

SMILE: A PROPOSED METHOD FOR MANAGING MACHINE LEARNING PROJECTS

SMILE: UMA PROPOSTA DE MÉTODO PARA GESTÃO DE PROJETOS DE APRENDIZADO DE MÁQUINA

Ana Lucia Figueiredo Facin ; <https://orcid.org/0000-0003-0379-4574>
UNESP

Mauricio Makoto Fukuda ; <https://orcid.org/0000-0001-6266-7036>
UNESP

Ricardo Ghantous Cervi ; <https://orcid.org/0000-0002-0674-0988>
UNESP

SMILE: A PROPOSED METHOD FOR MANAGING MACHINE LEARNING PROJECTS

ABSTRACT

The deepening of the discussion on specific project management methods for machine learning is relevant and justifiable due to the literature's scarcity of studies on this topic. The potential to respond to criticisms related to the adapted use of old methods, such as CRISP-DM, which was not originally developed for machine learning projects, also justifies new studies. This research aimed to create a project management method for machine learning projects called SMILE, an acronym for Structured Machine Learning Employment, which combines elements of traditional, agile, and hybrid project management methods. This method seeks to address the specific challenges of machine learning project management. Challenges and gaps in managing machine learning projects were identified through a literature review and interviews with project managers, analysts, and data scientists who develop machine learning products and services. The proposal of the SMILE was presented in this work in a procedural format, detailing each of its stages, including ideation, investment decision, data collection, development, and implementation, to facilitate the understanding of its application. The SMILE method was presented to experts who evaluated its applicability. The experts were the same ones interviewed in the research stage of surveying the specific challenges for machine learning projects.

Keywords: Machine learning. Agile methods. Project management. Agile-stage-gate. Artificial intelligence.

SMILE: UMA PROPOSTA DE MÉTODO PARA GESTÃO DE PROJETOS DE APRENDIZADO DE MÁQUINA

RESUMO

O aprofundamento da discussão sobre os métodos para gestão de projetos específicos para o aprendizado de máquina se mostra relevante e se justifica devido à escassez de estudos sobre esse tema na literatura e pelo potencial de resposta às críticas relativas à utilização adaptada de métodos antigos, como o CRISP-DM, que não foi originalmente desenvolvido para projetos de aprendizado de máquina. Esta pesquisa teve como objetivo desenvolver um método para gestão de projetos de aprendizado de máquina denominado SMILE, acrônimo de *Structured Machine Learning Employment*, que combina elementos de métodos tradicionais, ágeis e híbridos, para gestão de projetos. Esse método busca abordar os desafios específicos da gestão de projetos de aprendizado de máquina, identificados por meio de revisão da literatura e entrevistas com gestores de projetos, analistas e cientistas de dados que desenvolvem produtos e serviços utilizando o aprendizado de máquina. A proposta foi apresentada neste trabalho em formato de procedimento com o detalhamento de cada uma de suas etapas, incluindo a ideação, decisão de investimento, coleta de dados, desenvolvimento e implantação, de forma a facilitar o entendimento sobre sua aplicação. O método SMILE foi apresentado para especialistas que avaliaram a sua aplicabilidade.

Palavras-chave: aprendizado de máquina. Métodos ágeis. Gerenciamento de projetos. Inteligência artificial.

1 INTRODUÇÃO

A utilização do aprendizado de máquina para as mais diversas aplicações tem se intensificado visando alcançar benefícios tais como: diagnósticos precisos de doenças, (Pathak et al., 2020); redução de custos operacionais (Balakrishnan et al., 2020); identificação rápida das preferências e mudanças de comportamento dos clientes, no âmbito do marketing (Blomster & Koivumäki, 2022). Neste sentido, discussões recentes sugerem a necessidade de métodos mais adequados para gestão de projetos de aprendizado de máquina, para que tais projetos sejam mais bem geridos e alcancem os resultados esperados (Saltz & Krasteva, 2022; Martínez-Plumed et al., 2019; Ahmed, Dannhauser & Philip, 2018).

O aprendizado de máquina não é um assunto recente, e foi definido por Mitchell e Mitchell (1997) como o estudo de algoritmos computacionais que melhoram a performance ao longo do tempo por meio da experiência, sem serem programados explicitamente para a tarefa específica.

Esse assunto é relevante em função do recente aumento na utilização de soluções de aprendizado de máquina, provocado por uma maior acessibilidade às tecnologias que permitem um processamento de dados de forma rápida e com menor custo. Observa-se a partir dos dados apresentados no Google *Trends* (2022a) que houve um aumento expressivo na busca global do termo em inglês *machine learning*, com um crescimento da ordem de dez vezes entre 2010 e 2022. No meio acadêmico, também se verifica um aumento do interesse dos pesquisadores pelo tema aprendizado de máquina, observado por meio do aumento da frequência de publicações sobre o assunto.

Em termos da utilização do aprendizado de máquina, há um aumento considerável nas oportunidades de atuação e na popularidade dessas técnicas. Balakrishnan et al. (2020) apontam que 50% dos 2395 entrevistados em sua pesquisa reportaram que suas empresas adotaram o aprendizado de máquina em pelo menos uma função. De acordo com a mesma pesquisa, o aumento de receita em decorrência do uso de soluções de aprendizado de máquina é cada vez mais comum. O estudo citado apontou que 66% dos entrevistados reportaram um aumento de, pelo menos, 5% na receita do ano de 2019, impulsionado pela utilização de tecnologias de aprendizado de máquina.

No âmbito da transformação e estratégia das empresas, há uma expectativa de que o aprendizado de máquina transforme o modelo dos negócios no curto prazo. Segundo Davenport, Loucks e Schatsky (2017), 98% dos executivos entrevistados disseram ter expectativa de que as tecnologias cognitivas transformassem seus negócios em menos de dez anos, sendo que 94% esperavam que essa transformação ocorreria em até cinco anos. Existem muitos estudos que apresentam e discutem o uso de soluções de aprendizado de máquina, mas os que abordam a questão do gerenciamento de projetos para o desenvolvimento deste tipo de solução são escassos. No âmbito do desenvolvimento de softwares, é muito difundida a utilização dos chamados métodos ágeis, uma abordagem relativamente recente para gestão de projetos, que preza a flexibilidade e agilidade.

Neste sentido, Saltz e Krasteva (2022) identificaram em sua revisão sistemática da literatura que existe uma necessidade importante de combinar de forma eficiente métodos ágeis com os métodos utilizados atualmente para gestão de projetos de aprendizado de máquina, para alcançar uma abordagem que seja prescritiva, didática e adequada às particularidades desse tipo de projeto. Por outro lado, Blomster e Koivumäki (2022) avaliaram conceitualmente o método híbrido, combinação de métodos ágeis e clássicos, proposto por Cooper e Sommer (2016) e concluíram que é adequado para a gestão de projetos de aprendizado de máquina, pois apresenta vantagens importantes, tais como a possibilidade de uma liberdade de experimentação, que pode facilitar o entendimento das oportunidades e a construção de uma solução adequada às necessidades dos clientes. Saltz e Suthrland (2019)

e Shafique e Qaiser (2014) também compararam os métodos utilizados na gestão de projetos de aprendizado de máquina para levantar as particularidades de cada um. Por fim, as pesquisas de Brock e Von Wangenheim (2019) e Davenport, Loucks e Schatsky (2017) identificaram os principais desafios relacionados ao aprendizado de máquina, tanto do ponto de vista da gestão de projetos quanto do ponto de vista técnico de desenvolvimento.

