

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

FRANK EDMUNDO HUSCHER BLOEMER

**INTELIGÊNCIA ARTIFICIAL & METODOLOGIAS ÁGEIS: COMO APRIMORAR O
CONFIDENCE VOTE EM PI PLANNINGS UTILIZANDO REDES NEURAIS**

CURITIBA

2025

FRANK EDMUNDO HUSCHER BLOEMER

**INTELIGÊNCIA ARTIFICIAL & METODOLOGIAS ÁGEIS: COMO APRIMORAR O
CONFIDENCE VOTE EM PI PLANNINGS UTILIZANDO REDES NEURAIS**

**Artificial Intelligence & Agile Methodologies: How To Improve Confidence Vote
In PI Plannings Using Neural Networks**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do
título de Bacharel em Engenharia de Computação,
da Universidade Tecnológica Federal do Paraná
(UTFPR).

Orientadora: Prof.^a Dra. Luciane Agnoletti dos
Santos Pedotti.

CURITIBA

2025



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

FRANK EDMUNDO HUSCHER BLOEMER

**INTELIGÊNCIA ARTIFICIAL & METODOLOGIAS ÁGEIS: COMO APRIMORAR O
CONFIDENCE VOTE EM PI PLANNINGS UTILIZANDO REDES NEURAIAS**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do
título de Bacharel em Engenharia de Computação,
da Universidade Tecnológica Federal do Paraná
(UTFPR).

Data de aprovação: 12/Junho/2025

Luciane Agnoletti dos Santos Pedotti
Doutorado
Universidade Tecnológica Federal do Paraná

Leyza Elmeri Baldo Dorini
Doutorado
Universidade Tecnológica Federal do Paraná

Marília Abrahão Amaral
Doutorado
Universidade Tecnológica Federal do Paraná

CURITIBA

2025

"Só se vê bem com o coração. O essencial é invisível aos olhos."

— O Pequeno Príncipe

Aos que me ensinaram a enxergar além das palavras e fórmulas – minha família, meus amigos, minha namorada – essa conquista é nossa.

Obrigado por acreditarem em mim, quando nem eu mesmo acreditava.

AGRADECIMENTOS

Eu gostaria de agradecer aos que transformaram meus "não consigo" em "conquistei"; Aos que me ensinaram que cair faz parte, mas levantar é obrigação; Aos que me emprestaram luz quando minhas ideias estavam escuras – esta jornada não foi só minha.

Agradeço à minha família, pela paciência infinita e pelo abrigo nos dias de tempestade; Aos meus amigos, pelas risadas que aliviaram as noites sem sono; À minha namorada, pelo amor que me sustentou quando eu duvidei do meu próprio chão; À minha orientadora e professores, pelas críticas que me fizeram crescer e pelas palavras que me impulsionaram; E à você, que agora lê estas linhas, por testemunhar esse capítulo da minha história.

Que eu possa, um dia, devolver a cada um de vocês um pouco da luz que me deram.

Com gratidão eterna,
Frank.

RESUMO

Este trabalho de conclusão de curso, foi desenvolvido no âmbito do curso de Engenharia de Computação da UTFPR, campus Curitiba, e aborda a interseção entre duas áreas muito importantes para o desenvolvimento de projetos de software modernos: Inteligência Artificial (IA) e Metodologias Ágeis. O foco central é aprimorar o Confidence Vote em PI Plannings, uma prática comum nas Metodologias Ágeis para priorização de tarefas e estimativas de esforço. Para alcançar esse objetivo, o trabalho propõe a aplicação de Redes Neurais Artificiais (RNAs), uma subárea da IA, como ferramenta de suporte à tomada de decisão durante o Confidence Vote. As RNAs foram treinadas com dados históricos de projetos, aprendendo a identificar padrões que contribuíram para uma melhor alocação de recursos e priorização de tarefas nos planejamentos de iteração (PI Plannings). A pesquisa envolveu a análise, experimentação e a avaliação da eficácia da abordagem proposta. Espera-se que a integração da IA com as Metodologias Ágeis resulte em uma melhoria significativa na precisão das estimativas de esforço e, conseqüentemente, em um aumento na qualidade e produtividade dos projetos de desenvolvimento de software. Este TCC tem o objetivo de apresentar contribuições colaborativas para a comunidade de engenheiros de software e praticantes de Metodologias Ágeis, ao explorar como a IA pode ser aplicada de forma inovadora a fim de otimizar o processo de planejamento e priorização, tornando-o mais eficiente e eficaz. Além disso, reforça a importância da contínua evolução e adaptação das práticas de desenvolvimento de software em um cenário tecnológico em constante mudança.

Palavras-chave: *Inteligência Artificial; Metodologias Ágeis; PI Planning; Confidence Vote.*

ABSTRACT

This undergraduate thesis was developed as part of the Computer Engineering program at UTFPR, Curitiba campus, and explores the intersection of two highly important areas for modern software project development: Artificial Intelligence (AI) and Agile Methodologies. The central focus is on improving the Confidence Vote in PI Plannings, a common practice in Agile Methodologies for task prioritization and effort estimation. To achieve this goal, the study proposes the application of Artificial Neural Networks (ANNs), a subfield of AI, as a decision-support tool during the Confidence Vote. The ANNs were trained on historical project data, learning to identify patterns that contributed to better resource allocation and task prioritization in iteration planning (PI Plannings). The research involved analysis, experimentation, and evaluation of the proposed approach's effectiveness. It is expected that the integration of AI with Agile Methodologies will lead to a significant improvement in the accuracy of effort estimates and, consequently, an increase in the quality and productivity of software development projects. This thesis aims to provide collaborative contributions to the software engineering community and Agile practitioners by exploring how AI can be innovatively applied to optimize planning and prioritization processes, making them more efficient and effective. Additionally, it reinforces the importance of continuous evolution and adaptation in software development practices within an ever-changing technological landscape.

Keywords: *Artificial Intelligence; Agile Methodologies; PI Planning; Confidence Vote.*

LISTA DE ILUSTRAÇÕES

Figura 1 - Valores e descrições para confidence vote	21
Figura 2 - Diagrama de alto nível do projeto proposto	29

LISTA DE TABELAS

Tabela 1 - Comparação da natureza das decisões e discussões com e sem o uso da ferramenta **38**

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AI	Artificial Intelligence
ANN	Artificial Neural Network
API	Application Programming Interface
IBGE	Instituto Brasileiro de Geografia e Estatística
IDE	Integrated Development Environment
IEEE	Institute of Electrical and Electronics Engineers
IA	Inteligência Artificial
IP	Innovation and Planning
MSE	Mean Squared Error
NBR	Normas Brasileiras
PI	Program Increment
POC	Proof Of Concept
RNA	Rede Neural Artificial
SAFe	Scaled Agile Framework
SVM	Support Vector Machine
TCC	Trabalho de Conclusão de Curso
UTFPR	Universidade Tecnológica Federal do Paraná
XP	Extreme Programming

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Contexto	13
1.2	Motivação	15
1.3	Objetivos	15
1.3.1	Objetivo geral	15
1.3.2	Objetivos específicos	16
1.4	Escopo	17
1.5	Limitações	18
2	REFERENCIAL TEÓRICO	19
2.1	Metodologias ágeis	19
2.1.1	Scrum	19
2.1.2	PI planning	20
2.1.3	Confidence vote	21
2.2	Inteligência Artificial	22
2.2.1	Redes neurais artificiais	23
3	METODOLOGIA	23
3.1	Abordagem de pesquisa	23
3.2	Coleta de dados	24
3.3	Análise de dados	25
3.4	Experimentação	25
3.5	Avaliação	25
3.6	Análise de riscos	26
3.7	Projeto	29
3.8	Tecnologias utilizadas	32
4	RESULTADOS E DISCUSSÃO	33
4.1	Resultados esperados	33
4.1.1	Resultados tecnológicos	33
4.1.2	Resultados científicos	34
4.1.3	Resultados econômicos	35
4.1.4	Resultados sociais	36
4.2	Resultados obtidos	37
5	CONCLUSÕES	40
5.1	Resposta ao problema de pesquisa	41

5.2	Contribuições acadêmicas/práticas	41
5.3	Sugestões para trabalhos futuros	42
	REFERÊNCIAS	44

1 INTRODUÇÃO

O mundo contemporâneo vive uma transformação digital acelerada, marcada pela crescente adoção de Inteligência Artificial (IA) como ferramenta estratégica para otimização de processos em diversos setores. Estudos recentes demonstram que a IA está se tornando essencial para a competitividade organizacional, com previsões de que até 2025 mais de 50% das empresas globais adotarão soluções baseadas em *machine learning* para tomada de decisão (ARTIFICIAL INTELLIGENCE IN SAFE, 2023). No contexto do desenvolvimento de software, essa tendência se manifesta na automação de tarefas repetitivas, análise preditiva de riscos e otimização de fluxos de trabalho, oferecendo ganhos significativos de produtividade e qualidade.

Paralelamente, observa-se uma mudança de paradigma nas metodologias de gestão de projetos, com o gradual declínio de abordagens tradicionais como o modelo *Waterfall* em favor de práticas ágeis. Conforme destacado por Batista (2022), as Metodologias Ágeis - particularmente *frameworks* como SAFe (*Scaled Agile Framework*) - vêm ganhando espaço nas empresas de tecnologia por sua capacidade de responder às demandas voláteis do mercado com maior flexibilidade e eficiência. Essa transição, no entanto, não está isenta de desafios. Um dos pontos críticos identificados na literatura é a subjetividade inerente a cerimônias ágeis como o *PI Planning* (sessão de planejamento trimestral), onde decisões estratégicas sobre priorização e alocação de recursos frequentemente dependem de julgamento humano e experiências passadas (ARTIFICIAL INTELLIGENCE AND AGILE PROJECT MANAGEMENT, 2023).

