0,936, indicando boa dispersão ao longo de toda a escala. A opção por três classes, em vez de cinco níveis originais do LESAT, justifica-se pelo tamanho amostral.

Quadro 12 - Definição das classes de maturidade *lean* e distribuição amostral

Nível	Classe	Faixa de <i>score</i>	N de respondentes
1	Inicial	0,00 - 0,40	9 (20,9%)
2	Em desenvolvimento	0,40 - 0,65	16 (37,2%)
3	Avançado	0,65 - 1,00	18 (41,9%)

Fonte: Elaborado pela autora (2026)

A distribuição resultante, 20,9% considerados na classe Inicial, 37,2% Em desenvolvimento e 41,9% Avançado, é satisfatória para os fins do estudo, apresentando grau de equilíbrio compatível com as estratégias de validação cruzada estratificada adotadas.

4. DESENVOLVIMENTO

4.1.ANÁLISE EXPLORÁTORIA DOS DADOS


A análise exploratória de dados constitui uma etapa fundamental no desenvolvimento de modelos preditivos, pois permite compreender a estrutura, a distribuição e as relações

presentes nos dados antes da aplicação de qualquer algoritmo (Géron, 2019). No presente estudo, a análise foi conduzida sobre a base de dados composta por 43 respondentes e 41 variáveis de entrada, com o objetivo de identificar padrões, verificar a adequação das distribuições e apoiar as decisões de modelagem.

4.1.1. PERFIL DOS RESPONDENTES

A Figura 5 apresenta o perfil completo da amostra, composta por 43 respondentes, distribuída por segmento de atuação, nível hierárquico, nível de conhecimento sobre *lean* e classificação na variável-alvo de maturidade. De modo geral, o diagnóstico do perfil é relevante para a interpretação dos resultados do modelo preditivo, uma vez que se trata de dados autodeclarados que servirão de base para o aprendizado do modelo.

Figura 5 - Perfil dos respondentes



Fonte: Elaborado pela autora (2026)

Em relação ao segmento de atuação, a indústria de manufatura concentra a maior parte dos respondentes, 34,9%, seguida do setor automotivo, 14%, e eletroeletrônico, 11%. Os demais segmentos químicos, farmacêutico, alimentício, logística, serviços, entre outros, somam 39,5% da amostra.


Quanto ao nível hierárquico, 67,4% da amostra corresponde a respondentes em posições operacionais, como analistas, técnicos e especialistas. Seguido de 18,6% pelo nível tático, como líderes, supervisores e gerentes e por fim, pelo nível estratégico com 14% composto por membros de alta gestão e diretoria. De tal forma, essa distribuição reflete uma característica da área industrial, uma vez que profissionais de nível operacional representam o maior contingente de uma empresa, além de serem os que mais executam diretamente as práticas *lean* no dia a dia.

Em relação ao nível de conhecimento *lean*, cerca de 72,1% declararam conhecimento intermediário ou avançado, o que favorece a qualidade e a consistência das respostas obtidas. 25,6% declararam possuir conhecimento básico e apenas 2,3% declararam nenhum conhecimento sobre o tema.

4.1.2. DISTRIBUIÇÃO DO *SCORE* E DA VARIÁVEL-ALVO

A Figura 6 apresenta a distribuição do *score* composto de maturidade *lean*, calculado a partir da ponderação entre as práticas organizacionais, peso de 70%, e a adoção de ferramentas, peso 30%, e sua segmentação nas três classes definidas.

Figura 6 - Distribuição do score composto e separação por classe de maturidade



Fonte: Elaborado pela autora (2026)


O *score* apresentou média de 0,600 e desvio padrão de 0,211, com valores variando entre 0,174 e 0,936. A distribuição observada no histograma indica uma assimetria a direita, evidenciando maior concentração de respondentes na faixa intermediária da escala. Considerando os pontos de corte estabelecidos em 0,40 para transição entre as classes Inicial e Em desenvolvimento, e em 0,65 para a transição entre Em desenvolvimento e Avançado, verificou-se que 20,9% dos respondentes foram classificados como Inicial, 37,2% na categoria Em desenvolvimento e 41,9% na classe Avançado.

O *boxplot* por classe confirma que as três distribuições apresentam separação clara, com sobreposição mínima entre classes adjacentes. Além disso, apresenta ausência de *outliers* extremos dentro de cada classe, indicando a homogeneidade interna dos grupos formados.

4.1.3. ANÁLISE POR DIMENSÃO DO LESAT

A Figura 7 apresenta o *score* médio normalizado para cada uma das 13 subseções do LESAT avaliadas no instrumento, acompanhado do respectivo desvio-padrão como indicador de dispersão interna.

Figura 7 - *Score* médio por subseção do LESAT



Fonte: Elaborado pela autora (2026)


A análise dos *scores* por dimensão revela que a subseção I.D obteve o maior *score* médio, 0,712, indicando que os respondentes percebem com maior clareza a existência de uma visão compartilhada e de esforços organizacionais para o futuro. Em contraste, a subseção II.C apresentou o menor *score* médio, 0,535, sugerindo que a integração dos clientes e stakeholders ao longo da cadeia de valor ainda representa uma lacuna relevante nas organizações investigadas.

Ao realizar a média dos *scores* das três seções principais do LESAT, obteve-se *scores* similares. A Seção I, Transformação Empresarial e Liderança, obteve 0,654, a Seção III,

Infraestrutura Habilitadora, com 0,657 e a Seção II, Processos do Ciclo de Vida, ficou abaixo com 0,581. Esse resultado sugere que as organizações tendem a desenvolver de forma relativamente equilibrada suas capacidades de liderança e infraestrutura, enquanto os processos diretamente relacionados à cadeia de valor apresentam maior dificuldade de implementação sistemática.

A Figura 8 complementa essa análise por meio de um gráfico radar que permite visualizar simultaneamente o perfil médio de cada classe de maturidade ao longo das principais dimensões do LESAT.

Figura 8 - Perfil por dimensão LESAT por classe de maturidade



Fonte: Elaborado pela autora (2026)

O gráfico evidencia uma separação consistente entre as três classes em praticamente todas as dimensões avaliadas. É possível observar que nenhuma classe se sobrepõe, reforçando como evidência a diferenciação entre a variável-alvo construída, indicando que o *score* composto captura as diferenças reais entre os perfis organizacionais analisados. Organizações classificadas como Avançado apresentam *scores* superiores a 0,80 em dimensões relacionadas a liderança (I.B), à criação do plano de transformação (I.F) e à sua implementação e coordenação (I.G). Enquanto organizações Iniciais permanecem abaixo de 0,40 nas mesmas dimensões. Esse padrão sugere que a capacidade de mobilizar liderança e de estruturar e executar um plano de transformação é o que mais distingue organizações em diferentes estágios de maturidade.


A dimensão I.D destaca-se por apresentar *scores* relativamente elevados mesmo nas organizações Em desenvolvimento, sugerindo que as concepções de uma visão futura tendem a ser desenvolvida antes de sua efetiva implementação nos processos organizacionais. Ou seja, as organizações definem seus objetivos estratégicos de forma relativamente precoce, mas encontram maior dificuldade em traduzi-los em prática consolidada, o que é evidenciado pelo *score* menor da dimensão I.G, de implementação, nas mesmas organizações.

Em contrapartida, as dimensões de infraestrutura habilitadora (III.A e III.B) apresentam *gaps* proporcionalmente menores entre as classes, indicando que a disponibilidade de sistemas, ferramentas e padrões comuns tende a estar presente mesmo em organizações menos maduras, sem que isso implique necessariamente em avanço da transformação enxuta como um todo. Esse resultado reforça que investimentos isolados em infraestrutura tendem a ter efeito limitado sobre a maturidade organizacional caso não sejam acompanhados do fortalecimento da liderança, planejamento e capacidade de implementação, sendo esses os elementos observados que mais concentram variação entre os níveis na amostra.