Apesar do crescente interesse, ainda são poucos os estudos sobre métodos para gestão de projetos voltados para o aprendizado de máquina, o que fica evidenciado pela utilização alternativa de métodos de mineração de dados como o KDD, descrito por Piatetsky-Shapiro e Smyth (1996), e o CRISP-DM, descrito por Chapman et al. (2000), que não são específicos para o aprendizado de máquina (Saltz, 2015).

Os métodos disponíveis na literatura, como o CRISP-DM, SEMMA e KDD, segundo Saltz e Suthrland (2019), enfatizam as etapas de desenvolvimento do projeto; no entanto, são deficientes na definição de técnicas de gestão e dos papéis de cada integrante da equipe, enquanto os métodos mais generalistas, como o Scrum, definem como a coordenação da equipe deve ser feita, mas são deficientes em abordar as etapas específicas de projetos de aprendizado de máquina (Saltz & Hotz, 2020).

Além disso, de acordo com Saltz e Hotz (2020), o CRISP-DM é o método mais popularmente utilizado para projetos de aprendizado de máquina, e, no entanto, segundo Martínez-Plumed et al. (2019) e Ahmed, Dannhauser e Philip (2018), esse método foi criado há quase duas décadas para projetos de mineração de dados.

Nesse sentido pode ser interessante o estudo de um método novo, que possa se adequar às mudanças que ocorreram nas últimas décadas, considerando as particularidades dos projetos de aprendizado de máquina. Para cobrir essa lacuna, o objetivo deste estudo é propor um método para gestão de projetos de aprendizado de máquina, considerando suas particularidades, tendo como público-alvo gestores de projetos que desejam aprimorar sua gestão. Para atingir esse objetivo, esta pesquisa buscou responder às seguintes perguntas:

(P1) Qual é o contexto atual do aprendizado de máquina, suas oportunidades de pesquisa e benefícios?

(P2) Quais são os principais desafios para a gestão de projetos de aprendizado de máquina já pesquisados?

(P3) Quais são as principais técnicas de gestão existentes para projetos de aprendizado de máquina?

(P4) Existe algum desafio importante da gestão de projetos de aprendizado de máquina que não tenha sido abordado pela literatura?

(P5) Como gerir projetos de aprendizado de máquina de forma a abordar os principais desafios?

2 REVISÃO DA LITERATURA


Neste capítulo, foi realizada uma abordagem, em linhas gerais, dos métodos clássicos, ágeis e híbridos para gestão de projetos e dos métodos de desenvolvimento utilizados em projetos de aprendizado de máquina. Posteriormente, foi realizada uma análise comparativa de cada abordagem, identificando as principais lacunas existentes na literatura.

2.1 PRINCIPAIS DESAFIOS DO APRENDIZADO DE MÁQUINA

Nesta seção, foram explorados os desafios relacionados à implantação do aprendizado de máquina, abordados em pesquisas recentes. Davenport, Loucks e Schatsky (2017), por exemplo, realizou uma pesquisa com 250 indivíduos, identificando os principais desafios na implantação de tecnologias cognitivas. O autor define *tecnologia cognitiva* como inovações que executam atividades que tradicionalmente precisariam do raciocínio humano, como

planejar, prever ou aprender. Esse conceito abrange o aprendizado de máquina e demais tecnologias, tais como a robotização de processos, visão computacional e sistemas baseados em regras. Apesar de abranger mais tecnologias além do aprendizado de máquina, a pesquisa de Davenport, Loucks e Schatsky (2017) traz alguns *insights* importantes. O resultado de sua pesquisa pode ser observado na Figura 1.

Figura 1 – Desafios na implantação de tecnologias cognitivas



Fonte: Traduzida de Davenport, Loucks e Schatsky (2017)

Na Figura 1, é possível observar que o maior desafio na implantação de tecnologias cognitivas está relacionado à integração dessa nova tecnologia aos processos e sistemas já existentes, o que sugere um tópico direcionador de pesquisa: projetos de tecnologias cognitivas podem ser beneficiados com uma implantação gradual, uma das principais características dos métodos ágeis.

O uso de técnicas ágeis para a resolução dos desafios de projetos de aprendizado de máquina também é sugerido por Brock e Von Wangenheim (2019) na diretriz DIGITAL, acrônimo de: *Data, Intelligent, Grounded, Integral, Teaming, Agile e Leadership*. A Figura 2 ilustra o resultado de uma de suas pesquisas, com 3.557 entrevistados de 1.218 empresas diferentes, que avaliaram os principais desafios na implantação de projetos de inteligência artificial. Os mesmos autores definiram *Inteligência artificial* de maneira semelhante ao conceito de tecnologias cognitivas proposto por Davenport, Loucks e Schatsky (2017), isto é, como um termo que abrange diversas tecnologias capazes de executar tarefas que antes só eram possíveis de serem realizadas por humanos.

Observa-se que o resultado da pesquisa de Brock e Von Wangenheim (2019) diverge, em alguns aspectos, da pesquisa de Davenport, Loucks e Schatsky (2017), principalmente no ranking dos desafios. No entanto, pode-se observar que, apesar de as percentagens não terem uma correspondência, os principais fatores se mantêm os mesmos de forma consistente, como é o caso da falta de mão e obra qualificada, que aparece como principal desafio na obra de Brock e Von Wangenheim (2019), e como quarto principal desafio na pesquisa de Davenport, Loucks e Schatsky (2017), o que sugere uma oportunidade de trabalho em um método que aproveite melhor as especialidades de cada integrante e que possa absorver equipes compostas por poucas pessoas peritas em aprendizado de máquina. Também pode ser observada, em ambas as pesquisas, uma identificação importante relacionada aos custos da tecnologia, o que justifica a necessidade de se abordar de forma preditiva os benefícios do projeto, de modo a justificar os custos relativamente altos. Outro ponto de destaque nas duas pesquisas diz respeito ao conhecimento e apoio das lideranças dos projetos, reforçando a necessidade da sua conscientização acerca das particularidades dos projetos de aprendizado de máquina, corroborando a necessidade de um método que deixe claras tais particularidades.

Figura 2 – Desafios na implantação da inteligência artificial



Fonte: Traduzida de Brock e Von Wangenheim (2019).

2.2 MÉTODOS PARA GESTÃO DE PROJETOS

Nas seções a seguir foram exploradas algumas das técnicas de gestão de projetos, bem como suas particularidades e usos. No campo da gestão de projetos de softwares, os métodos ágeis estão ganhando cada vez mais popularidade, como é o exemplo do método Scrum. De acordo com o Google Trends (2022b), existe uma tendência de aumento considerável nas buscas pelas palavras-chave *Scrum* e *Agile*, sendo que a quantidade de buscas nos dois assuntos mais do que dobrou entre 2004 e 2020. Tanto o aumento na popularidade do assunto quanto os resultados positivos observados nas implantações justificam a necessidade de aprofundamento nos métodos, como uma oportunidade de gerar uma base para construir o método proposto nesta pesquisa. Ahmed et al. (2010) demonstraram que um total de 66,7% dos entrevistados relatou um aumento considerável na produtividade com a adoção de métodos ágeis.