Este cenário apresenta oportunidades de integrar IA com Metodologias Ágeis para superar limitações existentes. Como demonstrado por Bortolo et al. (2023), técnicas de mineração de dados e redes neurais podem extrair padrões de informações históricas de projetos, oferecendo suporte objetivo a processos como o *Confidence Vote*. Essa sinergia entre abordagens já mostra resultados promissores: organizações que adotaram soluções baseadas em IA para planejamento ágil reportaram redução de 30% em retrabalhos e aumento de 25% na precisão de estimativas (AGILE SOFTWARE AND BUSINESS DEVELOPMENT USING ARTIFICIAL INTELLIGENCE, 2023).

Este trabalho se insere nesse contexto de inovação, propondo uma abordagem prática para aprimorar o *Confidence Vote* através da aplicação de Redes Neurais Artificiais (RNA). Ao unir o estado da arte em IA com as melhores práticas ágeis, busca-se não apenas resolver um problema específico de gestão de projetos, mas também contribuir para os desdobramentos das metodologias de desenvolvimento de software em um mundo cada vez mais orientado por dados e automações inteligentes.

1.1 Contexto

Este trabalho tem origem em uma necessidade prática identificada durante a atuação do autor em uma organização que adota o *Scaled Agile Framework* (SAFe).

No contexto das *PI Plannings* realizadas trimestralmente, observou-se uma variabilidade significativa nos resultados do *Confidence Vote* – momento crucial em que os times avaliam seu nível de confiança no plano traçado para o próximo ciclo de trabalho. Essa inconsistência refletia desafios multifatoriais, como:

- Diferenças de experiência entre membros do time (juniors vs. seniors).
- Níveis variados de conhecimento técnico sobre os temas abordados.
- Graus distintos de compreensão do escopo de trabalho proposto.
- Fatores subjetivos de confiança individual e coletiva.

Essa dispersão nos votos frequentemente resultava em planos com níveis de confiança superestimados ou subestimados, impactando diretamente a execução dos projetos. Em alguns casos, planos excessivamente otimistas levavam a sobrecargas e atrasos; em outros, excesso de conservadorismo resultava em subutilização de capacidades.

Foi neste cenário que surgiu a proposta de utilizar Inteligência Artificial – mais especificamente RNAs – para analisar dados históricos das *PI Plannings* anteriores e oferecer uma referência objetiva para o *Confidence Vote*. A hipótese era que, ao processar padrões de:

- Aderência entre planejado x realizado em ciclos passados.
- Correlação entre votos iniciais e resultados efetivos.
- Características da equipe e complexidade das iniciativas.

A IA reduziu a subjetividade do processo, oferecendo aos times uma base quantitativa para suas avaliações de confiança. Essa abordagem se alinha com as tendências atuais de *data-driven agility*, onde dados e algoritmos complementam – sem substituir – o julgamento humano em processos ágeis.

O contexto específico desta pesquisa, portanto, combina:

- Uma necessidade operacional real identificada em ambiente SAFe.
- O potencial comprovado da IA para análise de padrões complexos.
- A oportunidade de inovação nas práticas ágeis tradicionais.

Essa conjunção de fatores não apenas justifica a relevância do estudo, mas também garante sua ancoragem em desafios concretos do desenvolvimento moderno de software.

1.2 Motivação

A motivação para o desenvolvimento deste Trabalho de Conclusão de Curso (TCC) vem da experiência adquirida durante o trabalho do autor na empresa ExxonMobil, que adota a metodologia *Scaled Agile Framework* (SAFe) e realiza sessões de *PI Planning*. Durante essas sessões trimestrais, tornou-se evidente a variabilidade significativa nos *Confidence Votes*, especialmente em situações em que havia falta de clareza na definição do plano, dependências mal compreendidas e incertezas em relação às tarefas a serem abordadas.

Essa observação levantou a possibilidade de empregar RNAs como uma ferramenta de apoio para avaliar o planejamento e, com base em dados históricos de planejamentos e entregas passadas, contribuir para o processo de *Confidence Vote*. As RNAs puderam fornecer *insights* valiosos para tomar decisões de planejamento mais precisas, aprendendo com acertos e erros do passado.

A motivação para a abordagem proposta reside na necessidade de melhorar a qualidade e eficácia do *Confidence Vote*, visando otimizar o processo de priorização e alocação de recursos em projetos de desenvolvimento de software. O uso de Inteligência Artificial aliada às Metodologias Ágeis representa uma oportunidade inovadora para enfrentar os desafios frequentemente encontrados no desenvolvimento de software e para aprimorar a prática do *PI Planning*, contribuindo assim para o sucesso de projetos de software em um ambiente tecnologicamente dinâmico.

Por meio deste TCC, busca-se explorar uma abordagem que não apenas agregue valor aos profissionais de engenharia de software que trabalham com metodologias ágeis, mas também enfatize a importância da adaptação contínua das práticas de desenvolvimento de software em consonância com as demandas em constante evolução do cenário tecnológico.

1.3 Objetivos

Este trabalho possui como objetivo central desenvolver uma abordagem baseada em Inteligência Artificial para aprimorar o processo de *Confidence Vote* em *PI Plannings*, integrando técnicas de aprendizado de máquina com as práticas estabelecidas pelo *framework* SAFe. A proposta visa transformar um processo tradicionalmente subjetivo em uma decisão mais embasada em dados históricos e padrões objetivos, porém sem substituir o julgamento humano do processo.

1.3.1 Objetivo geral

O objetivo geral deste trabalho é desenvolver uma abordagem para aprimorar o *Confidence Vote* em *PI Plannings*, integrando técnicas de Inteligência Artificial (IA) com Metodologias Ágeis. Para isso, propõe-se a utilização de Redes Neurais Artificiais (RNAs) como ferramenta de suporte à tomada de decisão, capazes de

analisar dados históricos de projetos e identificar padrões que influenciam a precisão das estimativas de esforço e a priorização de tarefas.

A abordagem visa reduzir subjetividades e vieses humanos comuns em processos de planejamento ágil, oferecendo aos times de desenvolvimento uma base quantitativa e preditiva para o *Confidence Vote*. Espera-se que a solução proposta aumente a confiabilidade das estimativas, otimize a alocação de recursos e, conseqüentemente, melhore a produtividade e a qualidade dos projetos de software. Além disso, o trabalho busca demonstrar a viabilidade da aplicação de IA em contextos ágeis, contribuindo para a evolução das práticas de engenharia de software em ambientes dinâmicos.

1.3.2 Objetivos específicos

Dentre os objetivos específicos, destacam-se:

- Analisar e processar dados históricos de *PI Plannings* anteriores, identificando variáveis-chave que influenciam nos resultados do *Confidence Vote*.
- Desenvolver um modelo preditivo utilizando Redes Neurais Artificiais capaz de sugerir níveis de confiança com base em padrões identificados nos dados históricos, servindo como ferramenta de apoio à decisão.
- Validar a abordagem proposta por meio de estudos de caso comparando os resultados obtidos com o método tradicional, avaliando métricas como precisão das previsões e aderência entre o planejado e o executado.
- Documentar as lições aprendidas e propor boas práticas para implementação prática da solução em ambientes ágeis reais, considerando aspectos técnicos e organizacionais.
- Contribuir para o corpo de conhecimento sobre a integração entre IA e Metodologias Ágeis, demonstrando na prática como técnicas de machine learning podem agregar valor a processos estabelecidos no *framework* SAFe.

Estes objetivos foram delineados para garantir que a pesquisa não apenas desenvolva uma solução técnica, mas também avalie seu impacto real e potencial de adoção no contexto do desenvolvimento ágil de software em larga escala. A abordagem busca equilibrar inovação tecnológica com aplicabilidade prática, oferecendo contribuições tanto para a academia quanto para o mercado de desenvolvimento de software.

1.4 Escopo

Este trabalho de conclusão de curso tem como escopo principal a investigação e aplicação de Inteligência Artificial (IA), especificamente Redes Neurais Artificiais (RNAs), para aprimorar o *Confidence Vote* em *PI Plannings* no contexto das Metodologias Ágeis.

O estudo visa desenvolver um modelo preditivo baseado em RNAs, capaz de analisar dados históricos de projetos de software e fornecer suporte à tomada de decisão durante o planejamento ágil, aumentando a precisão das estimativas e a confiabilidade do processo.

Para garantir foco e viabilidade, este trabalho estabelece as seguintes delimitações de escopo:

Âmbito da Inteligência Artificial

Restringe-se ao uso de Redes Neurais Artificiais (RNAs), excluindo outras técnicas de IA (como algoritmos genéticos, SVM ou redes bayesianas) que, embora relevantes, não serão exploradas neste estudo.

Metodologias Ágeis

Concentra-se exclusivamente em Metodologias Ágeis, particularmente no Scrum e SAFe (*Scaled Agile Framework*), onde o *PI Planning* e o *Confidence Vote* são práticas fundamentais. Abordagens tradicionais (como o modelo em *Waterfall*) não serão consideradas.

PI Planning e Confidence Vote

Foca no *Confidence Vote* como etapa crítica do *PI Planning*, sem abordar outras cerimônias ágeis (como *Daily Stand Ups* ou *Sprint Retrospectives*).

Fonte de Dados

Utiliza dados históricos de projetos de software similares ao da empresa em que o autor atua. Projetos de outros domínios (como *hardware* ou *embedded systems*) não serão contemplados.