4.1.4. ADOÇÃO DAS FERRAMENTAS *LEAN*

A Figura 9 apresenta o nível médio de adoção das 12 ferramentas *lean* avaliadas no instrumento, ordenadas do maior para o menor nível de utilização.

Figura 9 - Nível médio de adoção das ferramentas



Fonte: Elaborado pela autora (2026)

Para fins de análise, adotou-se o valor 1,5 como referência correspondente ao ponto médio da escala ordinal de quatro categorias utilizada no instrumento. As ferramentas com maior nível médio de adoção foram Trabalho Padronizado, 1,977, *kaizen*, 1,884, Gestão Visual, 1,860 e 5S com 1,721, indicando nível de utilização entre moderado e em consolidação. Essas ferramentas caracterizam-se por sua natureza operacional e de implementação mais acessíveis, não exigindo investimentos significativos ou mudanças sistêmicas complexas para sua adoção. A alta adoção do Trabalho Padronizado e do 5S é consistente com a literatura, que aponta essas ferramentas como as primeiras a serem implementadas na jornada *lean*, por constituírem a base visual e operacional sobre a qual as demais práticas são construídas (Liker, 2021).

O segundo grupo reúne ferramentas com nível de adoção entre 1,0 e 1,5 como TPM com 1,465, *Poka-yoke*, 1,419, *kanban*, 1,372, VSM, 1,209, *andon*, 1,186 e JIT com 1,163. A presença do VSM nesse grupo é indicativa, pois sugere que parte das organizações investigadas ainda opera com uma perspectiva predominantemente local e funcional, sem a visão integrada do fluxo. O mesmo padrão se observa no JIT e *kanban*, ferramentas que demandam estabilidade e sincronização entre processos, condições essas características de um nível de maturidade organizacional mais avançado.

Por outro lado, as ferramentas com menor adoção foram *Heijunka*, 0,860 e SMED, 1,093, todas abaixo do ponto médio da escala de 0 a 3. Essas ferramentas são de nivelamento e flexibilidade de produção que demandam estabilidade prévia, com domínio de técnicas avançadas de setup e uma cultura organizacional consolidada, sendo tipicamente associadas a estágios avançados do *lean* (Liker, 2021; Womack; Jones, 2003).

O nível médio geral de adoção de ferramentas foi de 1,434, entre utilização pontual e moderada, o que indica que a maior parte das organizações investigadas já iniciaram sua jornada enxuta com as ferramentas mais acessíveis, mas ainda não atingiram a consolidação plena. Observa-se ainda que a amplitude de variação entre as organizações pesquisadas não acompanha necessariamente o nível médio de adoção. As ferramentas do grupo intermediário, *kanban*, JIT, *andon*, SMED e TPM, apresentam as maiores dispersões observadas, com intervalos que vão de níveis próximos da não utilização a consolidação plena.


É possível observar ainda uma convergência entre os resultados da Figura 9 e o perfil por dimensão apresentado na Figura 8, onde as ferramentas com menor adoção, *Heijunka* e SMED, estão diretamente associadas a capacidade de implementação e execução avançada de práticas *lean*, observada na dimensão I.G, implementar e coordenar o plano de transformação enxuta, entre as organizações menos maduras. Da mesma forma, a maior adoção do Trabalho

Padronizado e do 5S converge com os *scores* elevados na dimensão relacionada a liderança (I.B).

4.1.5. CORRELAÇÃO ENTRE DIMENSÕES

A Figura 10 apresenta o mapa de correlação de Pearson entre as 13 subseções do LESAT, calculado com base nos *scores* médios por dimensão para os 43 respondentes.

Figura 10 - Mapa de correlação entre subseções do LESAT



Fonte: Elaborado pela autora (2026)

Todas as correlações identificadas são positivas, com valores variando entre $r = 0,45$, II.C e I.D, e $r = 0,89$, I.F e I.E, com média geral de $r = 0,69$. Esse padrão indica que as subseções do LESAT variam de forma coerente e interdependente. As correlações mais elevadas concentram-se entre subseções do núcleo da Seção I, que abrange as etapas de implementação e sustentação da transformação enxuta.

O par I.F e I.E apresentou a correlação mais alta de toda a matriz, $r = 0,89$, seguidos dos pares I.H e I.G, I.H e I.E, I.G e I.F, I.H e I.F. Esses resultados sugerem que as organizações que estruturam seus sistemas de gestão, I.E, tendem a desenvolver simultaneamente o planejamento formal da transformação, I.F, a capacidade de implementação, I.G, e os mecanismos de sustentação das iniciativas, I.H. As correlações entre a Seção I e Seção III são relativamente elevadas, principalmente entre III.A e I.E com $r = 0,83$, III.B e I.H com $r = 0,81$ e III.A e I.H com $r = 0,80$. Esses valores indicam que a construção de uma infraestrutura de medição e padronização, Seção III, caminha junto com os desenvolvimentos das capacidades de estruturação organizacional e sustentação da transformação, Seção I.

Já as subseções da Seção II, processos de ciclo de vida, apresentam menores correlações com as demais dimensões, especialmente entre II.C e I.D, considerada a mais baixa de toda a matriz com $r = 0,45$, seguida pelo par entre II.E e I.D. Esse padrão sugere que as práticas relacionadas ao ciclo de vida e ao valor do cliente desenvolvem-se de forma parcialmente independente das dimensões de liderança estratégica e visão de futuro.


Do ponto de vista da modelagem preditiva, a presença generalizada de correlações elevadas entre as dimensões introduz o fenômeno conhecido como multicolinearidade, onde variáveis preditoras carregam informação redundante entre si (Hair et al., 2019). Quando duas dimensões são altamente correlacionadas, como I.E e I.F, elas tendem a transmitir informações semelhantes ao modelo, dificultando a identificação de qual delas é de fato a mais relevante para a predição. Em amostras pequenas, esse problema é amplificado, pois o modelo dispõe de poucos exemplos para distinguir contribuições individuais de variáveis muito semelhantes.

Dessa forma, a redução de dimensões por agregação de 29 itens Likert para 13 se faz necessária, com isso, essa operação elimina redundância interna de cada subseção, sem perda de informações. Além disso, a escolha de algoritmos baseados em árvore é robusta a fenômenos de redundância, uma vez que as divisões são realizadas de forma univariada e a geração de um vetor de seleção aleatória de variáveis a cada nó, no algoritmo *Random Forest*, contribui para descorrelacionar as árvores individuais do conjunto (Breiman, 2001).

4.1.6. ÍNDICE DE CONSISTÊNCIA

A Figura 11 apresenta a distribuição do índice de consistência calculado com base no desvio-padrão das respostas dentro de cada subseção do LESAT.

Figura 11 - Distribuição do índice de consistência entre respondentes



Fonte: Elaborado pela autora (2026)

O índice de consistência médio da amostra foi de 0,725, com valores individuais variando entre 0,385 e 0,968. Treze respondentes (30,2%) apresentaram índice abaixo do limiar crítico de 0,65, indicando padrão de respostas com maior dispersão interna dentro das dimensões avaliadas. Esse resultado é esperado em instrumentos de autoavaliação aplicados a respondentes com diferentes níveis de familiaridade com os conceitos avaliados, e reforça a importância de incluir o índice de consistência como variável preditora adicional no modelo.