2.2.1 Método Cascata

O método *Cascata* (também denominado *Stage-Gate* ou *Phase-Gate*) consiste na execução de conjuntos de atividades correlatas, cuja finalização é pré-requisito para o início do próximo conjunto de atividades. Um dos primeiros autores a abordar o assunto para o desenvolvimento de softwares foi Royce (1987), que descreveu em seu artigo os principais passos para a criação de projetos de software. Amplamente utilizado como referência em gestão de projetos no formato Cascata, o PMBOK (*Project Management Body of Knowledge*) descreve um conjunto de boas práticas, diretrizes e padrões para a gestão eficiente de projetos, descritos como um processo de gerenciamento de projetos (PMI, 2018).

Os processos de gerenciamento de projetos descritos pelo *Project Management Institute* - PMI (2018) são um conjunto de atividades de gerenciamento de projetos ordenados em uma configuração lógica de forma a produzirem saídas a partir de uma ou mais entradas. Tais saídas resultam em uma entrada para outro processo ou uma entrega do projeto ou fase do projeto. Esses processos podem ser categorizados de acordo com seus objetivos (grupo de processos) ou de acordo com o conhecimento utilizado (área de conhecimento).

2.2.2 Métodos ágeis

O desenvolvimento ágil de software foi popularizado no início dos anos 2000 com a publicação do Manifesto ágil, um conjunto de princípios que direcionou a gestão de projetos desde sua criação. De acordo com Beck et al. (2001), esse método se baseia em flexibilidade

no escopo do projeto e priorização de entregas de valor em um curto período ou *timebox*. Os princípios descritos no Manifesto, em conjunto com o conceito de desenvolvimento de produtos descrito por Takeuchi e Nonaka (1986), possibilitaram a criação do método *Scrum* para desenvolvimento de softwares.

Scrum

De acordo com Schwaber e Sutherland (2017), o Scrum é um método ágil que tem como pilares transparência, inspeção e adaptação, e, para tanto, utiliza como base três papéis, cinco eventos e três artefatos.

Schwaber e Sutherland (2017) estabelecem cinco eventos que compõem o *Scrum*; são eles: *daily*s, *reviews*, *retrospectives*, *plannings* e *sprints*. As *sprints* são períodos de até 30 dias que correspondem a um ciclo de entrega de valor. As *daily*s são reuniões diárias com o objetivo de reforçar a transparência das atividades e sincronizar o trabalho da equipe, e possuem um limite de duração, ou *timebox*, de 15 minutos. As *plannings* são reuniões que ocorrem uma vez a cada *sprint*, e têm como principal objetivo selecionar quais itens do *backlog* do produto serão entregues dentro da *sprint*. As *reviews* ocorrem uma vez a cada *sprint* e têm como principal objetivo apresentar os resultados da *sprint* para os *stakeholders* e alinhar o que será feito na próxima *sprint*. Por fim, as retrospectivas são reuniões de melhoria contínua, que visam avaliar os sucessos e postos de melhoria identificados durante a *sprint*, gerando novos itens de *backlog* ou planos de ação.

Ainda segundo Schwaber e Sutherland (2017), estão presentes três artefatos em um *time Scrum*: o *backlog* do produto, o *backlog* da *sprint* e um incremento. O *backlog* do produto corresponde a uma lista ordenada do que precisa ser implantado no produto, e deve ser a fonte única dos requisitos para qualquer mudança a ser feita. *Backlog* da *sprint* é um recorte do *backlog* do produto que contém a lista de atividades passíveis de serem entregues durante o período da *sprint*, e que compõem uma entrega de valor ou incremento. Por fim, um incremento é um conjunto de atividades que, desenvolvidas, correspondem a uma entrega de valor, coerente com os objetivos definidos do *time Scrum*.

Continuando com as ideias de Schwaber e Sutherland (2017), um *time Scrum* é composto por membros que desempenham os papéis de *Scrum Master*, *Product Owner* e *Team Member*. O *Scrum Master* se constitui no principal responsável pela garantia da prática ágil do projeto. É denominado *servo-líder* por desempenhar atividades de suporte, e é o maior responsável por orientar os demais participantes nas práticas e ferramentas ágeis, além de ser o facilitador dos eventos *Scrum*. O *Product Owner*, ou “dono do produto”, é responsável, principalmente, por gerenciar o *backlog* do produto, incluindo definir cada item do *backlog* e priorizá-los de modo a maximizar a entrega de valor do *time*. É o *Product Owner* que tem a palavra final da priorização e definição dos itens do *backlog*. A equipe de desenvolvimento, composta por *Team Members*, consiste em profissionais que realizam o trabalho de desenvolver e entregar produtos potencialmente utilizáveis. Essas equipes são autogerenciáveis e têm como objetivo principal, em cada *sprint*, desenvolver e entregar valor, em conformidade com os seus objetivos. Por fim, os membros de cada equipe se organizam em *squads*, que são times multidisciplinares que possuem todas as capacidades necessárias para conduzir o desenvolvimento de produtos de forma autônoma.

Objetivos e resultados-chave (OKRs)

Objectives and Key Results (OKRs) são uma ferramenta utilizada para direcionar as atividades de uma empresa em torno de um objetivo comum. De acordo com Mello (2018), o objetivo deve ser o resultado qualitativo final a que a empresa quer chegar, e os resultados-chave constituem uma forma de provar o quão próximo o objetivo está de ser atingido. Por isso, os resultados-chave devem ter um caráter quantitativo, devendo ser específicos, mensuráveis, atingíveis, relevantes e temporais.

Chotiganta (2021) reforça essa característica de transparência, em seu estudo comparativo entre o método OKR e o KPIs (*Key Performance Indicators*). Em sua pesquisa, ele afirma que um dos benefícios do uso do método OKR é a transparência e a abertura com os funcionários, que, por sua vez, fomentam um engajamento maior na organização.

2.2.3 Diferenças entre os métodos Ágil e Cascata

Comparativamente, existem características diferentes de cada método, o que faz com que a aplicabilidade de cada um dependa do cenário, cultura da empresa e natureza de cada projeto. No Quadro 1, apresenta uma comparação das características de cada método.

Quadro 1 – Comparação entre os métodos Cascata e Ágil

	Cascata	Ágil
Tipo	Macroplanejamento	Microplanejamento, gestão de projetos
Escopo	Da ideia até o lançamento	Desenvolvimento e teste, pode ser expandido para o pré-desenvolvimento
Organização	Equipe multifuncional (P&D, marketing, vendas, operações)	Equipe técnica (desenvolvedores de <i>software</i> , engenheiros)
Modelo de decisão	Método de investimento: a decisão de aprovar ou não o projeto envolve um grupo sênior de governança.	Método tático: decisões sobre as ações da próxima <i>sprint</i> são tomadas majoritariamente por um time autogerenciável

Fonte: Traduzida de Cooper (2016).