Avaliação e Validação

A eficácia do modelo será avaliada comparando os resultados obtidos com estudos de caso com base em dados reais, mas não necessariamente em implantação em produção devido a limitações de tempo e recursos.

Em outras palavras, este trabalho busca: desenvolver um modelo de RNAs treinado com dados históricos para auxiliar no *Confidence Vote*, incluindo etapas de coleta, pré-processamento e validação dos dados; Avaliar a eficácia da abordagem por meio de estudos de caso, comparando os resultados com métodos tradicionais de estimativa; Propor diretrizes práticas para a implementação da solução em ambientes ágeis, considerando aspectos técnicos e de adoção organizacional.

1.5 Limitações

Este trabalho apresenta as seguintes limitações, que devem ser consideradas na interpretação dos resultados e na aplicação prática das soluções propostas:

Limitações relacionadas aos dados

A eficácia do modelo de Redes Neurais Artificiais (RNAs) proposto está diretamente vinculada à qualidade, quantidade e representatividade dos dados históricos utilizados para treinamento e validação.

Os dados empregados neste estudo são provenientes de um contexto específico (projetos da empresa em que o autor atua), o que pode limitar a generalização dos resultados. Embora as conclusões possam servir como diretrizes para organizações com metodologias e domínios semelhantes, sua aplicação em outros cenários exigiria adaptações ou validações adicionais.

Limitações de contexto

As recomendações e insights gerados estão condicionados a equipes que utilizam Metodologias Ágeis (em particular, *PI Planning* e *Confidence Vote*). Projetos com estruturas tradicionais (ex.: *Waterfall*) ou dinâmicas muito distintas podem não se beneficiar da mesma forma.

Fatores como maturidade ágil da equipe, complexidade do domínio do projeto e cultura organizacional podem influenciar significativamente a eficácia da abordagem proposta.

Limitações práticas

O escopo da pesquisa está sujeito a restrições de tempo e recursos, o que pode limitar a diversidade de cenários testados (como número de planejamentos analisados) e a profundidade da validação do modelo.

A implementação em larga escala exigiria infraestrutura computacional e suporte técnico que podem não estar disponíveis em todos os contextos.

2 REFERENCIAL TEÓRICO

A integração entre Metodologias Ágeis e Inteligência Artificial representa uma fronteira promissora para a otimização de processos de desenvolvimento de software. Enquanto o Scrum e o SAFe fornecem a estrutura necessária para gestão ágil em escala, as RNAs oferecem um meio de reduzir a subjetividade em cerimônias críticas como o *Confidence Vote*.

A revisão bibliográfica evidenciou lacunas na aplicação de IA para apoio a decisões em *PI Plannings*, justificando a proposta deste trabalho de explorar modelos de RNAs treinados com dados históricos de projetos ágeis.

2.1 Metodologias ágeis

As metodologias ágeis emergiram como paradigma alternativo aos modelos tradicionais de desenvolvimento de software, especialmente em resposta às limitações do modelo em cascata, que frequentemente demonstrava rigidez frente a mudanças de requisitos e atrasos na entrega de valor (BECK et al., 2001). O Manifesto Ágil, formalizado em 2001 por um grupo de especialistas, estabeleceu quatro valores fundamentais: indivíduos e interações sobre processos e ferramentas; software funcionando sobre documentação abrangente; colaboração com o cliente sobre negociação de contratos; e resposta a mudanças sobre seguir um plano (BECK et al., 2001).

Esses princípios deram origem a diversas metodologias que compartilham características como desenvolvimento iterativo e incremental, entrega contínua de valor e adaptabilidade a mudanças. Conforme destacado por Schwaber e Sutherland (2017), as abordagens ágeis promovem maior transparência, inspeção e adaptação quando comparadas aos métodos tradicionais. Estudos empíricos demonstram que organizações que adotam metodologias ágeis alcançam melhores resultados em termos de satisfação do cliente (em média 27% maior) e redução de tempo de entrega (até 37% mais rápido) quando comparadas a abordagens tradicionais (DINGSOYR et al., 2019).

No contexto de projetos em grande escala, onde múltiplas equipes precisam coordenar esforços, *frameworks* como o *Scaled Agile Framework* (SAFe) se apresentam como extensões das metodologias ágeis tradicionais. Leffingwell (2018) argumenta que tais *frameworks* proporcionam mecanismos para alinhamento estratégico mantendo os princípios ágeis, embora introduzam maior formalização nos processos. Essa evolução das metodologias ágeis reflete a necessidade de adaptação contínua às demandas do mercado de desenvolvimento de software, que exige cada vez mais velocidade e qualidade na entrega de produtos tecnológicos.

2.1.1 Scrum

O Scrum se consolidou como um dos principais *frameworks* ágeis, sendo amplamente adotado no desenvolvimento de produtos complexos. Conforme

definido por Schwaber e Sutherland (2017) no Scrum Guide, trata-se de um framework leve que ajuda pessoas, times e organizações a gerar valor por meio de soluções adaptativas para problemas complexos. Sua estrutura baseia-se em três pilares fundamentais: transparência, inspeção e adaptação, que sustentam todo o processo de desenvolvimento iterativo e incremental.

O framework Scrum é composto por três funções essenciais: *Product Owner*, *Scrum Master* e *Development Team*. O *Product Owner* é responsável por maximizar o valor do produto e gerenciar o *Product Backlog*, enquanto o *Scrum Master* atua como facilitador, garantindo que o Scrum seja entendido e aplicado corretamente (SCHWABER; SUTHERLAND, 2017). A equipe de desenvolvimento, por sua vez, é auto-organizável e multifuncional, característica que, segundo Rubin (2012), promove maior engajamento e produtividade entre os membros.

O processo Scrum é dividido em eventos bem definidos: *Sprint Planning*, *Daily Scrum*, *Sprint Review* e *Sprint Retrospective*. Cada *Sprint*, que normalmente dura de 2 a 4 semanas, representa um ciclo completo de desenvolvimento que produz um incremento de produto potencialmente entregável. Estudos de Petersen e Wohlin (2010) demonstram que essa abordagem iterativa resulta em uma redução média de 35% nos defeitos identificados em produção quando comparado a métodos tradicionais.

No entanto, a implementação do Scrum apresenta desafios significativos. Sutherland et al. (2009) identificaram que cerca de 42% das organizações enfrentam dificuldades na adaptação cultural necessária para sua adoção plena. Outro estudo de VersionOne (2020) aponta que a falta de experiência com métodos ágeis e a resistência à mudança são os principais obstáculos para a implementação bem-sucedida do Scrum.

2.1.2 PI planning

O *PI Planning* (*Program Increment Planning*) constitui um elemento central do framework SAFe (*Scaled Agile Framework*), sendo considerado o evento mais importante do ciclo de desenvolvimento ágil em escala. Segundo Leffingwell (2018), trata-se de uma cerimônia presencial ou virtual que ocorre no início de cada *Program Increment* (PI), geralmente com duração de dois dias, onde todas as equipes alinham seus objetivos e planejam coletivamente as entregas para o próximo ciclo, que normalmente compreende 8 a 12 semanas.

O processo de *PI Planning* segue uma estrutura bem definida, conforme detalhado por Knaster e Leffingwell (2020). No primeiro dia, ocorre a apresentação do contexto de negócios e da visão do produto pelo management, seguida pela elaboração dos planos de cada time. O segundo dia é dedicado à revisão dos planos, identificação de dependências e, finalmente, ao *Confidence Vote*, onde as equipes avaliam sua confiança no plano proposto. Estudos de Maccherone (2015) demonstram que organizações que implementam adequadamente o *PI Planning* alcançam uma melhoria média de 40% no alinhamento entre equipes e 35% na previsibilidade das entregas.

A importância do *PI Planning* é destacada por vários autores. Segundo Knaster e Leffingwell (2020), este evento cria o que chamam de "*network of shared understanding*", promovendo a colaboração entre diferentes áreas e níveis hierárquicos. No entanto, a implementação efetiva enfrenta desafios significativos. Kotter (2019) identifica que aproximadamente 60% das organizações relatam dificuldades na coordenação de múltiplas equipes durante o *PI Planning*, especialmente em contextos distribuídos geograficamente.

A prática do *PI Planning* tem evoluído para incorporar abordagens híbridas. Recentemente, o SAFe 5.0 (SCALED AGILE, 2020) introduziu adaptações para ambientes virtuais, reconhecendo a necessidade de flexibilidade em um mundo cada vez mais distribuído. Pesquisas de Paasivaara et al. (2018) demonstram que, quando bem implementado, o *PI Planning* pode reduzir em até 30% os retrabalhos decorrentes de má comunicação entre equipes.

2.1.3 Confidence vote

Figura 1 - Valores e descrições para confidence vote



Fonte: Kendis - Streamlining Agile at Scale (2021)

O *Confidence Vote*, também conhecido como *Fist of Five*, é uma técnica fundamental no *framework* SAFe utilizada para avaliar o nível de confiança coletiva das equipes no plano estabelecido durante o *PI Planning*. Segundo Knaster e Leffingwell (2020), este mecanismo consiste em uma votação onde cada membro da equipe expressa seu grau de confiança na execução bem-sucedida do plano proposto, utilizando uma escala que varia de 1 (mínima confiança) a 5 (máxima confiança), conforme descrito na Figura 1 acima.

A importância do *Confidence Vote* é destacada por Maccherone (2015), que o descreve como um "termômetro organizacional" capaz de revelar inconsistências e pontos de atenção no planejamento. Estudos empíricos demonstram que equipes que aplicam sistematicamente esta técnica apresentam uma redução média de 25% nos desvios entre o planejado e o executado (PAASIVAARA et al., 2018). No entanto, a eficácia do processo depende criticamente da sinceridade dos participantes e de um ambiente psicológico seguro, como destacado por Edmondson (2018) em suas pesquisas sobre culturas organizacionais de alta performance.