As classes Inicial e Avançado apresentam comportamentos semelhantes, com medianas mais altas e maior amplitude, indicando grupos mais heterogêneos internamente. Em contrapartida, a classe Em desenvolvimento apresenta a menor consistência mediana. Esse padrão observado no *boxplot* indica que respondentes da classe Inicial tendem a ter percepções mais homogêneas porque avaliam uma realidade ainda pouco desenvolvida, respondentes da classe Avançado, por sua vez, demonstram maior consistência por possuírem domínio das práticas enxutas, favorecendo respostas mais coerentes e equilibradas. Já os respondentes da classe Em desenvolvimento por possuírem práticas parcialmente implementadas, podem gerar percepções heterogêneas e, por vezes, contraditórias sobre o estado real de cada dimensão avaliada.

4.2.CONSTRUÇÃO DO PIPELINE DE MACHINE LEARNING

Com base na análise exploratória, foram definidas as configurações do *pipeline* de aprendizado de máquina, composto pelas etapas de preparação das variáveis, definição dos modelos e configuração da validação.

4.2.1. CONFIGURAÇÃO DAS VARIÁVEIS DE ENTRADA

O conjunto final de variáveis preditoras é composto por 28 *features*, variáveis, organizadas em quatro grupos. O primeiro grupo é formado por 13 *features* de *score* médio por subseção LESAT, calculadas como a média normalizada das respostas Likert dos itens pertencentes a cada dimensão. O segundo é composto por 12 *features* de adoção de ferramentas *lean*, codificadas ordinalmente e normalizadas para o intervalo [0,1]. O terceiro é por 2 *features* de perfil do respondente, com seu nível de conhecimento sobre *lean* e posição hierárquica, ambas normalizadas. Por fim, o quarto é o índice de consistência entre respondentes de cada subseção, calculado conforme a Equação 1. Essa configuração equilibra as informações evitando a dimensionalidade que ocorreria com os 41 itens brutos do instrumento em uma amostra de 43 respondentes.

4.2.2. VARIÁVEL-ALVO

A variável-alvo é o nível de maturidade *lean*, definida em três classes ordinais: Inicial, Em desenvolvimento e Avançado. A distribuição relativamente equilibrada entre as classes, com a menor representando 20,9% da amostra, favorece a aplicação da validação cruzada estratificada e reduz o risco de viés do classificador em direção à classe majoritária.

4.2.3. ALGORITMOS SELECIONADOS

Foram selecionados dois algoritmos de classificação supervisionada para o treinamento e comparação: Árvore de Decisão e Floresta Aleatória. A escolha desses dois algoritmos justifica-se pela adequação a problemas de classificação multiclasse com amostras pequenas, interpretabilidade dos resultados e robustez à multicolinearidade entre *features*, característica identificada na análise exploratória.

4.2.4. ESTRATÉGIA DE VALIDAÇÃO

Dado o tamanho amostral de 43 respondentes, a divisão convencional de valores de treino e teste resultaria em conjuntos insuficientes para avaliação confiável. Por isso, foi adotada a validação cruzada estratificada com $k = 5$ dobras, *Stratified k-fold cross-validation*, como estratégia principal de avaliação. Nessa abordagem, a amostra é dividida em 5 partições de tamanho aproximadamente igual, mantendo a proporção das classes em cada partição. Em cada iteração, quatro partições são usadas para treinamento e uma para teste, rotacionando-se o conjunto de teste até que todos os exemplos tenham sido avaliados uma vez (James et al., 2021).

Com $k = 5$ e $N = 43$, cada dobra de teste contém aproximadamente 8 a 9 respondentes, e o conjunto de treinamento utiliza cerca de 34 exemplos por iteração. As métricas de

desempenho são calculadas para cada dobra e depois agregadas por média e desvio-padrão, fornecendo estimativas mais estáveis e confiáveis do que uma única divisão treino/teste. Como análise complementar, foi aplicado o LOOCV, que utiliza cada respondente individualmente como conjunto de teste, sendo especialmente indicado para amostras com $N < 50$ (Kohavi, 1995).

4.3.TREINAMENTO DOS MODELOS

O treinamento dos modelos foi realizado em Python, utilizando a biblioteca scikit-learn, com o dataset de 43 amostras e 28 features preditoras. Os parâmetros foram ajustados por meio de busca em grade com validação cruzada interna, garantindo que os parâmetros ótimos sejam determinados sem vazamento de informação do conjunto de teste.

Para a *Decision Tree*, os principais parâmetros ajustados foram a profundidade máxima da árvore, o critério de impureza utilizado nas divisões e o número mínimo de amostras por folha. Para o *Random Forest*, além dos parâmetros compartilhados com a árvore de decisão, foram ajustados o número de árvores no *ensemble*, o número máximo de *features* consideradas em cada divisão e o critério de balanceamento de classes.

5. RESULTADOS E DISCUSSÃO

5.1.DESEMPENHO COMPARATIVO DOS MODELOS

O desempenho dos dois modelos foi avaliado por meio de duas estratégias de validação complementares, sendo a validação cruzada estratificada, *k-fold cross-validation*, com $k = 5$ dobras e o LOOCV. A Tabela 1 apresenta as métricas obtidas em ambas as estratégias para DT e RF.

Tabela 1 - Comparação De Métricas De Desempenho

Métrica	<i>Decision Tree</i>	<i>Random Forest</i>	Diferença
Acurácia (validação cruzada)	0,769 $\pm$ 0,067	0,906 $\pm$ 0,092	+0,137
F1-macro	0,794 $\pm$ 0,059	0,902 $\pm$ 0,097	+0,108
Precisão macro	0,803 $\pm$ 0,070	0,911 $\pm$ 0,092	+0,108
Recall macro	0,800 $\pm$ 0,054	0,922 $\pm$ 0,073	+0,122
Acurácia (LOOCV)	0,674	0,907	+0,233
F1-macro (LOOCV)	0,713	0,905	+0,192

Fonte: Elaborado pela autora (2026)


Os resultados demonstram que em todas as métricas avaliadas a abordagem por floresta aleatória foi superior em relação à árvore de decisão, com todas acima de 0,900. Na validação cruzada $k = 5$, o RF alcançou acurácia média de 0,906 contra 0,769 da DT, diferença de 13,7

pontos percentuais. Enquanto no LOOCV, o RF atingiu acurácia de 0,907 e F1-macro de 0,905, enquanto a DT atingiu 0,674 e 0,713, respectivamente, com diferença de 23,3 pontos percentuais de acurácia.

A acurácia de 0,907 obtida pelo RF no LOOCV indica que o modelo captura padrões genuínos nos dados, uma vez que o LOOCV avalia cada respondente individualmente sem que suas informações contaminem o treinamento. Por outro lado, a diferença de desempenho entre os dois modelos reforça o argumento de que o RF, por combinar múltiplas árvores com seleção aleatória de *features*, consegue reduzir o erro de generalização e evitar o *overfitting*, mantendo baixa a correlação entre as árvores individuais (Breiman, 2001). Consequentemente, essa mecânica torna o modelo mais robusto, o que justifica sua melhor capacidade de generalização no cenário da pesquisa, caracterizado por amostras pequenas e dados correlacionados.

A Figura 12 apresenta a acurácia obtida em cada uma das cinco dobras de validação, permitindo avaliar a estabilidade dos modelos ao longo das partições. O *Random Forest* apresenta desempenho estável ao longo das cinco dobras, com variação máxima de aproximadamente 18 pontos percentuais entre a dobra de menor e maior acurácia.