Por meio da análise do Quadro 1, pode-se concluir que projetos ágeis possuem de fato uma característica mais dinâmica. Conforme a complexidade de um projeto aumenta, sua previsibilidade diminui, gerando uma necessidade de flexibilização de escopo para que o projeto possa se adaptar corretamente às necessidades do cliente, bem como às mudanças de cenário e incertezas, tornando projetos ágeis mais adequados para casos de maior complexidade. Portanto, projetos ágeis se caracterizam por possuírem prazos e orçamento fixos, controlados pelos ciclos de cada *sprint*, ao passo que o escopo possui mais flexibilidade, podendo ser alterado a cada ciclo do projeto. Ainda se observa que projetos geridos da forma tradicional (Cascata) são preditivos, ou seja, eles buscam prever o orçamento e o prazo do projeto na partida, e cada desvio gera uma necessidade de mudança do planejamento. Por outro lado, os projetos ágeis são iterativos, ou seja, o planejamento é feito a cada iteração em um período curto e sem a necessidade de uma previsão de longo prazo para os custos e prazos.

2.2.4 Métodos híbridos

Métodos híbridos são aqueles que incorporam as técnicas dos métodos ágeis, tais como equipes multifuncionais, *sprints* curtas, cerimônias e artefatos, entre *gates*, que são estruturas dos métodos clássicos, como ilustrado por Cooper e Sommer (2018).

Eljayar e Busch (2021) conduziram uma pesquisa com 52 indivíduos com experiência em métodos híbridos, que demonstrou benefícios importantes na utilização dessa abordagem para projetos de desenvolvimento de software. Dentre esses benefícios, destacam-se: aumento na velocidade de entrega do projeto (*time-to-market*), aumento da efetividade da comunicação entre equipe e gestores, e dentro da própria equipe, facilitação da coordenação do projeto e aumento da motivação dos integrantes das equipes.

2.2.5 Métodos de desenvolvimento utilizados em projetos de aprendizado de máquina

No ambiente de desenvolvimento de projetos em aprendizado de máquina, é comum a utilização de três principais métodos: SEMMA, KDD e CRISP-DM. Esses métodos foram inicialmente criados para o desenvolvimento de projetos de mineração de dados; no entanto, eles são amplamente utilizados por falta de um método de gestão específico para o

aprendizado de máquina (Plotnikova, Dumas & Milani, 2020; Saltz & Krasteva, 2022).

De acordo com Han, Kamber e Pei (2011), *mineração de dados (data mining)* é definida como o processo de extração de conhecimento a partir de grandes quantidades de dados, armazenados em bancos ou outros repositórios de informação. Witten, Frank e Hall (2011) definiram mineração de dados como sendo a análise de conjuntos de dados com o objetivo de encontrar correlações ocultas, resumindo os dados de forma que sejam interpretáveis e úteis para o usuário. A seguir, serão apresentados os métodos KDD, SEMMA e CRISP-DM e suas particularidades, para posterior comparação.

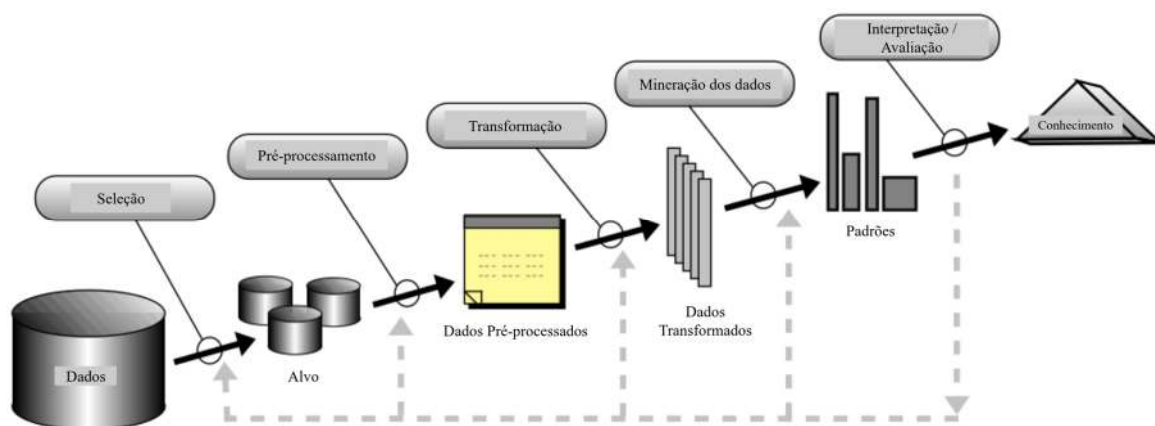
KDD

Para Fayyad, Piatetsky-Shapiro e Smyth (1996), o processo KDD, sigla de *Knowledge Discovery in Databases*, se divide em cinco principais etapas: seleção, pré-processamento, transformação, mineração de dados (ou *data mining*) e avaliação/interpretação dos dados.

Os mesmos autores destacam que a etapa de seleção corresponde à definição do problema, à definição do alvo da análise, bem como à separação dos dados que serão utilizados pelo processo. A etapa de pré-processamento corresponde ao levantamento e preparação inicial dos dados para a análise, incluindo remoção de ruídos e limpeza dos dados. É na próxima etapa, de transformação, que são aplicadas técnicas de seleção dos atributos dos modelos estatísticos. Nessa etapa, ocorre, também, a redução dos dados, ou seja, o banco de dados é reduzido para somente os dados necessários para se atingir o alvo do levantamento. A etapa de mineração de dados é definida por Piatetsky-Shapiro e Smyth (1996) como uma etapa do KDD que consiste na aplicação de técnicas de análise de dados e algoritmos de descoberta, que tem por objetivo identificar padrões particulares nos dados estudados. Por fim, a etapa de avaliação/interpretação refere-se à etapa em que são extraídas as conclusões. Todas essas etapas foram sintetizadas na Figura 3.

Além das etapas descritas na Figura 3, Fayyad, Piatetsky-Shapiro e Smyth (1996) descrevem uma etapa anterior ao começo do processo, que corresponde ao entendimento do domínio da aplicação, o entendimento das informações relevantes do negócio e os objetivos do cliente final. Mais tarde, Azevedo e Santos (2008) nomearam essa etapa como “Pré-KDD” para fins de comparação com os demais métodos.

Figura 3 - Visão geral do processo KDD



Fonte: Traduzida de Fayyad, Piatetsky-Shapiro e Smyth (1996).

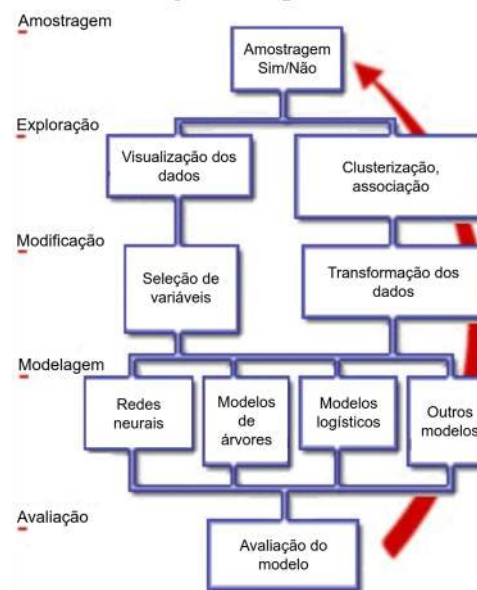
SEMMA

Segundo o SAS Institute (2020), que o desenvolveu, SEMMA é o acrônimo de *Sample*,

Explore, Modify, Model, Assess. Esse processo considera um ciclo de cinco estágios representados por cada letra do acrônimo. No estágio de amostragem (*sample*), extrai-se uma parcela da base de dados que seja grande o suficiente para representar o conjunto total de dados, mas pequena o suficiente para agilizar o processo de manipulação inicial. Este é apontado como um estágio opcional.