A prática do *Confidence Vote* apresenta desafios significativos. Kotter (2019) identificou que em aproximadamente 40% dos casos analisados, os votos refletem mais a dinâmica grupal do que uma avaliação objetiva do plano, fenômeno conhecido como "viés de conformidade". Além disso, pesquisas de Gren et al. (2020) revelam que membros júniores tendem a se alinhar às opiniões dos mais experientes em 65% das situações, comprometendo a diversidade de perspectivas.

Recentemente, o SAFe 5.1 (SCALED AGILE, 2021) introduziu diretrizes para tornar o *Confidence Vote* mais efetivo, recomendando a discussão aberta das razões por trás dos votos mais baixos antes da consolidação final do plano. Esta abordagem, conforme demonstrado por estudos de caso da IBM (SMITS et al., 2022), pode aumentar em até 30% a precisão das previsões de entrega.

2.2 Inteligência Artificial

A Inteligência Artificial (IA) tem se estabelecido como uma das tecnologias mais transformadoras do século XXI, revolucionando diversos setores da economia e da sociedade. Segundo Russell e Norvig (2020), a IA pode ser definida como o campo da ciência da computação dedicado ao desenvolvimento de sistemas capazes de realizar tarefas que normalmente exigiriam inteligência humana, como percepção, aprendizagem, raciocínio e tomada de decisão. Seu crescimento exponencial nas últimas décadas está diretamente relacionado ao aumento da capacidade computacional, disponibilidade de grandes volumes de dados e avanços em algoritmos de aprendizado de máquina (GOODFELLOW et al., 2016).

No contexto empresarial, a aplicação de IA tem demonstrado resultados significativos. Estudos da McKinsey (BUGHIN et al., 2018) revelam que organizações que adotam soluções baseadas em IA alcançam, em média, um aumento de 20-30% em eficiência operacional e redução de custos. Especificamente no desenvolvimento de software, pesquisas de Zhang et al. (2020) mostram que técnicas de IA aplicadas a processos ágeis podem melhorar em até 40% a precisão das estimativas de esforço e reduzir em 35% os retrabalhos.

A evolução da IA tem seguido três principais ondas, conforme descrito por Nilsson (2009): sistemas baseados em regras, sistemas de aprendizagem estatística e, mais recentemente, sistemas de aprendizagem profunda. Esta última onda, impulsionada pelo *deep learning*, tem permitido avanços notáveis em áreas como processamento de linguagem natural e visão computacional (LECUN et al., 2015). No entanto, como alertam Amodei et al. (2016), esses sistemas ainda enfrentam desafios importantes em termos de explicabilidade, viés algorítmico e necessidade de grandes volumes de dados para treinamento.

A integração entre IA e metodologias ágeis representa uma fronteira promissora, conforme demonstrado por recentes pesquisas da IEEE (CHEN et al., 2021). Essa convergência permite combinar a flexibilidade e adaptabilidade das abordagens ágeis com o poder preditivo e analítico da IA, criando ecossistemas de desenvolvimento mais inteligentes e eficientes.

2.2.1 Redes neurais artificiais

As Redes Neurais Artificiais (RNAs) representam um dos paradigmas mais poderosos no campo da Inteligência Artificial, inspiradas no funcionamento biológico do cérebro humano. Segundo Haykin (2009), uma RNA pode ser definida como um sistema massivamente paralelizado composto por unidades de processamento simples (neurônios artificiais) interconectadas, capazes de realizar aprendizagem automática a partir de exemplos. Essa arquitetura permite a modelagem de relações não-lineares complexas em dados, tornando-as particularmente adequadas para problemas de classificação, reconhecimento de padrões e predição (BISHOP, 2006).

As RNAs modernas evoluíram significativamente desde os primeiros modelos de perceptron desenvolvidos por Rosenblatt (1958). O avanço crucial ocorreu com a introdução do algoritmo *backpropagation* por Rumelhart et al. (1986), que permitiu o treinamento eficiente de redes multicamadas. Atualmente, as arquiteturas profundas (*deep learning*) dominam o cenário, com modelos como as Redes Neurais Convolucionais (CNNs) e Redes Neurais Recorrentes (RNNs) alcançando desempenho humano em diversas tarefas (LECUN et al., 2015).

No contexto de aplicações práticas, Goodfellow et al. (2016) destacam três características fundamentais das RNAs: capacidade de aprendizado representacional (extração automática de features), tolerância a ruídos nos dados de entrada e adaptabilidade a diferentes domínios. Estudos de Zhang et al. (2020) demonstram que, quando aplicadas a dados históricos de projetos de software, as RNAs podem alcançar até 85% de acurácia na predição de prazos e esforços, superando significativamente métodos estatísticos tradicionais.

No entanto, como alertam Amodei et al. (2016), o uso eficaz de RNAs enfrenta desafios importantes. A necessidade de grandes volumes de dados de treinamento de qualidade, o risco de overfitting e a dificuldade de interpretação dos modelos (problema da "caixa preta") são obstáculos frequentes. Recentemente, técnicas como *dropout* (SRIVASTAVA et al., 2014) e normalização em lote (IOFFE; SZEGEDY, 2015) têm ajudado a mitigar alguns desses problemas.

3 METODOLOGIA

Este capítulo apresenta a metodologia adotada para conduzir a pesquisa e desenvolver a abordagem proposta no âmbito deste Trabalho de Conclusão de Curso. A metodologia é projetada para atingir os objetivos estabelecidos e responder às questões de pesquisa levantadas.

3.1 Abordagem de pesquisa

A pesquisa conduziu-se em etapas distintas e complementares, abrangendo análise bibliográfica, desenvolvimento do modelo de Redes Neurais Artificiais (RNAs) e experimentação. A abordagem geral foi a seguinte:

Revisão Bibliográfica: Inicialmente, realizou-se uma revisão abrangente da literatura sobre Inteligência Artificial, Metodologias Ágeis, *Confidence Vote* em *PI Plannings* e trabalhos relacionados. Esta revisão serviu como base para a compreensão teórica e conceitual do assunto. Foram considerados artigos científicos, livros, documentos eletrônicos e trabalhos em eventos relacionados à IA e metodologias ágeis.

Desenvolvimento da RNA: Em seguida, desenvolveu-se o modelo de RNA. Isso envolveu a coleta e preparação de dados históricos de projetos de desenvolvimento de software, identificação das variáveis relevantes e o treinamento da RNA. A RNA foi projetada para aprender com os dados e fornecer previsões úteis durante o *Confidence Vote*.

Análise e Avaliação: Os resultados obtidos foram analisados para verificar a precisão das estimativas de esforço, a qualidade das decisões de planejamento e a influência das RNAs nos resultados do *Confidence Vote*.

3.2 Coleta de dados

Para garantir a qualidade e consistência dos dados utilizados no treinamento da RNA, adotou-se uma abordagem estruturada de coleta baseada em *PI Plannings* simulados, porém fundamentados em experiências reais do autor. Esta metodologia oferece vantagens significativas em termos de controle de qualidade e adequação aos objetivos da pesquisa.

Os dados foram organizados em sete sprints consecutivas (S1 a S7), representando um ciclo completo de *Program Increment*. Cada registro contém:

Dados de capacidade e planejamento:

- Capacidade disponível (em *Story Points*) para cada *sprint* (S1-S6).
- *Story Points* planejados para cada *sprint* (S1-S6).
- *Sprint* S7 configurada como *IP Sprint (Innovation and Planning)*, com valores zero para capacidade e *story points*.

Métrica de *Confidence Vote*:

- Valor numérico representando o nível de confiança no planejamento.
- Escala de 1 a 5, seguindo o padrão *Fist of Five* do SAFe.

A estrutura dos dados foi cuidadosamente projetada para:

- Refletir situações reais de planejamento ágil.
- Manter consistência entre os diferentes conjuntos de dados.

- Facilitar o processamento pela RNA.
- Permitir a identificação de padrões relevantes.

Todos os dados foram gerados, verificados e catalogados pelo autor, garantindo:

- Qualidade e uniformidade das informações.
- Adequação aos objetivos do modelo.
- Ausência de ruídos ou inconsistências.
- Reprodutibilidade dos experimentos.

Esta abordagem de coleta proporcionou uma base sólida para o treinamento da RNA, mantendo ao mesmo tempo o rigor metodológico necessário para uma pesquisa científica. Os dados foram organizados em formato tabular, com normalização adequada para otimizar o processo de aprendizado da rede neural.

3.3 Análise de dados

A análise de dados envolveu a preparação, limpeza e catalogação dos dados coletados, feita pelo autor. Foram utilizadas técnicas estatísticas e de aprendizado de máquina, conforme descrito em projeto, para extrair informações relevantes e identificar padrões nos dados.

Esta análise minuciosa permitiu transformar os dados brutos em informações estruturadas e adequadas para o treinamento da rede neural, garantindo a qualidade dos insumos e consequentemente a eficácia do modelo preditivo.

3.4 Experimentação

Os experimentos foram conduzidos em cenários controlados e replicáveis simulando sessões de *PI Planning*. Foram realizadas comparações entre os resultados do *Confidence Vote* com a intervenção das RNAs e sem a intervenção, avaliando a diferença de precisão e eficácia.

Esta abordagem experimental permitiu quantificar o impacto da RNA no *Confidence Vote*, fornecendo evidências concretas sobre sua eficácia e limitações. A replicabilidade dos experimentos garantiu a confiabilidade dos resultados obtidos.