Figura 12 - Acurácia por dobra na validação cruzada k=5



Fonte: Elaborado pela autora (2026)

5.2. ANÁLISE POR CLASSE DE MATURIDADE

A análise por classe permite identificar onde cada modelo acerta e erra, fornecendo uma melhor compreensão sobre a dificuldade de classificação de cada nível. A Tabela 2 apresenta as métricas por classe para o *Random Forest* no LOOCV e a Figura 13 exibe as matrizes de confusão de ambos os modelos.


Tabela 2 - Desempenho por classe de maturidade no modelo *Random Forest* LOOCV

Classe de maturidade	Precisão	Recall	F1-score	N
Nível 1 – Inicial	0,818	1,000	0,900	9

Nível 2 – Em desenvolvimento	0,875	0,875	0,875	16
Nível 3 – Avançado	1,000	0,889	0,941	18
Média macro	0,898	0,921	0,905	43

Fonte: Elaborado pela autora (2026)

Figura 13 - Matrizes de confusão (LOOCV)




Fonte: Elaborado pela autora (2026)

A matriz da árvore de decisão, à esquerda, evidencia a limitação sugerida pelas métricas, que embora classifique corretamente todos os 9 casos da classe Inicial, o modelo concentra a maior parte dos seus erros na fronteira entre Em desenvolvimento e Avançado. As duas últimas classes juntas respondem por 14 dos 43 casos mal classificados, 32,6% da amostra. Dos 16 respondentes reais da classe Em desenvolvimento, apenas 9 são classificados corretamente, com 6 sendo confundidos com Avançado e 1 com Inicial. Já dos 18 respondentes Avançado, 7 são classificados de maneira errada como Em desenvolvimento. Esse padrão indica que a DT não consegue capturar de forma consistente a fronteira entre os dois níveis mais elevados de maturidade, tratando-os como uma região de decisão pouco discriminada.

Já a matriz RF, à direita, reduz os erros do algoritmo anterior de 14 para 4 casos, mantendo a classificação correta de todos os 9 respondentes da classe Inicial. As inconsistências do RF concentram-se nas fronteiras adjacentes, sendo um padrão esperado, uma vez que essas classes compartilham a faixa de *score*. Os erros foram 2 respondentes Em desenvolvimento classificados como Inicial, e 2 Avançado classificados como Em desenvolvimento. Além disso, nenhum caso o RF confunde as classes Inicial e Avançado entre si, o que é um resultado importante, pois mesmo quando erra, o modelo erra por uma classe de distância, nunca por duas.

A Figura 14 compara o F1-score por classe entre os dois modelos, evidenciando onde cada um se destaca ou apresenta dificuldades. A *Decision Tree* demonstra desempenho notável na classe Inicial, mas apresenta dificuldade considerável nas classes Em desenvolvimento e Avançado. Esse padrão sugere que a DT aprendeu regras simples que separam bem os casos extremos, mas não é capaz de discriminar de forma confiável os níveis intermediário e avançado. O *Random Forest*, por sua vez, apresenta F1-score superior nas três classes, com valor expressivo na classe Avançado.

Figura 14 - F1-score por classe de maturidade (LOOCV)




Fonte: Elaborado pela autora (2026)

5.3. ANÁLISE DE IMPORTÂNCIA DAS VARIÁVEIS

A Figura 15 apresenta a importância relativa de todas as 28 variáveis preditoras no modelo RF, modelo com resultados superiores, de forma que é possível identificar quais dimensões do LESAT e quais ferramentas *lean* mais contribuem para a predição do nível de maturidade. Além disso, Quadro 13 detalha as 10 variáveis com maior importância relativa no modelo.

Figura 15 - Importância das variáveis: Dimensões LESAT, Ferramentas e de Contexto



Fonte: Elaborado pela autora (2026)

Quadro 13 - 10 variáveis mais importantes (RF)

<i>Ranking</i>	Variável	Grupo	Importância
1º	I.E – Desenvolver Estrutura e Comportamento Organizacional	Dimensão LESAT	0,136
2º	I.F – Criar Plano de Transformação	Dimensão LESAT	0,109
3º	I.G – Implementar e Coordenar Plano de Transformação	Dimensão LESAT	0,092
4º	I.H – Nutrir Transformação e Pensamento Empresarial	Dimensão LESAT	0,086
5º	I.A – Determinar o Imperativo Estratégico	Dimensão LESAT	0,060
6º	I.B – Engajar Liderança na Transformação	Dimensão LESAT	0,058
7º	Kaizen – Nível de adoção	Ferramenta <i>Lean</i>	0,047
8º	VSM – Nível de adoção	Ferramenta <i>Lean</i>	0,043
9º	III – Infraestrutura Habilitadora	Dimensão LESAT	0,041
10º	Trabalho Padronizado – Nível de adoção	Ferramenta <i>Lean</i>	0,035

Fonte: Elaborado pela autora (2026)

As seis variáveis mais importantes são todas dimensões da Seção I do LESAT, Transformação Empresarial e de Liderança, com destaque para I.E, I.F, I.G e I.H. Juntas essas quatro dimensões somam importância de aproximadamente 42% do poder preditivo total do modelo. Esse resultado é teoricamente consistente com os princípios do LESAT 2.0, segundo Nightingale e Srinivasan (2011) a maturidade *lean* é primordialmente determinada pela capacidade da organização de transformar sua estrutura, seus comportamentos e seus sistemas de gestão. Ao se considerar o conjunto completo dessas seis variáveis, a importância acumulada sobe para 54,1%, evidenciando que pouco mais de um quinto das variáveis concentra mais da metade da capacidade discriminativa do RF.

Um resultado significativo é a posição das ferramentas no *ranking*, sendo a primeira ferramenta a aparecer o *Kaizen* em 7º lugar, seguido pelo VSM em 8º e Trabalho Padronizado em 10º. Nota-se que o VSM, Mapeamento de Fluxo de Valor, ocupa posição superior a ferramentas operacionais de maior difusão como o 5S e *Kanban*, sugerindo que a capacidade de enxergar e analisar o fluxo de valor, mesmo que de baixa adoção, é um diferencial relevante

para distinguir organizações em diferentes estágios de maturidade. A presença do Kaizen em 7º lugar reforça que a cultura de melhoria contínua, quando efetivamente implementada, também contribui para a predição do nível de maturidade. No conjunto, as 12 variáveis de ferramentas somam 24,1% da importância total do modelo, uma contribuição relevante, porém fragmentada, reforçando que nenhuma ferramenta isolada substitui o peso das dimensões estruturais do LESAT na predição da maturidade.


O índice de consistência das respostas aparece na 21ª posição correspondendo a apenas 1,4% do poder preditivo total do modelo, não sendo uma variável determinante para a classificação, sendo sua principal contribuição a metodológica, na seção de pré-processamento, para qualificar a confiabilidade dos dados. Ainda assim, é a mais relevante das três variáveis de contexto do modelo. Já as variáveis de contexto, nível de conhecimento e posição hierárquica, dispostas nas últimas posições, indicam que o perfil do respondente individual tem influência mínima sobre a classificação do nível de maturidade da organização.

5.4. ESTRUTURA DOS MODELOS

A Figura 16 apresenta a estrutura completa da árvore de decisão treinada com profundidade máxima de 4 níveis, permitindo visualizar as regras de classificação aprendidas pelo modelo. A primeira divisão da árvore ocorre na variável I.E, Estrutura Organizacional, com limiar de 0,575, pois dentre todas as 28 variáveis disponíveis é a que mais reduz a impureza de Gini no nó da raiz, ou seja, a que melhor separa as 43 amostras em grupos mais homogêneos em relação à classe de maturidade. As amostras são divididas então em 10 com score baixo e 33 com score alto.