O segundo estágio corresponde à exploração dos dados, em busca de correlações ou tendências que ainda não foram identificadas. No próximo estágio, o de modificação, ocorre a manipulação dos dados, com o intuito de sintetizar a base somente com as informações necessárias ao modelo estatístico. A etapa de modelagem corresponde à utilização de *softwares* para prever valores ou identificar padrões. O último estágio (*assess*) corresponde à avaliação dos resultados, verificando confiabilidade, erro e aplicabilidade. Na Figura 4, representa-se o processo SEMMA e suas cinco etapas.

Figura 4 - Visão geral do processo SEMMA



Fonte: Traduzida de SAS Institute (2020).

CRISP-DM

De acordo com Azevedo e Santos (2008) e Chapman et al. (2000), o processo CRISP-DM, sigla de *Cross-Industry Standard Process for Data Mining*, foi desenvolvido por um consórcio inicialmente composto pela Daimler Chrysler, SPSS e NCR, e corresponde a um processo de seis estágios, a saber:

1. Entendimento do negócio: fase inicial, voltada ao entendimento dos objetivos do projeto e requisitos, de uma perspectiva de negócio, para a definição de um plano preliminar.

2. Entendimento dos dados: esta fase se inicia com uma coleta inicial de dados e segue com atividades de exploração desses mesmos dados, com o objetivo de familiarizar a equipe com eles, identificar os primeiros *insights* e avaliar a sua qualidade.

3. Preparação de dados: engloba todas as atividades para a construção do *dataset* final, ou conjunto de dados final, que será utilizado para a alimentação dos modelos estatísticos de aprendizado de máquina.


4. Modelagem: nesta fase, são aplicadas diversas técnicas de modelagem, e seus parâmetros são calibrados para o atendimento dos valores ótimos de saída.

5. Avaliação: nessa etapa, os modelos estatísticos obtidos são avaliados, detalhadamente, para garantir que eles estão funcionando adequadamente e atendem aos objetivos do negócio.

6. Implantação: geralmente, a criação do modelo estatístico não determina o final do projeto. É nessa fase que o modelo estatístico é implantado de uma forma que o cliente poderá utilizá-lo.

Na Figura 5, ilustra-se a visão geral do processo CRISP-DM e suas etapas de implantação.

Figura 5 - Visão geral do processo CRISP-DM



Fonte: Traduzida de Chapman et al. (2000).

2.2.6 Lacunas da literatura em projetos de aprendizado de máquina

O método Cascata do PMI (2018), uma evolução do método proposto por Royce (1987), é amplamente utilizado e bastante completo em termos do detalhamento de cada etapa; no entanto, apresenta uma abordagem preditiva, ou seja, é fundamental que o escopo e as atividades sejam definidos antes do início do projeto, tornando essa abordagem incompatível com projetos de aprendizado de máquina, dadas as características de complexidade e incerteza que esses projetos possuem.

O método ágil proposto pelo PMI (2017), assim como o *Scrum* descrito por Schwaber e Sutherland (2017), tem como base uma abordagem iterativa, o que facilita a adaptação às mudanças que possam ocorrer durante o desenvolvimento do projeto, e, portanto, é mais adequado para projetos de difícil estimativa prévia do escopo. No entanto, esses métodos não foram desenvolvidos especificamente para projetos de aprendizado de máquina e carecem de uma etapa de determinação de viabilidade econômica, o que dificulta a tomada de decisão de investimento.

O método híbrido descrito por Cooper e Sommer (2018) soluciona a falta de uma etapa de viabilidade financeira, e, ao mesmo tempo, propõe uma abordagem iterativa nas etapas de desenvolvimento, o que torna essa abordagem atrativa para se constituir a base do método proposto nesta dissertação. No entanto, esse método necessita de adaptações para ser aplicado em um projeto de aprendizado de máquina. Apesar de o método híbrido conter uma etapa de viabilidade financeira, não supera a dificuldade de se estimar os benefícios em projetos de aprendizado de máquina, dado que nesses projetos só é possível determinar a efetividade de um modelo estatístico após a realização de um teste, e, para isso, é necessário que o modelo estatístico esteja desenvolvido. Os custos de desenvolvimento desses projetos também são de difícil estimativa, tendo em vista que dependem de fatores como a qualidade dos dados, infraestrutura existente e disponibilidade das informações (Saltz & Crowston, 2017).

O método CRISP-DM descrito por Chapman et al. (2000), considerado mais completo do que os métodos SEMMA e KDD em termos de detalhamento das etapas, possui uma abordagem específica para projetos de mineração de dados, descrevendo detalhadamente as atividades específicas de projetos dessa natureza; no entanto, diferente do Scrum de Schwaber e Sutherland (2017), o CRISP-DM não possui uma definição das cerimônias e procedimentos de gestão que sustentam o ciclo de desenvolvimento do projeto, ou seja, o CRISP-DM aborda detalhadamente as atividades que constituem um projeto de mineração de dados, mas carece da determinação de como essas atividades podem ser viabilizadas do ponto de vista do gestor do projeto. Além disso, o CRISP-DM não possui uma etapa de determinação da viabilidade econômica do projeto e também é voltado para projetos de mineração de dados.

3 METODOLOGIA DE PESQUISA

3.1 DELINEAMENTO DO TRABALHO DE CAMPO

Na Figura 6, são descritas todas as etapas de pesquisa de forma resumida, desde o levantamento bibliográfico até o desenvolvimento e entrega do método proposto. Também pode ser observada a etapa em que cada pergunta de pesquisa é respondida, bem como a ordem cronológica de atuação em cada etapa.

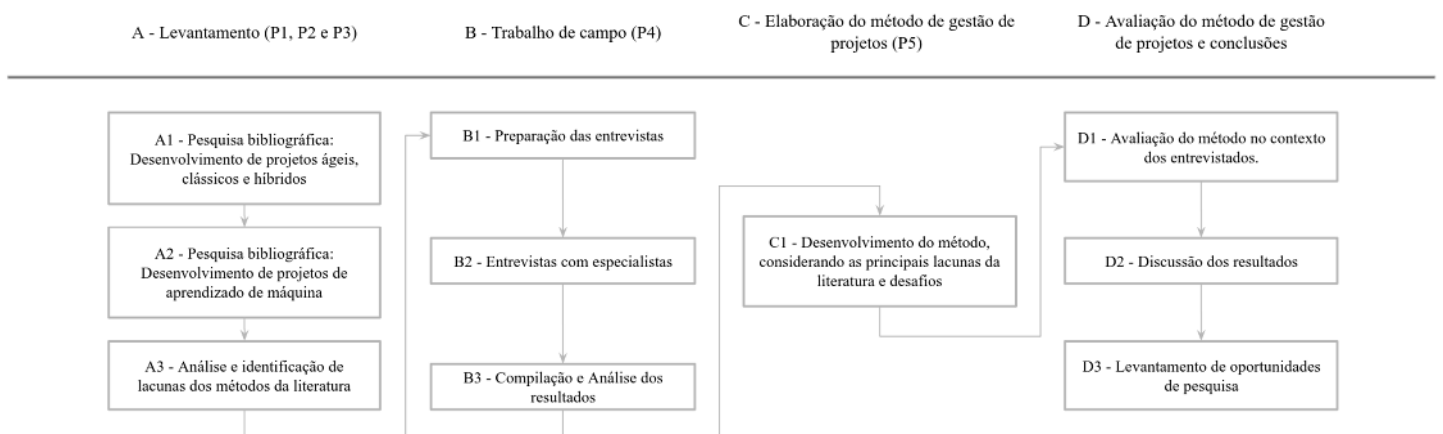


Figura 6 – Passo a passo do processo de pesquisa

Fonte: Próprio autor.