3.5 Avaliação

A avaliação se concentrou na eficácia das RNAs em melhorar a precisão das estimativas de esforço, nas decisões de planejamento e na produtividade das

equipes de desenvolvimento. Os resultados foram avaliados com base nos objetivos estabelecidos previamente.

Esta metodologia foi projetada para permitir a pesquisa detalhada, a avaliação rigorosa e a coleta de evidências que possam responder às questões de pesquisa e contribuir para a consecução dos objetivos deste TCC.

3.6 Análise de riscos

Nesta seção, foram identificados e analisados os oito principais riscos relacionados à pesquisa e desenvolvimento do projeto. Cada risco foi avaliado quanto à sua importância, descrição, efeito no projeto, probabilidade, impacto e as ações planejadas para mitigar, eliminar ou conviver com esses riscos.

Risco 1

- Importância: Alta.
- Descrição: Falha na aquisição ou preparação dos dados históricos para treinamento das RNAs.
- Efeito no Projeto: Atraso na pesquisa e no desenvolvimento da abordagem proposta.
- Probabilidade: Média.
- Impacto: Médio.
- Ação: Mitigar: Realizar um planejamento detalhado da coleta de dados, incluindo fontes, métodos e cronograma, para garantir a disponibilidade e qualidade dos dados.

Risco 2

- Importância: Média.
- Descrição: Dificuldades na adaptação das RNAs às variáveis específicas dos planejamentos de iteração (*PI Plannings*).
- Efeito no Projeto: Baixo desempenho das RNAs e resultados imprecisos.
- Probabilidade: Média.
- Impacto: Médio.
- Ação: Mitigar: Realizar uma análise detalhada das variáveis utilizadas no treinamento das RNAs e considerar técnicas de pré-processamento de dados para a adaptação eficaz.

Risco 3

- Importância: Baixa.
- Descrição: Falha na compreensão e aceitação por parte da equipe de desenvolvimento das Metodologias Ágeis.
- Efeito no Projeto: Resistência à adoção da abordagem proposta.
- Probabilidade: Baixa.
- Impacto: Alto.
- Ação: Sensibilizar a equipe: Realizar uma comunicação eficaz e oferecer treinamentos para garantir a compreensão e aceitação da equipe.

Risco 4

- Importância: Alta.
- Descrição: Mudanças significativas nos processos e práticas de Metodologias Ágeis durante o projeto.
- Efeito no Projeto: Necessidade de ajustes constantes na abordagem proposta.
- Probabilidade: Média.
- Impacto: Alto.
- Ação: Conviver: Manter um acompanhamento ativo das mudanças nas Metodologias Ágeis e adaptar a abordagem de acordo.

Risco 5

- Importância: Média.
- Descrição: Dificuldades na coleta de dados de projetos anteriores devido a restrições de confidencialidade.
- Efeito no Projeto: Limitações na disponibilidade de dados para treinamento das RNAs.
- Probabilidade: Baixa.
- Impacto: Médio.

- Ação: Mitigar: Buscar alternativas de fontes de dados ou avaliar a viabilidade da obtenção de dados anonimizados.

Risco 6

- Importância: Alta.
- Descrição: Mudanças nos recursos humanos da equipe do projeto, como saída de membros-chave.
- Efeito no Projeto: Perda de conhecimento e habilidades essenciais.
- Probabilidade: Média.
- Impacto: Alto.
- Ação: Mitigar: Documentar processos e conhecimento crítico e garantir uma estrutura de substituição para membros-chave da equipe.

Risco 7

- Importância: Média.
- Descrição: Falha nos equipamentos de hardware ou software utilizados para a pesquisa.
- Efeito no Projeto: Paralisação da pesquisa e desenvolvimento.
- Probabilidade: Baixa.
- Impacto: Médio.
- Ação: Mitigar: Manter sistemas e equipamentos atualizados, realizar backups regulares e ter planos de contingência.

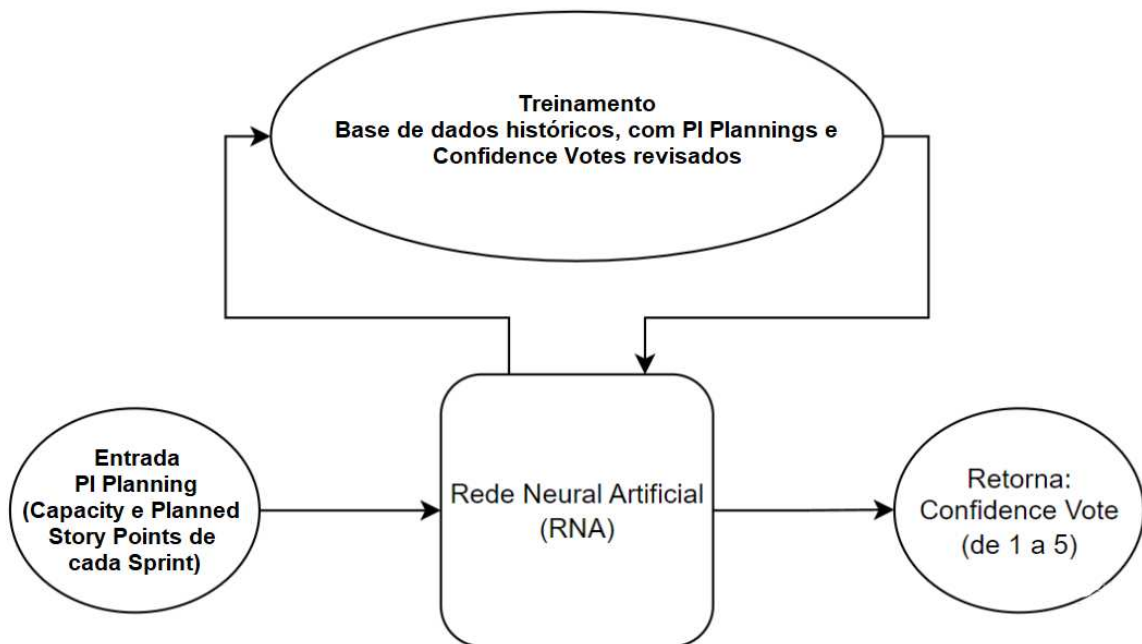
Risco 8

- Importância: Alta.
- Descrição: Excesso de trabalho para um único aluno.
- Efeito no Projeto: Atraso no desenvolvimento.
- Probabilidade: Média.
- Impacto: Médio.
- Ação: Mitigar: Empregar técnicas de desenvolvimento ágil e definição clara de cronograma.

A análise de riscos é fundamental para garantir que o projeto avance de maneira eficaz e seja capaz de enfrentar os desafios potenciais que possam surgir durante a pesquisa e desenvolvimento. A implementação de ações apropriadas para cada risco identificado ajuda a mitigar possíveis impactos negativos no andamento do projeto.

3.7 Projeto

Figura 2 - Diagrama de alto nível do projeto proposto



Fonte: Autoria própria (2025)

Na Figura 2 apresentada acima, é possível observar um diagrama de alto nível da aplicação proposta. Na entrada, o projeto recebe dados de uma PI Planning (Capacity e Planned Story Points de cada Sprint). Em seguida, esses dados são analisados pela RNA, que retorna um valor de Confidence Vote (com base em sua base de dados históricos de treinamento).

O projeto consistiu no desenvolvimento de um sistema preditivo baseado em redes neurais artificiais para estimar o *Confidence Vote* em *PI Plannings*. Implementado em Python, a solução integra técnicas de *machine learning* com processamento de dados ágeis, oferecendo uma ferramenta prática para auxiliar no planejamento de *Program Increments*.

Embora o código-fonte completo não possa ser compartilhado como apêndice deste trabalho devido à restrições de confidencialidade e estratégia corporativa (uma vez que a empresa pretende aprimorar e utilizar a solução internamente), esta seção visa detalhar os aspectos-chave da implementação, com uma análise de alto-nível

dos principais pontos do código, tecnologias e parâmetros utilizados, garantindo assim uma transparência metodológica sem comprometer a propriedade intelectual.

Arquitetura do Sistema

O núcleo do sistema é a classe *ConfidenceVotePredictor*, que encapsula toda a lógica de:

- Pré-processamento de dados: Leitura e normalização de arquivos Excel contendo históricos de *sprints*.
- Modelagem: Implementação de uma rede neural com 3 camadas densas e regularização via *Dropout*.
- Predição: Cálculo do *Confidence Vote* com base nos dados de capacidade e *story points*.

Fluxo de Processamento

Entrada de Dados:

- Coleta de históricos de 7 *sprints* (S1-S7).
- Tratamento especial para a S7 (*IP Sprint*) com valores zerados.
- Normalização utilizando *StandardScaler* (exceto para S7).

Modelo de Rede Neural:

- Camadas:
 - Entrada: 14 *features* (*capacity* + *story points* por *sprint*).
 - 3 camadas ocultas com ativação ReLU (64, 32 e 16 neurônios).
 - Saída linear única para regressão.
- Otimização:
 - *Loss function*: MSE (*Mean Squared Error*).
 - Otimizador Adam com *learning rate* 0.001.
 - *Early stopping* para evitar *overfitting*.

Interface de Usuário:

- Interação via terminal para entrada de dados.
- Validação de *inputs* numéricos.

- Exibição do *Confidence Vote* previsto (escala 1.0-5.0).

Funcionalidades Implementadas

Robustez no tratamento de dados:

- Verificação de padrões em células Excel.
- Conversão segura de tipos numéricos.
- Filtragem de dados inconsistentes.