No ramo da esquerda, ocorre a segunda divisão com a dimensão III, Infraestrutura Habilitadora, limiar $III \leq 0,575$, para separar organizações Iniciais das demais. No ramo da direita, organizações com $I.E > 0,575$, a segunda divisão usa $I.H \leq 0,833$ para distinguir entre Em desenvolvimento e Avançado, com subdivisões subsequentes via I.G e T_Gestão visual.

Figura 16 - Estrutura da árvore de decisão



Fonte: Elaborado pela autora (2026)

A interpretação da estrutura revela uma hierarquia de decisão coerente com a teoria do LESAT 2.0. Primeiramente, a árvore avalia se a organização possui estrutura organizacional mínima alinhada ao *lean*, I.E. Depois verifica se essa estrutura é suportada por infraestrutura habilitadora, III, e finalmente, distingue os níveis mais avançados pela capacidade de nutrir e sustentar a transformação, I.H, e de implementar os planos de forma coordenada, I.G. A presença de T_Gestão visual como critério de divisão no nível mais profundo da árvore indica que, entre organizações de alta maturidade, a implementação de ferramentas de comunicação visual serve como diferenciador adicional.

Essa hierarquia proposta pelo modelo segue a mesma lógica teórica do LESAT e o fato de o modelo ter encontrado essa sequência a partir dos próprios dados, sem receber previamente essa orientação teórica, reforça a coerência entre os resultados obtidos e a base conceitual do instrumento.

Diferentemente da DT, cuja estrutura hierárquica de regras pode ser representada e visualizada de forma completa, Figura 16, o RF não possui uma estrutura única interpretável. Por ser um método ensemble, o RF combina 500 árvores de decisão distintas, cada uma treinada sobre uma amostra diferente e com subconjuntos aleatórios de features em cada nó de divisão. A predição final é determinada pela votação majoritária entre todas as árvores. Essa característica configura o *Random Forest* como um modelo de caixa-preta (black-box model): embora apresente desempenho preditivo superior, sua lógica de decisão interna não é diretamente acessível ao usuário (Molnar, 2019).

6. CONCLUSÃO

Diante do exposto, o estudo desenvolveu uma abordagem metodológica para a predição do nível de maturidade *lean* em organizações, integrando dados qualitativos estruturados com base no modelo LESAT 2.0 e técnicas de aprendizado de máquina supervisionado. A pesquisa justifica-se pelas limitações reconhecidas na literatura sobre os modelos tradicionais de avaliação da maturidade *lean*, caracterizados por elevada subjetividade nos critérios avaliativos, dependência de autoavaliação, dificuldades de escalabilidade e baixa reprodutibilidade dos diagnósticos (Bataglia et al., 2018; Jayanetti et al., 2023; Lameijer; De Mast; Does, 2017).

A redução de subjetividade e aumento da confiabilidade na previsão do nível de maturidade a partir de dados qualitativos se deu por meio de uma abordagem em três frentes complementares, sendo elas: a construção de um instrumento de coleta fundamentos nas dimensões do LESAT 2.0; o tratamento da subjetividade dos dados autodeclarados, incluindo

o Alfa de Cronbach; e a aplicação de algoritmos de aprendizado de máquina supervisionados capazes de identificar padrões preditivos nos dados coletados de 43 profissionais de organizações brasileiras.

Os resultados demonstram que a abordagem proposta é viável e eficaz. O modelo RF alcançou acurácia de 0,907 e F1-macro de 0,905 no LOOCV, com desempenho equilibrado nas três classes de maturidade. Essa estratégia de validação é especialmente rigorosa para amostras pequenas, na qual cada respondente é avaliado individualmente sem que suas informações contaminem o treinamento. O desempenho por classe foi equilibrado: Inicial, $F1 = 0,900$, Em desenvolvimento, $F1 = 0,875$ e Avançado, $F1 = 0,941$, com apenas 4 erros em 43 classificações. Esse modelo demonstra que padrões de maturidade podem ser identificados a partir de dados estruturados de percepção organizacional, mesmo com amostras de tamanho pequenas.

A árvore de decisão, por sua vez, alcançou acurácia de 0,674 e F1-macro de 0,713 no LOOCV, com desempenho notável na classe Inicial, $F1 = 0,947$, mas limitado nas demais classes com F1 abaixo de 0,63. Esse modelo demonstra que os padrões podem ser representados em estrutura de regras interpretáveis, pois segue uma hierarquia nas divisões conforme a literatura. A combinação dos dois modelos gera contribuições significativas, sendo um para precisão preditiva e o outro para a facilidade de compreensão das regras que levam à classificação.

Nesse sentido, cabe destacar neste estudo a convergência entre o que o algoritmo aprendeu dos dados e o que a teoria do LESAT 2.0 prescreve. O modelo DT identificou empiricamente, por meio do critério de redução de impureza de Gini, que as dimensões de estrutura organizacional (I.E), planejamento da transformação (I.F), implementação (I.G) e nutrição (I.H) são as que mais separam organizações com diferentes níveis de maturidade, conforme a sequência que o LESAT 2.0 descreve como o caminho da transformação enxuta onde as organizações estruturaram seus sistemas de gestão, planejam, implementam e sustentam. Essa convergência sugere ainda que o instrumento captura dimensões que de fato discriminam a maturidade organizacional e que os dados coletados são suficientemente consistentes para que o algoritmo identifique esses padrões de forma independente.

É importante ainda situar o aprendizado no perfil da amostra que o originou, visto que os 43 respondentes que compuseram a base de treinamento são majoritariamente de organizações do setor de manufatura, 34,9%, automotivo, 14%, e eletroeletrônico, 11%, e respondem, em sua maioria, por profissionais de nível operacional, 67,4%, seguidos por níveis tático, 18,6% e estratégico, 14%. Isso significa que o que o modelo aprendeu não representa uma verdade objetiva e universal sobre a maturidade enxuta das organizações, mas sim os

padrões extraídos da percepção autodeclarada de um perfil específico de respondente. A convergência identificada entre os achados do modelo e a teoria do LESAT 2.0, portanto, deve ser interpretada como evidência de que essa percepção operacional é internamente consistente com o referencial teórico.

As descobertas da pesquisa reforçam que a maturidade *lean* é determinada, antes de qualquer coisa, pela capacidade da organização de transformar sua estrutura, seus comportamentos e seus sistemas de gestão. Ferramentas como 5S, *Kanban* e Trabalho padronizado são importantes, mais insuficientes quando não estão sustentadas por um plano de transformação consistente. Nesse sentido, *Kaizen* e VSM, ferramentas com maior poder preditivo identificadas no modelo, reforçam que a capacidade de enxergar sistemicamente o fluxo de valor e de melhorá-lo continuamente distingue organizações maduras das demais.

6.1.PRINCIPAIS CONTRIBUIÇÕES E IMPACTOS

Uma das contribuições é do ponto de vista teórico com a proposição de uma estrutura metodológica replicável para a construção de modelos preditivos de maturidade *lean*, que integra um instrumento de coleta baseado no LESAT 2.0, estratégias de tratamento de subjetividade e técnicas de aprendizado de máquinas supervisionados. Já do ponto de vista prático, uma das contribuições é um diagnóstico de maturidade mais objetivo e reproduzível. O modelo pode substituir a avaliação puramente qualitativa por uma classificação baseada em padrões identificados em dados estruturados, tornando o diagnóstico mais confiável e comparável entre organizações e ao longo do tempo. Outra contribuição é a identificação de prioridades de investimento na jornada enxuta, por meio de análise de importância de variáveis que indicam quais devem ser priorizadas para avançar em maturidade. Além disso, há a questão da escalabilidade do instrumento, que pode ser aplicado de forma remota e simultânea a múltiplas organizações com processamento automatizado dos dados e geração imediata do diagnóstico de maturidade, sem necessidade de um facilitador especializado presencial.