3.1.1 Pesquisa bibliográfica

Para a pesquisa bibliográfica, foram utilizadas as bases Web of Science, Scopus e Google Acadêmico, pesquisando combinações dos termos “*machine learning*”, “*artificial intelligence*”, “*data science*”, “*data mining*”, “*management*”, “*project*”, “*life cycle*”, “*challenges*”, “*agile*”, “*hybrid*”, “*pitfalls*”, “*methodology*”, “*agile stage gate*”, “*use cases*”, “*case studies*”, “*implementation*”, “*perspectives*”, “*benefits*”, “*scrum*”, “*definition*”, “*trends*”, “*systematic literature review*”, “*digital transformation*”, “*waterfall*”, “*framework*”, “*comparison*”, “*design science*”, “*applications*”, “*KPI*” e “*CRISP-DM*”. Dentre os 76 artigos selecionados para compor o referencial teórico da pesquisa, foram encontrados apenas cinco artigos que se dedicam a discutir métodos específicos para gestão de projetos de aprendizado de máquina.

3.1.2 Método das entrevistas

Com o intuito de detalhar os problemas específicos de projetos de aprendizado de máquina e compará-los aos resultados obtidos em outras pesquisas, foi utilizada a técnica de entrevistas em profundidade por meio de um questionário semiestruturado. O intuito foi fomentar uma expressão livre das experiências e percepções do entrevistado e facilitar a

conservação da atenção e foco do entrevistado no tema central.

De acordo com Malhotra (2010), a pesquisa em profundidade proporciona algumas vantagens em relação aos grupos de foco, tais como o aprofundamento do assunto abordado, a atribuição mais pessoal das percepções do entrevistado e o fomento de um ambiente com menor pressão social e maior flexibilidade na condução das pesquisas.

As entrevistas foram conduzidas com o auxílio de um questionário semiestruturado composto por perguntas abertas, dando a possibilidade da inclusão de novas perguntas, à medida que novas reflexões sobre o assunto central iam se desenrolando, ou seja, a entrevista seguiu um roteiro com perguntas e temas centrais, mas abriu a possibilidade para discussões não previstas inicialmente. Segundo Boynton e Greenhalgh (2004), questões qualitativas constituem uma forma efetiva de atuação em situações em que não há domínio prévio das expectativas das respostas dos entrevistados.

De acordo com Easterby, Thorpe e Lowe (2001), a utilização de entrevistas semiestruturadas é recomendada quando existe a necessidade de entendimento das circunstâncias em que o respondente está inserido, quando o assunto é comercialmente sensível ou quando outra forma de abordagem pode causar relutância em discutir o assunto. Estas questões justificam a adoção, neste trabalho, da entrevista em profundidade, com um questionário semiestruturado.

3.1.3 Seleção da amostra de entrevistados

Segundo Malhotra (2010), não há a necessidade de utilização de um processo de amostragem probabilística em pesquisas qualitativas, devido às características subjetivas e específicas desse tipo de abordagem. Portanto, a amostra utilizada nesta pesquisa foi do tipo não probabilístico, seguindo os procedimentos prescritos por Brace (2018), de forma a minimizar os vieses nos resultados, com a prioridade de selecionar entrevistados capazes de discutir e avaliar o método de gestão proposto, baseado nas suas experiências prévias com o tema. Quanto à quantidade de entrevistados, foi utilizado um critério de parada baseado na diminuição de novas descobertas conforme as entrevistas foram feitas, ou seja, as entrevistas foram interrompidas quando pararam de surgir informações novas.

Foram realizadas 19 entrevistas, seguidas do envio por e-mail de um protótipo do método proposto para que os entrevistados pudessem avaliá-lo, de acordo com a aplicabilidade e vantagens da utilização. O Quadro 2 exemplifica o perfil dos entrevistados.

Quadro 2 – Perfil dos entrevistados

Entrevistado	Ramo da empresa	Profissão	Experiência no cargo atual	Gestor de pessoas?
1	Aviação	Analista de TI	17 anos	Não
2	Bens de consumo	Cientista de dados	1 ano	Não
3	Bens de consumo	Consultor SAP	23 anos	Não
4	Consultoria	Gerente de <i>Analytics</i>	2 anos	Sim
5	Educação	Professor	1 ano	Não
6	Educação	Coordenador de curso (Desenvolvimento de sistemas)	11 anos	Sim
7	Educação	Coordenador de curso (Gestão de TI)	9 anos	Sim
8	Educação	Coordenador de curso (Gestão de TI)	14 anos	Sim
9	Energia	Cientista de dados	1 ano	Não

10	Marketing	Analista de dados	2 anos	Não
11	Saúde e bem-estar	CIO	2 anos	Sim
12	Saúde e bem-estar	Gerente de dados	3 anos	Sim
13	Seguros	Coordenadora de <i>Advanced Analytics</i>	2 anos	Sim
14	TI	Cientista de dados	2 anos	Não
15	TI	Engenheiro de aprendizado de máquina	2 anos	Não
16	TI	Engenheiro de aprendizado de máquina	1 ano	Não
17	TI	CTO	5 anos	Sim
18	Têxtil	Cientista de dados	2 anos	Não
19	Varejo	Engenheiro de aprendizado de máquina	2 anos	Sim

Fonte: Próprio autor.

4 RESULTADOS

4.1 REALIZAÇÃO DO TRABALHO DE CAMPO

Como previamente descrito, a parte prática desta pesquisa se dividiu em três momentos: entrevistas em profundidade, elaboração do método de gestão e avaliação do método de gestão.

4.1.1 Resultado das entrevistas em profundidade

As entrevistas foram realizadas via videoconferência entre 23/08/2021 e 29/09/2021, dentro do horário comercial. Foram gravadas e tiveram em média 50 minutos de duração. O roteiro da entrevista foi dividido em três blocos: conhecer o entrevistado e a empresa em que ele trabalha, identificar os principais desafios do cotidiano do entrevistado, e, por fim, identificar os métodos para gestão de projetos utilizados pelos entrevistados. Posteriormente, o modelo proposto foi avaliado pelos entrevistados, a fim de identificar as lacunas e o potencial de utilização. As avaliações foram recebidas entre 03/09/2021 e 04/11/2021.