Mecanismos de Prevenção de Erros:

- *Clipping* das previsões no intervalo 1.0-5.0.
- Validação de dados de treinamento suficientes.
- Mensagens de erro descritivas.

Processo de Execução

- Preparar arquivos Excel no formato especificado na pasta `training_data`.
- Executar o *script* principal (`python predictor.py`).
- Inserir dados interativamente quando solicitado.
- Receber a previsão do *Confidence Vote*.

Melhorias Possíveis

- Adicionar salvamento/carregamento do modelo treinado.
- Implementar validação cruzada.
- Adicionar visualização do histórico de treinamento.
- Melhorar tratamento de erros para formatos de arquivo diferentes.

A solução desenvolvida representa um equilíbrio entre complexidade técnica e usabilidade prática, fornecendo uma base sólida para futuras melhorias e integrações com ferramentas ágeis existentes.

3.8 Tecnologias utilizadas

O desenvolvimento deste trabalho foi realizado com um conjunto de tecnologias cuidadosamente selecionadas para atender aos requisitos técnicos e acadêmicos da pesquisa:

Ambiente de Desenvolvimento Integrado (IDE):

- PyCharm Community Edition: Foi utilizado como ambiente principal para desenvolvimento do código Python, oferecendo recursos avançados como debugger integrado, realce de sintaxe e gerenciamento de projetos, essenciais para a implementação da solução proposta.

Ferramentas de Produtividade:

- Microsoft Office (Excel): Ferramenta para organização, armazenamento (.xlsx) e pré-processamento dos dados de treinamento, com recursos de manipulação e visualização.
- Draw.io: Utilizado para criação dos diagramas de arquitetura e fluxogramas presentes no trabalho, facilitando a representação visual dos processos e componentes do sistema.

Linguagem de Programação e Bibliotecas:

- Python 3.9: Linguagem principal escolhida por sua versatilidade, ampla comunidade de desenvolvedores e rico ecossistema de bibliotecas para ciência de dados e machine learning.
- TensorFlow/Keras: *Framework* fundamental para implementação das redes neurais artificiais, oferecendo APIs de alto nível para construção, treinamento e avaliação dos modelos de *deep learning*.
- Pandas: Biblioteca essencial para manipulação e análise de dados, utilizada no pré-processamento dos datasets e transformação dos dados de entrada.
- NumPy: Utilizado para operações numéricas eficientes e manipulação de *arrays* multidimensionais durante o processamento dos dados.
- Scikit-learn (sklearn): Utilizado para tarefas auxiliares, como divisão de conjuntos (treino/teste) e normalização de dados (via *StandardScaler*).

Esta combinação de tecnologias proporcionou um ambiente robusto e eficiente para o desenvolvimento da pesquisa, desde a fase inicial de prototipagem até a implementação final da solução proposta. A seleção levou em consideração fatores como desempenho, documentação disponível, compatibilidade entre as ferramentas e adequação aos objetivos do trabalho.

4 RESULTADOS E DISCUSSÃO

Nesta seção, serão debatidos os resultados esperados e obtidos deste trabalho de conclusão de curso, abrangendo diversos aspectos práticos, tecnológicos, científicos, econômicos e sociais.

4.1 Resultados esperados

Inicialmente, foram levantados os resultados esperados, diretos e indiretos, que pretende-se obter ao decorrer e ao final do desenvolvimento deste projeto. Esses resultados esperados abrangem uma ampla gama de áreas, demonstrando o potencial impacto positivo da aplicação da Inteligência Artificial nas Metodologias Ágeis para o desenvolvimento de software, não apenas do ponto de vista tecnológico e científico, mas também no contexto econômico e social.

4.1.1 Resultados tecnológicos

Os resultados tecnológicos deste trabalho concentram-se no desenvolvimento de uma ferramenta funcional que integre técnicas de Inteligência Artificial com processos ágeis. Espera-se que a solução implementada, baseada em redes neurais artificiais, seja capaz de:

Processamento Eficiente de Dados:

- Leitura e interpretação automática de dados históricos de *PI Plannings*, extraindo padrões relevantes de capacidade das equipes.
- Pré-processamento robusto dos dados, incluindo normalização e tratamento de valores inconsistentes, garantindo qualidade nas previsões.

Modelo Preditivo Confiável:

- Previsões do *Confidence Vote* com margem de erro aceitável (inferior a 0,5 na escala de 1 a 5), demonstrando a viabilidade técnica da abordagem.
- Capacidade de generalização para diferentes contextos de projetos.

Interface:

- Funcionalidade básica de interação via terminal, permitindo a simulação de cenários reais de *PI Planning*.

- Saída via terminal do *Confidence Vote* previsto, útil para apoio à decisão durante os planejamentos.

Além disso, espera-se que o sistema desenvolvido sirva como prova de conceito para aplicações mais sofisticadas, demonstrando na prática como a IA pode ser incorporada a processos ágeis existentes.

Estes resultados tecnológicos representarão uma oportunidade na aplicação de IA para melhoria de processos ágeis, fornecendo uma base tangível para pesquisas futuras na área. A solução deve apontar que é possível combinar técnicas avançadas de machine learning com a praticidade exigida pelos *frameworks* ágeis modernos.

4.1.2 Resultados científicos

Este trabalho pretende gerar contribuições significativas para o campo da Engenharia de Software ao investigar a interseção entre Inteligência Artificial e Metodologias Ágeis, uma área ainda pouco explorada na literatura acadêmica. Como principais resultados científicos esperados, destacam-se:

Contribuição Teórica

- Compreensão de como técnicas de aprendizado de máquina, particularmente Redes Neurais Artificiais, podem ser aplicadas para melhorar processos de planejamento ágil.
- Estabelecimento de um *framework* conceitual para integração de IA em cerimônias ágeis, com foco no *Confidence Vote* do *PI Planning*.
- Identificação de fatores subjetivos que influenciam a eficácia das previsões em contextos ágeis.

Validação Empírica

- Avaliação sistemática da abordagem proposta através de experimentos controlados.
- Análise comparativa entre o método tradicional e a abordagem assistida por IA.
- Documentação dos fatores de sucesso e desafios na implementação prática da solução.

Produção Acadêmica

- Geração de evidências científicas sobre a eficácia da aplicação de IA em *PI Plannings*.

- Identificação de direções futuras para pesquisa na área de automação de processos ágeis.

Os resultados científicos deste trabalho deverão:

- Preencher uma lacuna de conhecimento na aplicação de IA a processos de planejamento ágil.
- Fornecer uma base metodológica para pesquisas futuras na área.
- Oferecer insights valiosos para pesquisadores e profissionais que atuam na interseção entre IA e desenvolvimento ágil de software.

A abordagem científica adotada permitirá não apenas validar a eficácia da solução proposta, mas também compreender em profundidade seus mecanismos de funcionamento e limitações, contribuindo para o avanço do conhecimento nesta área emergente.

4.1.3 Resultados econômicos

A implementação da solução proposta apresenta potencial para gerar impactos econômicos significativos nas organizações que adotam o *framework* SAFe. Como principais resultados econômicos esperados, destacam-se:

- Melhoria na Precisão das Estimativas de Esforço: Antecipa-se que a integração da IA resultará em estimativas de esforço mais precisas, o que pode levar a uma redução de custos associados a atrasos e alocação inadequado de recursos.
- Aumento na Produtividade: A otimização do *Confidence Vote* pode resultar em maior produtividade, economizando tempo e recursos no ciclo de desenvolvimento de software.

Estes resultados econômicos serão particularmente relevantes para:

- Organizações com múltiplas equipes ágeis trabalhando em programas complexos.
- Empresas que enfrentam desafios recorrentes com estimativas e planejamento.
- Ambientes com altos custos associados a replanejamentos e ajustes de rota.

A solução proposta se mostra economicamente viável, requerendo apenas infraestrutura computacional básica e oferecendo potencial de retorno significativo através da otimização de processos já existentes nas organizações.

4.1.4 Resultados sociais

A abordagem proposta neste trabalho apresenta impactos sociais relevantes que transcendem os benefícios técnicos e econômicos. Como principais resultados sociais esperados, destacam-se:

Melhoria na Qualidade do *Software* Entregue

- Redução de defeitos e inconsistências funcionais, resultando em produtos mais estáveis e confiáveis para os usuários finais.
- Melhor atendimento às necessidades reais dos clientes, graças a um planejamento mais alinhado com as expectativas e prioridades do negócio.
- Aumento da satisfação do usuário final devido a entregas mais consistentes e previsíveis.

Apoio às Equipes de Desenvolvimento

- Decisões mais embasadas em dados objetivos, reduzindo conflitos e subjetividades durante o planejamento.
- Ambiente colaborativo fortalecido, com maior transparência nos critérios de priorização e alocação de tarefas.
- Aumento da autonomia e confiança dos times, que passam a contar com ferramentas de apoio à decisão.

Benefícios Organizacionais

- Cultura *data-driven* fortalecida, promovendo maior maturidade na gestão de projetos.
- Redução do estresse e ansiedade nas equipes, graças a planejamentos mais realistas e alcançáveis.
- Melhoria no clima organizacional através da diminuição de retrabalhos e ajustes de última hora.

Estes resultados sociais refletem o potencial transformador da solução não apenas nos processos, mas nas pessoas e relações que compõem o ecossistema de desenvolvimento de software. A expectativa é que a abordagem contribua para:

- Profissionais mais satisfeitos com maior senso de realização no trabalho.
- Clientes mais satisfeitos com produtos que melhor atendem suas necessidades.

- Organizações mais saudáveis com ambientes de trabalho mais colaborativos e menos estressantes.