6.1.1. IMPACTOS ACADÊMICOS

Do ponto de vista acadêmico, o estudo buscou preencher uma lacuna metodológica ao propor uma integração entre dados qualitativos e modelos computacionais, contribuindo para o aprofundamento das pesquisas sobre avaliação da maturidade *lean* e uso de inteligência artificial. Sendo combinado um instrumento de autoavaliação fundamentado no LESAT 2.0 com dois algoritmos de aprendizado de máquina supervisionado: *Decision Tree* e *Random Forest*. A pesquisa aproxima os campos da Engenharia de Produção e da Ciência de Dados,

demonstrando que técnicas de aprendizado de máquina podem ser utilizadas para problemas de diagnóstico organizacional.

6.1.2. IMPACTOS ECONÔMICOS

Do ponto de vista econômico, ao nível da organização, os impactos potenciais dessa pesquisa estão estritamente relacionados aos resultados dos modelos, uma vez que fornecem um diagnóstico confiável no nível de maturidade atual e indicam qual dimensão deve ser prioritariamente desenvolvida para avançar ao nível seguinte. Essa sistematização de prioridades permite que organizações direcionem investimentos em transformação enxuta de forma mais assertiva, evitando desperdícios de recursos em treinamentos de ferramentas operacionais, por exemplo, antes que a estrutura de gestão esteja preparada para sustentá-las. O ganho de ter o direcionamento mais assertivo de investimentos é o resultado diretamente sustentado pelos dados desta pesquisa, uma vez que decorre da análise de importância de variáveis obtida a partir das respostas dos profissionais das organizações participantes desta pesquisa.

Ao nível macroeconômico, uma ferramenta de diagnóstico escalável e de baixo custo pode ser utilizada por entidades e autarquias, vinculadas ao desenvolvimento, indústria, comércio e serviços, para mapear o nível de maturidade do conjunto de empresas de determinada região. Além disso, pode contribuir para o avanço da maturidade *lean* nas indústrias com aumento de produtividade, redução de desperdícios e o fortalecimento da competitividade industrial. Esse potencial de ganhos é uma expectativa teórica a partir dos resultados obtidos junto às organizações participantes desta pesquisa. A validação empírica desse potencial depende de pesquisas futuras com amostras mais amplas e indicadores de desempenho operacional.

6.1.3. IMPACTOS SOCIAIS

O impacto social desta pesquisa é de democratizar o acesso ao diagnóstico de maturidade *lean*. Os modelos tradicionais frequentemente dependem de consultores externos especializados, cujo custo pode ser proibitivo para pequenas e médias empresas. Um instrumento de autoavaliação automatizado, processado por algoritmos de aprendizado de máquina e disponibilizado em plataforma digital, reduziria significativamente esse custo, tornando o diagnóstico acessível a organizações de menor porte.

Em relação ao escopo laboral, a melhoria da maturidade tem impactos diretos sobre as condições de trabalho dos colaboradores. Organizações maduras tendem a apresentar processos mais estáveis, ambientes de trabalho mais organizados, menor índice de retrabalho e maior

envolvimento dos trabalhadores na melhoria contínua (Liker, 2021). Ao oferecer um diagnóstico mais preciso e acessível, este estudo contribui indiretamente nas condições de trabalho, beneficiando os profissionais das organizações, principalmente dos níveis operacionais, criando espaços de trabalho mais seguros e saudáveis, desenvolvimento da competência dos funcionários e estímulo da promoção da cultura organizacional. O fortalecimento da competitividade e a eventual geração de empregos nas organizações participantes são efeitos potenciais, condicionados à implementação das prioridades de transformação identificadas pelo diagnóstico e ao consequente avanço de maturidade no médio e longo prazo, relação essa que não foi diretamente mensurada nesta pesquisa.

6.2.LIMITAÇÕES DA PESQUISA

O presente estudo apresentou limitações que devem ser consideradas na interpretação dos resultados e no planejamento de pesquisas futuras. A principal limitação é o tamanho amostral de 43 respondentes, adequado para a natureza exploratória da pesquisa, se a abordagem é viável ou não, mas insuficiente para generalização dos resultados a populações mais amplas. Embora estratégias de mitigação tenham sido adotadas, como a redução das classes de cinco para três, agregações de variáveis por subseção LESAT e validação cruzada estratificada, a ampliação da amostra em fases subsequentes é condição necessária para consolidar o modelo e permitir análises mais refinadas.

A segunda limitação é a natureza autodeclarada dos dados, que embora o índice de consistência entre respondentes e o alfa de Cronbach por subseção tenham sido utilizados para identificar padrões de inconsistências, não é possível eliminar completamente os vieses inerentes a autoavaliação.

Uma terceira limitação refere-se à interpretação dos próprios indicadores utilizados para mitigar o viés das respostas. Índices como o alfa de Cronbach medem a consistência interna entre os itens de uma mesma subseção, mas um valor elevado não garante, por si só, que as respostas refletem adequadamente a realidade avaliada, podendo criar uma falsa sensação de segurança quanto à qualidade dos dados. Dessa forma, tais indicadores devem ser interpretados com cautela, como um sinal complementar de consistência das respostas, e não como uma validação definitiva de sua fidedignidade.

Por fim, os resultados obtidos não devem ser interpretados como um padrão único e universal a ser perseguido por todas as organizações. A relevância de cada dimensão do LESAT pode variar conforme a materialidade e os objetivos estratégicos de cada organização, de modo

que o diagnóstico gerado pelo modelo deve ser lido à luz do contexto específico de cada empresa, e não como uma meta obrigatória de maturidade máxima em todas as dimensões.

6.3.SUGESTÃO PARA TRABALHOS FUTUROS

Com base nos resultados obtidos e nas limitações identificadas, recomenda-se que estudos futuros ampliem a coleta de dados, contemplando amostras superiores a 100 respondentes. Sugere-se ainda a realização de aplicações direcionadas a uma única organização, de modo a possibilitar um diagnóstico mais aprofundado e absoluto. Recomenda-se também a realização de estudos longitudinais, acompanhando as mesmas organizações ao longo do tempo, a fim de avaliar se a evolução dos níveis de maturidade converge com os ganhos operacionais observados.

Além disso, estudos futuros podem desenvolver versões complementares dos modelos que incorporem indicadores objetivos de desempenho operacional extraídos de sistemas de *Manufacturing Execution System* (MES), tais como OEE, *lead time* e índices de qualidade. A inclusão dessas métricas permitiria validar os resultados do modelo em relação a indicadores independentes, fortalecendo a sua robustez e minimizando a subjetividade.

Por fim, recomenda-se o desenvolvimento de uma ferramenta digital interativa, em formato de aplicação web ou mobile capaz de automatizar a coleta de dados, o processamento das respostas e a geração do diagnóstico de maturidade *lean*. Essa solução tornaria a abordagem ainda mais acessível, reduzindo a necessidade de conhecimento técnico.

Sugere-se ainda, como trabalho futuro, a integração complementar dos dois algoritmos utilizados: a estrutura de regras extraída da árvore de decisão, mais interpretável e alinhada à lógica teórica do LESAT, poderia ser empregada como etapa de pré-processamento ou de análise exploratória prévia, orientando e refinando as variáveis de entrada utilizadas no treinamento do *random forest*. Essa combinação permitiria unir a clareza interpretativa da árvore de decisão à capacidade preditiva superior do modelo de floresta aleatória.