Desafios técnicos e de gestão do aprendizado de máquina

O foco central das entrevistas foi identificar os principais desafios de projetos de aprendizado de máquina, para avaliar se existe algum desafio que não tenha sido identificado na literatura (P4). A partir da análise das gravações das entrevistas, foram identificados os três principais desafios relatados por cada entrevistado. Esses desafios foram extraídos do segundo bloco de perguntas do roteiro e também foram identificados ao longo da entrevista conforme as discussões foram se aprofundando. A Figura 7 mostra o resultado consolidado do levantamento dos desafios. O percentual do gráfico corresponde à fração dos entrevistados que mencionaram o desafio listado; por exemplo, no caso do desafio “Pouca previsibilidade de prazo e custo”, 47,4% dos entrevistados (9 de 19) apontaram esse desafio como sendo um dos três principais enfrentados no cotidiano de projetos de aprendizado de máquina.

Figura 7 – Principais desafios identificados nas entrevistas de profundidade



Fonte: Próprio autor.

A seguir, é apresentada uma descrição com um compilado do que foi dito pelos entrevistados para cada um dos desafios listados na Figura 7, com o intuito de aprofundar o entendimento dos entrevistados de cada desafio e extrair oportunidades de direcionamento da construção do método proposto por esse trabalho.

Pouca previsibilidade de prazo e custo

Refere-se à dificuldade de prever em um projeto de aprendizado de máquina os prazos e custos no longo prazo, principalmente devido à incerteza relacionada ao acerto dos modelos estatísticos, que dependem de fatores que muitas vezes não podem ser previstos, tais como a qualidade dos dados e a sua efetividade para a previsão que deseja ser alcançada. Em outras palavras, foi relatado que em projetos de aprendizado de máquina só é sabido o tempo total que será gasto no projeto quando o projeto já foi desenvolvido em quase sua totalidade, dificultando a priorização do projeto, dado que tanto o custo do quanto o seu benefício são difíceis de se estimar.

Pouco detalhamento dos requisitos do projeto

Trata da falta de documentações que detalham a necessidade do cliente, os objetivos do projeto e as funcionalidades e requisitos necessários para que o projeto gere resultados. Foi reportado que muitas vezes existe retrabalho no desenvolvimento por entendimento falho das necessidades do cliente, o que poderia ser evitado por meio de uma especificação adequada dos projetos.

Falta de profissionais com conhecimento técnico adequado

É a dificuldade de encontrar no mercado de trabalho profissionais com conhecimento técnico adequado para desenvolver os projetos. Principalmente nas áreas da Ciência de dados, que se refere ao desenvolvimento de modelos estatísticos, e na área de Engenharia de dados, que normalmente se refere à implantação de modelos estatísticos em produção e à preparação dos dados e da infraestrutura.

Baixa qualidade dos dados

Aborda a dificuldade de acesso a dados com boa qualidade no que diz respeito ao volume necessário para treinar os modelos estatísticos com a precisão esperada. Inclui outras características tais como completude dos dados, limpeza (dados bem-preparados e livres de erros) e consistência.

Falta de profissionais com conhecimento do negócio

Se refere a profissionais que conhecem as necessidades do cliente, bem como as características, cultura, produtos e processos da área do cliente. Foi muito relatada a necessidade de profissionais de aprendizado de máquina que tenham conhecimento da parte técnica em conjunto com o conhecimento do negócio, para que as soluções sejam tecnicamente consistentes e ao mesmo tempo atendam às necessidades do cliente. Apesar de serem desafios diferentes, a falta de profissionais com conhecimento de negócio tem correlação com o desafio de detalhamento dos requisitos do projeto, dado que ambos abordam o desenvolvimento de uma solução que pode não ser compatível com as expectativas do cliente.

Pouca dedicação à implementação robusta em produção

Foi relatada a importância de cuidar não só do desenvolvimento do modelo estatístico, mas também dos passos relacionados à implantação do modelo estatístico em produção e sua manutenção. Os relatos apontaram um impacto importante na produtividade da equipe, que tinha que dedicar muito tempo para a manutenção de projetos que não tiveram o cuidado e a atenção necessários na implantação robusta e automatizada na produção.

Baixa interpretabilidade dos modelos estatísticos

Tem ligação com a dificuldade de atribuir causa e efeito entre as variáveis do modelo estatístico e sua resposta, dificultando o entendimento das partes interessadas e dos gestores que patrocinam o projeto e diminuindo a confiança que essas partes têm no modelo estatístico proposto. É um desafio especialmente importante para os ambientes em que os gestores e partes interessadas não conhecem os conceitos mais gerais de aprendizado de máquina; dessa forma, tem relação com o desafio “Falta de gestores com conhecimento técnico adequado”.

Pouca produção científica sobre assuntos mais específicos

Foi relatado que não existe produção científica sobre assuntos mais específicos, fazendo com que o desenvolvimento tenha que ser feito “do zero”. Essa escassez, de acordo com os entrevistados, se dá principalmente pelo grande número de assuntos na área e pela velocidade com que surgem novos usos para o aprendizado de máquina. A ocorrência desses relatos sugere uma oportunidade de pesquisa: avaliar se a quantidade de produção científica sobre aprendizado de máquina supre de maneira adequada às necessidades dos profissionais, identificando se existem lacunas em algum procedimento de pesquisa específico (ex: estudo de caso) ou em alguma área específica do aprendizado de máquina.

Método de gestão incompatível com as características do projeto

Refere-se a relatos de que o método utilizado para a gestão dos projetos de aprendizado de máquina não considera particularidades inerentes a esse tipo de projeto. Os dois entrevistados que mencionaram esse desafio abordaram a incompatibilidade do *Scrum* para gestão de projetos de aprendizado de máquina, principalmente nas etapas de planejamento da *sprint*, dado que os projetos de aprendizado de máquina possuem uma complexidade maior de previsão de prazos e custos, o que gera uma dificuldade de planejar a *sprint*, mesmo que o planejamento seja de curto prazo. Esse desafio se conecta com o quesito “Pouca previsibilidade de prazo e custo” visto que os dois entrevistados mencionaram principalmente a etapa de planejamento como causa da incompatibilidade.

Governanças e leis de privacidade dificultam o acesso aos dados

Diz respeito ao cuidado necessário com a privacidade do cliente, que introduz uma camada adicional de complexidade aos projetos, sendo necessária a participação de áreas especializadas para validar a utilização dos dados, como nos casos das governanças relacionadas à lei geral de proteção de dados.

Falta de gestores com conhecimento técnico adequado

Refere-se à falta de compreensão dos gestores quanto às particularidades dos projetos de aprendizado de máquina, gerando expectativas no gestor que não podem ser atendidas na prática.

Turnover elevado de desenvolvedores

Foi relatado como uma consequência da abundância de vagas no mercado para poucos candidatos capacitados. Esse cenário fomenta a mudança frequente para empresas que oferecem melhores salários ou um ambiente de trabalho mais compatível com o perfil do profissional.

Mercado muda mais rápido do que a capacidade de o acompanhar

Diz respeito à velocidade muito grande com que as tecnologias e produtos se modernizam, o que gera um ambiente com uma necessidade de rápida adaptação, que nem sempre é possível dada a complexidade das soluções e recursos das empresas menores.

Infraestrutura não atende às necessidades de processamento

Refere-se a uma deficiência na infraestrutura para processar grandes volumes de dados, como por exemplo quantidade de memória RAM, capacidade de processamento dos servidores, ou uma estrutura eficiente para consulta dos dados. Essa deficiência de infraestrutura faz com que muitos dos possíveis projetos tornem-se inviáveis devido ao tempo que seria necessário para processar as informações.