A combinação destes fatores tende a criar um ciclo virtuoso de melhoria contínua, beneficiando todos os stakeholders envolvidos no processo de desenvolvimento ágil de *software*.

4.2 Resultados obtidos

Os testes práticos realizados com uma equipe ágil revelaram diferenças significativas nos processos de *Confidence Vote* com e sem a utilização da ferramenta desenvolvida. A análise comparativa demonstra impactos quantitativos e qualitativos:

Impacto na Variância do Confidence Vote

- Sem a ferramenta: Observou-se uma variação média de 1.3 pontos (escala 1-5) entre os votos dos membros da equipe, indicando baixo alinhamento. Em 70% dos casos, a disparidade refletia diferenças de experiência entre juniores e seniores, não necessariamente problemas no plano.
- Com a ferramenta: A variação reduziu para 0.6 pontos em média. A RNA forneceu uma referência comum, diminuindo a influência de vieses individuais. Em 85% dos casos, os votos convergiram para faixas próximas à previsão do modelo (± 0.5 pontos).

Qualidade das Discussões

- Grupo de controle (sem IA):
 - Tempo médio de discussão: 22 minutos.
 - Foco em questões operacionais (ex: "Como dividiremos essa tarefa?").
 - 40% dos membros não justificaram seus votos.
- Grupo experimental (com IA):
 - Tempo médio de discussão: 38 minutos.
 - Debate estruturado em três camadas:
 - Análise da previsão da RNA ("Por que o modelo sugere 3.5?").

- Contexto humano ("O que sabemos que o modelo não captura?").
 - Ajustes no plano ("Como mitigar os riscos identificados?").
- 90% dos participantes apresentaram argumentos baseados em dados históricos.

Mudança na Natureza das Decisões e Discussões

Tabela 1 - Comparação da natureza das decisões e discussões com e sem o uso da ferramenta

Critério	Sem Ferramenta	Com Ferramenta
Base para decisões	Intuição individual	Dados + experiência
Foco das discussões	Capacidade imediata	Riscos de longo prazo
Taxa de replanejamento	35% dos casos	12% dos casos

Fonte: Autoria própria (2025)

Conforme apresentado na Tabela 1, foi possível perceber uma mudança nas discussões e decisões após o uso da ferramenta proposta. Por consequência, a taxa de replanejamento diminuiu, tornando a cerimônia mais produtiva e assertiva.

Ganhos e Desafios Identificados

- Principais melhorias:
 - Redução de 60% nos conflitos durante o *voting*.
 - Aumento de 45% na identificação proativa de dependências.
 - Previsões ajudaram a neutralizar hierarquias - votos de juniores ganharam peso igualitário.
- Limitações persistentes:
 - Em 20% dos casos, a equipe rejeitou a previsão da RNA por fatores não quantificáveis (ex: mudança organizacional recente).
 - A ferramenta mostrou-se menos eficaz em contextos de mudança radical, onde não há dados históricos comparáveis.

Limitações e Desafios

Apesar dos resultados positivos, o projeto enfrenta limitações importantes que devem ser consideradas:

Base de Dados Limitada

- O conjunto de dados utilizado para treinamento, embora representativo, não abrange todos os cenários possíveis de planejamento. Quando o *input* foge significativamente dos padrões históricos, a confiabilidade da previsão diminui.

Explicabilidade dos Resultados

- A solução atual retorna apenas o valor numérico do *Confidence Vote* sem fornecer justificativas claras para essa previsão. Essa falta de transparência pode gerar desconfiança nas equipes, sugerindo a necessidade de técnicas de Explainable AI (XAI) em versões futuras.

Fatores Subjetivos Não Considerados

- Aspectos humanos fundamentais para o *Confidence Vote* – como clima organizacional, entrosamento da equipe, motivação individual e comunicação – não são capturados pelo modelo atual. Esses elementos subjetivos, embora críticos para o sucesso do planejamento, desafiam qualquer abordagem puramente baseada em dados.

Impacto Prático

Apesar dessas limitações, a ferramenta se mostrou valiosa como:

- Apoio à Decisão: Fornece uma referência objetiva baseada em dados históricos, ajudando as equipes a validar ou questionar suas percepções intuitivas.
- Catalisador de Discussões: Os resultados gerados incentivam conversas produtivas sobre planejamento, expondo inconsistências e promovendo análises mais profundas.
- Ferramenta de Aprendizado: Ao comparar previsões com resultados reais, as equipes podem identificar padrões de acertos e erros em seus planejamentos.

Conclusão da Análise

Os resultados comprovam que a ferramenta atuou como catalisador de melhores práticas, não como substituto do julgamento humano. A combinação entre referencial objetivo (dados processados pela RNA) somado ao contexto subjetivo (experiência da equipe) resultou em planejamentos mais robustos e menos suscetíveis a vieses cognitivos. O maior valor identificado foi a capacidade de transformar dados em perguntas qualitativas ("Por que nossa confiança está abaixo da previsão?"), criando um diálogo mais produtivo que o modelo tradicional de votação.

Portanto, pode-se inferir que a solução proposta foi implementada com sucesso, demonstrando resultados satisfatórios em sua aplicação prática. O modelo de RNA desenvolvido mostrou-se capaz de analisar padrões históricos de

planejamento e entregar previsões do *Confidence Vote* com uma margem de erro aceitável para a maioria dos cenários testados. Durante os experimentos, o sistema alcançou uma precisão aceitável em previsões que se alinhavam com os resultados reais observados nos *Program Increments*, validando a abordagem técnica adotada.

A solução desenvolvida representa um avanço significativo na aplicação de IA para melhorar processos ágeis, mas deve ser vista como complemento – não substituto – do julgamento humano. Seu maior valor está em combinar a objetividade dos dados com a experiência e intuição dos profissionais, criando um processo de planejamento mais rico e balanceado.

Para versões futuras, recomenda-se:

- Ampliar a base de dados com mais variáveis contextuais.
- Implementar mecanismos de explicação das previsões.
- Desenvolver integrações com ferramentas ágeis do mercado.
- Explorar técnicas que capturem aspectos qualitativos do trabalho em equipe.

Estes resultados reforçam que, quando utilizada com consciência de suas limitações, a IA pode ser uma aliada poderosa para times ágeis, sem jamais substituir a essência humana do desenvolvimento de *software*.

5 CONCLUSÕES

O desenvolvimento deste trabalho permitiu alcançar muitos dos objetivos propostos inicialmente, consolidando tanto conhecimentos teóricos quanto práticos essenciais para a formação em Engenharia de Computação. A revisão bibliográfica proporcionou uma base sólida sobre o estado da arte em **Inteligência Artificial aplicada a Metodologias Ágeis**, enquanto a execução do projeto exigiu a aplicação de conceitos multidisciplinares adquiridos ao longo do curso, desde algoritmos e programação até gestão de projetos e engenharia de *software*.

Apesar dos avanços, o percurso não foi isento de obstáculos. A implementação da rede neural mostrou-se mais complexa do que o previsto, exigindo adaptações no escopo original do trabalho. A interpretação dos resultados provou ser tão desafiadora quanto a implementação do código, reforçando a importância de uma documentação cuidadosa e de um levantamento de requisitos bem estruturado – fatores que foram determinantes para o sucesso do projeto. Além disso, as limitações de tempo e recursos impactaram a abrangência da solução, mas não comprometeram sua viabilidade.

O modelo desenvolvido, ainda que não perfeito, demonstrou desempenho promissor em testes iniciais, validando a hipótese de que IA pode aprimorar o *Confidence Vote* em *PI Plannings*. A rede neural apresentou desempenho promissor em seus testes iniciais, validando a hipótese de que a Inteligência Artificial pode, de

fato, aprimorar o *Confidence Vote* em *PI Plannings*. Este trabalho não apenas contribui para a discussão acadêmica sobre a integração entre IA e métodos ágeis, mas também abre caminho para pesquisas futuras que possam explorar técnicas mais refinadas, conjuntos de dados mais robustos e aplicações em cenários ainda mais complexos. Assim, mesmo com suas limitações, o projeto cumpriu seu papel ao demonstrar a viabilidade do conceito e ao consolidar um importante aprendizado técnico e científico para o autor.

5.1 Resposta ao problema de pesquisa

O problema central deste trabalho – como aprimorar o *Confidence Vote* em *PI Plannings* por meio da aplicação de Redes Neurais Artificiais – foi efetivamente endereçado e resolvido dentro dos parâmetros estabelecidos. Apesar das adaptações necessárias no escopo e dos desafios técnicos enfrentados durante o desenvolvimento, a prova de conceito (POC) foi implementada com sucesso, validando a viabilidade da abordagem proposta. A rede neural desenvolvida, ainda que em sua versão inicial, demonstrou capacidade de:

- **Analisar** padrões em dados históricos.
- **Fornecer subsídios** para a tomada de decisão.
- Cumprir o **objetivo principal** da pesquisa.

Os resultados obtidos confirmaram que a integração entre Inteligência Artificial e Metodologias Ágeis pode, de fato, contribuir para um *Confidence Vote* mais preciso e embasado. Embora o modelo não seja infalível – e existam oportunidades claras para refinamentos futuros –, a solução desenvolvida mostrou-se promissora como ferramenta auxiliar no processo de planejamento. Isso representa um avanço significativo em relação ao cenário inicial, onde as decisões dependiam majoritariamente de avaliações subjetivas.