REFERÊNCIAS

- AGUS, Arawati; ITENG, Rosman. Lean Production And Business Performance: The Moderating Effect Of The Length Of Lean Adoption. **Journal of Economics, Business and Management**, v. 1, n. 4, p. 324–328, nov. 2013.
- AJOUDANIAN, Shohreh; ABOUTALEBI, Hamid Reza. A capability maturity model for smart city process-aware digital transformation. **Journal of Urban Management**, v. 14, n. 3, p. 877–895, 1 set. 2025.

AL-BARRAK, Masha'el A.; AL-RAZGAN, Muna. Predicting Students Final GPA Using Decision Trees: A Case Study. **International Journal of Information and Education Technology**, v. 6, n. 7, p. 528–533, 2016.

ALI, Oussama Ben *et al.* Using machine learning to evaluate Industry 4.0 maturity: a comprehensive analysis highlighting lean's impact on digital transformation. **Journal of Engineering and Technology for Industrial Applications**, v. 10, n. 50, p. 156–167, 12 dez. 2024.

ALPAYDIN, Ethem. **Introduction to Machine Learning**. 2. ed. [S.l.]: MIT Press, 2010.

AMATI, Mirjam *et al.* Reducing Changeover Time Between Surgeries Through Lean Thinking: An Action Research Project. **Frontiers in Medicine**, v. 9, 27 abr. 2022.

BATAGLIA, Karina *et al.* A maturidade do Sistema Lean: um estudo de caso em uma Pequena e Média Empresa (PME) do segmento de saúde. *In*: Maceió: Encontro Nacional de Engenharia de Produção - ABEPRO, 15 nov. 2018.

BEAULAC, Cédric; ROSENTHAL, Jeffrey S. **Predicting University Students' Academic Success and Major using Random Forests**. [S.l.: S.n.]. Disponível em: <<http://arxiv.org/abs/1802.03418>>. Acesso em: 30 jul. 2025.

BENTO, Graziela dos Santos; TONTINI, Gérson. Developing an instrument to measure lean manufacturing maturity and its relationship with operational performance. **Total Quality Management and Business Excellence**, v. 29, n. 9–10, p. 977–995, 29 jul. 2018.

BHASIN, Sanjay. **Lean management beyond manufacturing: A holistic approach**. [S.l.]: Springer International Publishing, 2015.

BLACK, John R. **Lean production: implementing a world-class system**. 1. ed. New York: Industrial Press, 2008.

BOTELHO, Joacy Machado; CRUZ, Vilma Aparecida Gimenes da. **Metodologia científica**. 1. ed. São Paulo: Pearson Education do Brasil, 2013.

BREIMAN, Leo. **Random Forests**. Berkeley: University of California, 2001.

CARALLI, Richard; KNIGHT, Mark; MONTGOMERY, Austin. **Maturity Models 101: A Primer for Applying Maturity Models to Smart Grid Security, Resilience, and Interoperability** Mark Knight, CGI Group and GridWise Architecture Council (GWAC) Member. [S.l.: S.n.]. Disponível em: <<https://insights.sei.cmu.edu/library/maturity-models->

101-a-primer-for-applying-maturity-models-to-smart-grid-security-resilience-and-interoperability>. Acesso em: 30 abr. 2025.

CHEMWENO, Peter *et al.* Asset maintenance maturity model: structured guide to maintenance process maturity. **Int. J. Strategic Engineering Asset Management**, v. 2, n. 2, p. 119–135, 2015.

CNI. **Competitividade Brasil 2021-2022**. BrasíliaCNI, , 2022. Disponível em: <https://static.portaldaindustria.com.br/media/filer_public/e7/40/e740259f-460c-44c1-b4bb-1c0c7ec0e34c/competitividadebrasil_2021-2022_v1.pdf>. Acesso em: 26 abr. 2025

CRESWELL, J. W. **Projeto de pesquisa : métodos qualitativo, quantitativo e misto**. 1. ed. Porto Alegre: Artmed, 2010.

CROSBY, Philip B. **Quality is Free: The Art of Making Quality Certain**. 1. ed. New York: Mentor Penguin Group, 1980.

DE MORAES, André Oliveira. **Desenvolvimento de um modelo de avaliação da maturidade lean nas organizações**. Mestrado—[S.l.]: Universidade do Minho, 2020.

DE OLIVEIRA, Marcelo Albuquerque. **Sistema de gestão da manutenção baseada no grau de maturidade da organização no âmbito da manutenção**. Doutorado—Minho: Universidade do Minho, 2017.

DE SOUZA, Helder Jose Celani; SALOMON, Valerio Antonio Pamplona; DA SILVA, Carlos Eduardo Sanches. Statistical Predictors of Project Management Maturity. **Stats**, v. 6, n. 3, p. 868–888, 1 set. 2023.

DENNIS, Pascal. **Lean Production Simplified: A Plain-Language Guide to the World's Most Powerful Production System**. 3. ed. Boca Raton: CRC Press, 2015.

FACELI, Katti *et al.* **Inteligência artificial - Uma Abordagem de Aprendizado de Máquina**. 3. ed. Rio de Janeiro: LTC, 2025.

FORSTER, Malcolm R. Predictive Accuracy as an Achievable Goal of Science. **Philosophy of Science**, v. 69, p. S124–S134, set. 2002.

GALHARDI, Antonio César; TABETA, Adriana Mieko. Modelos de maturidade em lean manufacturing: uma análise bibliográfica. **Brazilian Journal of Business**, v. 3, n. 1, p. 312–323, 27 jan. 2021.

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems**. 2. ed. [S.l.]: O'Reilly Media, Inc., 2019.

GIL, André do Nascimento Fernandes. **Modelos de Maturidade na Gestão da Informação: Estudo Comparativo**. Mestrado—Lisboa: Universidade Nova de Lisboa, jun. 2021.

GIL, Antonio Carlos. **Como Elaborar Projetos de Pesquisa**. 4. ed. São Paulo: Atlas, 2002.

HAIR, Joseph F. *et al.* **Multivariate Data Analysis**. 8. ed. [S.l.]: Cengage Learning, 2019.

IKEZIRI, Lucas Martins *et al.* A perspectiva da indústria 4.0 sobre a filosofia de gestão Lean Manufacturing. **Brazilian Journal of Development**, v. 6, n. 1, p. 1274–1289, 2020.

JAMES, Gareth *et al.* **An Introduction to Statistical Learning with Applications in R**. 2. ed. New York: Springer, 2021.

JAYANETTI, J. K. D. D. T. *et al.* Critical Analysis of Lean Construction Maturity Models: A Systematic Literature Review. **Buildings**, v. 13, n. 6, 1 jun. 2023.

JIANG, Xuefeng; LI, Min; CHENG, Lin. Application of Decision Tree and Machine Learning in New Energy Vehicle Maintenance Decision Making. **Applied Mathematics and Nonlinear Sciences**, v. 9, n. 1, 1 jan. 2024.

KOHAVI, Ron. **A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection**. Stanford: Stanford University, 1995.

LAMEIJER, Bart A.; DE MAST, Jeroen; DOES, Ronald J. M. M. Lean six sigma deployment and maturity models: A critical review. **Quality Management Journal**, v. 24, n. 4, p. 6–20, 2017.

LARMAN, Craig; VODDE, Bas. **Scaling Lean & Agile Development Thinking and Organizational Tools for Large-Scale Scrum**. 1. ed. Boston: Pearson Education, 2009.