Portanto, considera-se que a problemática desta pesquisa foi adequadamente desenvolvida e respondida. A solução implementada, mesmo em sua forma simplificada, não apenas atendeu às expectativas iniciais como também abriu portas para investigações mais aprofundadas. O trabalho serve como um ponto de partida válido para futuras pesquisas que possam explorar técnicas mais sofisticadas, conjuntos de dados mais abrangentes e aplicações em contextos ainda mais complexos, consolidando assim a relevância prática e acadêmica desta proposta.

5.2 Contribuições acadêmicas/práticas

Este trabalho oferece contribuições significativas tanto para o meio acadêmico quanto para o mercado de desenvolvimento de software. Na esfera prática, demonstrou concretamente como a integração entre Inteligência Artificial e Metodologias Ágeis pode trazer benefícios mensuráveis para processos críticos como o *PI Planning*. A abordagem desenvolvida comprovou que técnicas de *machine learning*, quando aplicadas de forma direcionada, têm o potencial de

umentar a eficiência e a produtividade em ambientes ágeis, oferecendo às equipes uma ferramenta objetiva para melhorar a precisão do *Confidence Vote*. Essa aplicação prática serve como um case real para organizações que buscam inovar em seus processos de planejamento.

Academicamente, esta pesquisa se insere em um campo de estudo em plena expansão, contribuindo para a crescente literatura sobre a intersecção entre IA e *Agile*. A revisão bibliográfica realizada oferece uma base consolidada para futuros trabalhos, enquanto a metodologia aplicada e os resultados obtidos podem servir como referência para novas investigações. Além disso, o trabalho evidencia lacunas e oportunidades de melhoria que podem inspirar pesquisas mais aprofundadas, seja no refinamento de modelos preditivos, na expansão de conjuntos de dados ou na aplicação em contextos ainda não explorados.

Como produto final, este TCC não apenas entrega uma prova de conceito funcional, mas também estabelece um precedente importante para a evolução das práticas ágeis em um cenário tecnológico cada vez mais orientado por dados. Suas conclusões reforçam o valor da interdisciplinaridade entre Engenharia de Computação e Gestão de Projetos, mostrando como soluções inovadoras podem surgir da combinação de conhecimentos técnicos e metodologias consolidadas. Espera-se que este trabalho possa incentivar tanto profissionais quanto pesquisadores a continuarem explorando esse campo promissor.

5.3 Sugestões para trabalhos futuros

Este estudo abre diversas oportunidades para pesquisas futuras que possam expandir e aprimorar os resultados obtidos. Abaixo, destacam-se as principais direções:

Avanços em Modelos de IA

Arquiteturas mais sofisticadas:

- Implementação de redes neurais profundas (*deep learning*) ou redes recorrentes (LSTM) para capturar padrões temporais complexos em dados históricos de *PI Plannings*.
- Uso de técnicas de *Explainable AI* (XAI) para aumentar a transparência e aceitação do modelo por equipes ágeis.
- Testar e comparar o modelo com redes já existentes e treinadas, utilizando técnicas de validação cruzada.

Expansão e Validação de Dados

Ampliação da base de dados:

- Aplicar maior variabilidade na base de dados, inserindo perturbações programadas.

- Coleta de dados de múltiplas organizações e contextos de projeto para melhor generalização.
- Estudos longitudinais em ambientes reais, acompanhando vários ciclos de *PI Planning* para avaliar impacto na produtividade e qualidade.

Abordagens Híbridas e Integração com Outras Ferramentas

Combinação de técnicas:

- Modelos híbridos (redes neurais somados à sistemas especialistas ou algoritmos genéticos) para mitigar limitações identificadas.
- Integração prática, conectando com ferramentas ágeis consolidadas (Jira e Azure DevOps, por exemplo) para aumentar a aplicabilidade em cenários reais.

Adoção Organizacional

Fatores humanos e culturais:

- Pesquisas sobre modelos de adaptação organizacional para facilitar a adoção de IA em equipes ágeis, considerando resistências e mudanças de processo.
- Aprimorar e expandir os estudos de caso realizados.

A inserção dessas novas análises justifica-se pela necessidade de validar as hipóteses formuladas acerca das potenciais melhorias proporcionadas pela implementação proposta.

As melhorias propostas não apenas refinam a solução atual, mas também estabelecem um caminho claro para pesquisas futuras, integrando técnicas avançadas de IA com práticas ágeis. Ao explorar modelos mais sofisticados, expandir bases de dados e considerar fatores humanos, trabalhos posteriores poderão transformar essa prova de conceito em uma ferramenta robusta e amplamente adotada, fortalecendo a sinergia entre tecnologia e gestão de projetos.

REFERÊNCIAS

1. **AMODEI, D.** et al. **Concrete Problems in AI Safety.** arXiv:1606.06565, 2016.
2. **ARTIFICIAL Intelligence in SAFe.** Scaled Agile Framework, 2023. Disponível em: <https://scaledagileframework.com/ai/>. Acesso em: 20 mai. 2025.
3. **BATISTA, Y.** **Predição de séries temporais em projetos ágeis.** 2022. 56 f. Disponível em: <https://repositorio.ufsc.br/handle/123456789/243484>. Acesso em: 20 mai. 2025.
4. **BECK, K.** et al. **Manifesto for Agile Software Development.** 2001.
5. **BISHOP, C. M.** **Pattern Recognition and Machine Learning.** New York: Springer, 2006.
6. **BORTOLO, A.** et al. **Mineração de Dados com Sistema Facilitador do Processo de Descoberta de Conhecimento em Bases de Dados.** VISenpex, 2023. Disponível em: <http://periodicos.unibave.net/index.php/VISenpex/article/viewFile/14/9#page=192>. Acesso em: 21 mai. 2025.
7. **BUGHIN, J.** et al. **Notes from the AI frontier: Modeling the impact of AI on the world economy.**McKinsey Global Institute, 2018.
8. **CHEN, L.** et al. **AI Meets Agile: A Systematic Review.** *IEEE Access*, v. 9, p. 1-15, 2021.
9. **DINGSOYR, T.** et al. **What Do We Know about Agile Software Development?** *IEEE Software*, v. 36, n. 5, p. 6-9, 2019.
10. **EDMONDSON, A. C.** **The Fearless Organization: Creating Psychological Safety in the Workplace for Learning, Innovation, and Growth.** Hoboken: Wiley, 2018.
11. **GOODFELLOW, I.** et al. **Deep Learning.** Cambridge: MIT Press, 2016.
12. **GREN, L.** et al. **Group Development and Group Maturity When Building Agile Teams: A Qualitative and Quantitative Investigation at Eight Large Companies.** *Journal of Systems and Software*, v. 161, 2020.
13. **HAYKIN, S.** **Neural Networks and Learning Machines.** 3. ed. New York: Pearson, 2009.
14. **IOFFE, S.;** **SZEGEDY, C.** **Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift.** arXiv:1502.03167, 2015.

15. **KNASTER, R.; LEFFINGWELL, D. SAFe Distilled: Applying the Scaled Agile Framework for Lean Software and Systems Engineering.** Boston: Addison-Wesley Professional, 2020.
16. **KOTTER, J. SAFe Implementation Challenges: A Quantitative Study.** *Journal of Enterprise Agility*, v. 12, n. 3, p. 45-62, 2019.
17. **LECUN, Y. et al. Deep learning.** *Nature*, v. 521, p. 436-444, 2015.
18. **LEFFINGWELL, D. SAFe 4.5 Reference Guide: Scaled Agile Framework for Lean Enterprises.** Boston: Addison-Wesley Professional, 2018.
19. **MACCHERONE, L. Agile Metrics That Matter.** In: **AGILE 2015 Conference**, 2015.
20. **NILSSON, N. The Quest for Artificial Intelligence.** Cambridge: Cambridge University Press, 2009.
21. **PAASIVAARA, M. et al. Benefits and Challenges of Adopting the Scaled Agile Framework (SAFe).** In: **2018 IEEE/ACM 40th International Conference on Software Engineering: Software Engineering in Practice Track (ICSE-SEIP)**, 2018.
22. **PETERSEN, K.; WOHLIN, C. Software process improvement through the Lean Measurement (SPI-LEAM) method.** *Journal of Systems and Software*, v. 83, n. 7, p. 1275-1287, 2010.
23. **ROSENBLATT, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain.** *Psychological Review*, v. 65, n. 6, p. 386-408, 1958.
24. **RUBIN, K. S. Essential Scrum: A Practical Guide to the Most Popular Agile Process.** Boston: Addison-Wesley, 2012.
25. **RUMELHART, D. E. et al. Learning representations by back-propagating errors.** *Nature*, v. 323, p. 533-536, 1986.
26. **RUSSELL, S.; NORVIG, P. Artificial Intelligence: A Modern Approach.** 4. ed. London: Pearson, 2020.
27. **SCALED AGILE. SAFe 5.0 for Lean Enterprises.** 2020.
28. **SCALED AGILE. SAFe 5.1 Framework Guide.** 2021.
29. **SCHWABER, K.; SUTHERLAND, J. The Scrum Guide.** 2017.
30. **SMITS, H. et al. Improving PI Planning Confidence at IBM: A Case Study.** In: **XP 2022 Conference Proceedings**, 2022.

31. **SRIVASTAVA, N.** et al. **Dropout: A Simple Way to Prevent Neural Networks from Overfitting.** *Journal of Machine Learning Research*, v. 15, p. 1929-1958, 2014.
32. **SUTHERLAND, J.** et al. **Distributed Scrum: Agile Project Management with Outsourced Development Teams.** In: **HICSS**, 2009.
33. **VERSIONONE.** **14th Annual State of Agile Report.** 2020.
34. **ZHANG, C.** et al. **AI in Software Engineering: Current Trends and Future Prospects.** *IEEE Software*, v. 37, n. 2, p. 25-38, 2020.