LEDBETTER, Phil. **The Toyota Template: The Plan for Just-In-Time and Culture Change Beyond Lean Tools**. 1. ed. Boca Raton: CRC Press, 2018.

LIKER, Jeffrey K. **The Toyota Way: 14 management principles from the world's greatest manufacturer**. 2. ed. New York: McGraw-Hill, 2021.

MAASOUMAN, Mohammad Ali. **Development of Lean Maturity Model for Operational Level Planning**. Master—Montreal, Quebec: Concordia University, 2014.

MAIER, Anja M.; MOULTRIE, James; CLARKSON, P. John. Assessing organizational capabilities: Reviewing and guiding the development of maturity grids. **IEEE Transactions on Engineering Management**, v. 59, n. 1, p. 138–159, fev. 2012.

MANN, David. **Creating a lean culture : tools to sustain lean conversions**. 3. ed. New York: CRC Productivity Press, 2014.

MIGUEL, Paulo Augusto Cauchick *et al.* **Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações**. 2. ed. Rio de Janeiro: Elsevier: ABEPRO, 2012.

MOGOTSI, Keratilo; SARUCHERA, Fanny. The influence of lean thinking on philanthropic organisations' disaster response processes. **Journal of Humanitarian Logistics and Supply Chain Management**, v. 13, n. 1, p. 42–60, 9 fev. 2023.

MOLNAR, Christoph. **Interpretable Machine Learning A Guide for Making Black Box Models Explainable**. 1. ed. [S.l.]: Leanpub, 2019.

NESENSOHN, Claus. A Lean Construction Maturity Model for Organizations. **Proceedings IGLC**, p. 357–363, 2017.

NETO, Annibal Affonso *et al.* Análise da adoção de práticas lean em empresas brasileiras: um estudo exploratório. **Sistemas & Gestão**, v. 13, n. 2, p. 196–208, 3 jun. 2018.

NIGHTINGALE, Deborah J. *et al.* **LAI Enterprise Self-Assessment Tool LESAT**. United States of AmericaLean Advancement Initiative, , 2012a. Disponível em: <www.lean.mit.edu>

NIGHTINGALE, Deborah J. *et al.* **LAI Enterprise Self-Assessment Tool LESAT Facilitator's Guide**. United States of AmericaLean Advancement Initiative, , 2012b. Disponível em: <www.lean.mit.edu>

NIGHTINGALE, Deborah J.; MIZE, Joe H. Development of a Lean Enterprise Transformation Maturity Model. **Information Knowledge Systems Management**, v. 3, n. 1, p. 15–30, jan. 2002.

NIGHTINGALE, Deborah J.; SRINIVASAN, Jayakanth. **Beyond the Lean Revolution: Achieving Successful and Sustainable Enterprise Transformation**. 1. ed. New York: AMACOM, 2011.

NILSSON, Nils J. **Introduction to Machine Learning**. Stanford: Stanford University, 1998.

ORJI, Fidelia A.; VASSILEVA, Julita. Machine Learning Approach for Predicting Students Academic Performance and Study Strategies based on their Motivation. 2022.

- PEDUZZI, Peter *et al.* A Simulation Study of the Number of Events Per Variable in Logistic Regression Analysis. **J Clin Epidemiol**, v. 49, n. 12, p. 1373–1379, 1996.
- PELLINI, Francesca *et al.* Effects of Lean Thinking and Emerging Technologies on Breast Cancer Patients' Therapeutic Process During COVID-19 Pandemic: A Case-Control Matched Study. **Frontiers in Surgery**, v. 8, 11 mar. 2021.
- PIAIA, Maria Luiza. **Modelo de Avaliação da Maturidade da Implementação do Lean Manufacturing com Utilização de uma Abordagem Multicritério Linguística**. Mestrado—[S.l.]: Universidade Tecnológica Federal do Paraná, 2019.
- PROBST, Philipp; WRIGHT, Marvin N.; BOULESTEIX, Anne Laure. Hyperparameters and tuning strategies for random forest. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 9, n. 3, 1 maio 2019.
- PRODANOV, C.; FREITAS, E. C. **Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico**. 2. ed. Novo Hamburgo: Feevale, 2013.
- PROTZMAN, Charles; WHITON, Fred; PROTZMAN, Dan. **Implementing Lean: Twice the Output with Half the Input!** 1. ed. Boca Raton: Routledge Productivity Press, 2019.
- RICH, Nick *et al.* **Lean Evolution: Lessons from the Workplace**. New York: Cambridge University Press, 2006.
- ROTHER, Mike; SHOOK, John. **Aprendendo a enxergar: mapeando o fluxo de valor para agregar valor e eliminar o desperdício**. São Paulo: Lean Institute Brasil, 2012.
- RUSSELL, Stuart; NORVIG, Peter. **Artificial Intelligence: A Modern Approach**. 4. ed. Harlow: Pearson, 2022.
- SALMAN, Hasan Ahmed; KALAKECH, Ali; STEITI, Amani. Random Forest Algorithm Overview. **Babylonian Journal of Machine Learning**, v. 2024, p. 69–79, 15 dez. 2024.
- SEKHAR, Ravi; SOLKE, Nitin; SHAH, Pritesh. Lean Manufacturing Soft Sensors for Automotive Industries. **Applied System Innovation**, v. 6, n. 1, 1 fev. 2023.
- SHALEV-SHWARTZ, Shai; BEN-DAVID, Shai. **Understanding Machine Learning: From Theory to Algorithms**. 1. ed. New York: Cambridge University Press, 2014.
- SHINGO, Shigeo. **A Revolution in Manufacturing: The SMED System**. 1. ed. Tokyo: CRC Press, 1985.

SOARES, Gabriela Pereira *et al.* A fuzzy maturity-based method for lean supply chain management assessment. **International Journal of Lean Six Sigma**, v. 12, n. 5, p. 1017–1045, 21 out. 2021.

STEWART, John. **The Toyota Kaizen Continuum: A Practical Guide to Implementing Lean**. 1. ed. Boca Raton: CRC Press, 2011.

TANRIVERDI, Nur; SENCER, Asli. Creating a Digital Transformation Maturity Model (Dx Mm) as A Single Solution. *In*: Porto: MCIS 2024 Proceedings, 2024. Disponível em: <<https://aisel.aisnet.org/mcis2024>>

URIARTE, A. Goienetxea *et al.* Lean, Simulation and Optimization: A Maturity Model. *In*: Singapura: International Conference on Industrial Engineering and Engineering Management (IEEM), 2017.

VINODH, S. **Lean Manufacturing: Fundamentals, Tools, Approaches, and Industry 4.0 Integration**. 1. ed. Boca Raton: CRC Press, 2023.

WENDLER, Roy. The maturity of maturity model research: A systematic mapping study. **Information and Software Technology**, v. 54, n. 12, p. 1317–1339, jul. 2012.

WOMACK, James P.; JONES, Daniel T. **Lean Thinking: Banish Waste and Create Wealth in Your Corporation**. 2. ed. New York: Free Press, 2003.

WOMACK, James P.; JONES, Daniel T.; ROOS, Daniel. **The Machine That Changed The World: The Story Of Lean Production**. 1. ed. New York: Macmillan, 1990.

YADAV, Gunjan *et al.* Development of a lean manufacturing framework to enhance its adoption within manufacturing companies in developing economies. **Journal of Cleaner Production**, v. 245, 1 fev. 2020.

YEH, Shea Tinn; ARTHAUD-DAY, Marne; TURVEY-WELCH, Michelle. Propagation of lean thinking in academic libraries. **Journal of Academic Librarianship**, v. 47, n. 3, 1 maio 2021.