Dificuldade para gerar resultados no curto prazo

Refere-se à dificuldade de trazer benefícios para a empresa no curto prazo. Foi mencionado que os projetos que não são de aprendizado de máquina normalmente geram um produto que pode ser utilizado ao fim de cada *sprint*, enquanto projetos de aprendizado de máquina não conseguem entregar no curto prazo, devido a suas características intrínsecas.

Dificuldade na comunicação entre pessoas com funções diferentes

Foi relatado como sendo um problema genérico de todos os tipos de projetos, mas que

tem mais destaque em projetos de aprendizado de máquina dada a dificuldade de explicar as soluções para áreas de funções diferentes, que não conhecem o conceito do aprendizado de máquina. Esse desafio tem relação com “Baixa interpretabilidade dos modelos estatísticos”; no entanto, não foi classificado dentro da mesma denominação pois o relato aqui teve um caráter mais genérico na descrição do desafio como sendo de comunicação de uma forma mais abrangente.

Complexidade da solução maior do que a necessária

Foi relatada a presença recorrente de soluções demasiadamente complexas, mais do que a necessidade do cliente, gerando um desperdício de tempo com funcionalidades que não agregam valor. Segundo os entrevistados, a causa principal seria a tendência dos desenvolvedores a aplicar a técnica mais recente (estado da arte), perdendo de vista as necessidades do negócio. Dessa forma, esse desafio tem conexão com “Falta de profissionais com conhecimento do negócio”.

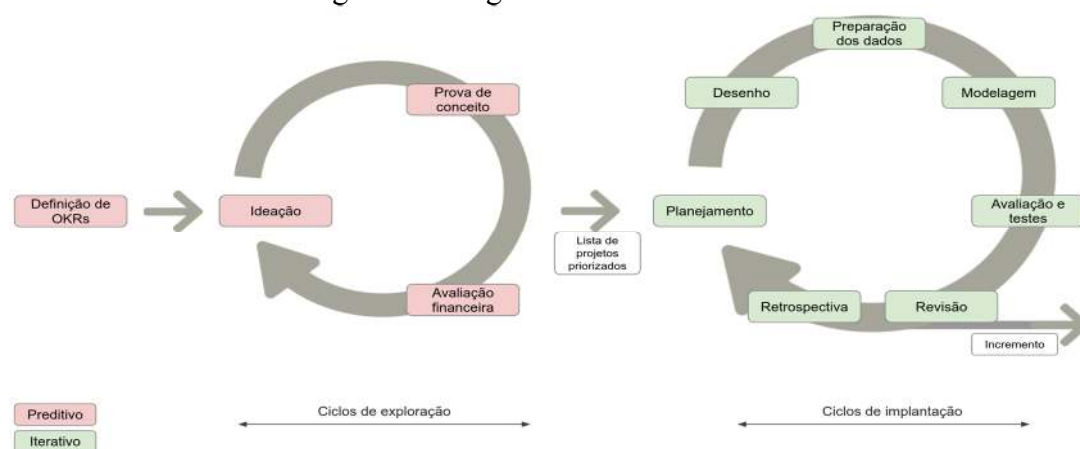
4.2 DESENVOLVIMENTO DO MÉTODO DE GESTÃO

4.2.1 Etapas

Com base nos desafios levantados nas entrevistas, bem como na revisão da literatura, foi desenvolvido o método SMILE, que consiste em uma evolução dos métodos CRISP-DM, considerando uma abordagem ágil nas etapas de desenvolvimento (ciclo de implantação), e adicionando-se uma etapa preditiva ao planejamento (ciclo de exploração), semelhante ao proposto por Cooper e Sommer (2018), que prescreveram fases preditivas de “ideação”, “definição de conceito” e “avaliação financeira” anteriores aos ciclos ágeis de “desenvolvimento” e “teste”, mesclando a previsibilidade dos métodos clássicos nas etapas preditivas à capacidade de adaptação às mudanças dos métodos ágeis nas fases iterativas de “desenvolvimento” e “testes”. Essa abordagem híbrida com um ciclo de exploração proporciona uma liberdade de experimentação, característica apontada por Blomster e Koivumäki (2022) como sendo importante na gestão de projetos de aprendizado de máquina.

O método proposto consiste em onze etapas. A Figura 8 ilustra essas etapas de forma sequencial, sendo que as etapas ilustradas em vermelho possuem características preditivas, influenciadas pelos métodos clássicos, enquanto as etapas coloridas em verde indicam características iterativas, inspiradas em métodos ágeis.

Figura 8 - Diagrama do método SMILE



Fonte: Próprio Autor.

O Quadro 3 apresenta a relação entre cada um dos desafios dos projetos de aprendizado de máquina identificados com a etapa que busca abordá-los. Ao todo, 25 dos 32 desafios

levantados foram abordados pelo método de gestão proposto, sendo que dos sete desafios não atendidos, cinco possuem associação com a escassez de profissionais qualificados no mercado, e dois possuem associação com as governanças e riscos que restringem o acesso aos dados necessários para o desenvolvimento dos projetos. Tanto a escassez de profissionais quanto às exigências regulatórias e de governança, por serem fatores externos à gestão de projetos, não puderam ser abordados diretamente pelo método proposto, já que as práticas propostas não alterariam a disponibilidade de profissionais no mercado, o risco de segurança da informação nem as exigências de órgãos reguladores.

Quadro 3 - Desafios abordados *versus* etapas do SMILE

Etapas SMILE	Desafio abordado	Fonte
OKR	Falta de agilidade organizacional	Brock e Von Wangenheim (2019)
OKR	Resistência interna	Brock e Von Wangenheim (2019)
Ideação	Pouca produção científica sobre assuntos mais específicos	Entrevistas em profundidade
Ideação	Complexidade da solução maior do que a necessária	Entrevistas em profundidade
Prova de conceito	Dificuldade na integração de projetos cognitivos a processos e sistemas já existentes	Davenport, Loucks e Schatsky (2017)
Prova de conceito	Gestores não entendem as tecnologias cognitivas e como elas funcionam	Davenport, Loucks e Schatsky (2017)
Prova de conceito	As tecnologias são imaturas	Davenport, Loucks e Schatsky (2017)
Prova de conceito	O potencial da tecnologia é exagerado por quem vende	Davenport, Loucks e Schatsky (2017)
Prova de conceito	Baixa interpretabilidade dos modelos	Entrevistas em profundidade
Prova de conceito	Falta de gestores com conhecimento técnico adequado	Entrevistas em profundidade
Prova de conceito	Infraestrutura não atende às necessidades de processamento	Entrevistas em profundidade
Avaliação financeira	Pouca previsibilidade de prazo e custo	Entrevistas em profundidade
Avaliação financeira	Tecnologia e conhecimento são muito caros	Davenport, Loucks e Schatsky (2017)
Avaliação financeira	Investimento insuficiente	Brock e Von Wangenheim (2019)
Planejamento	Dificuldade na comunicação entre pessoas com funções diferentes	Entrevistas em profundidade
Planejamento	Dificuldade para gerar resultados no curto prazo	Entrevistas em profundidade
Planejamento	Mercado muda mais rápido do que a capacidade de acompanhá-lo	Entrevistas em profundidade
Desenho	Integração das tecnologias antigas às novas	Brock e Von Wangenheim (2019)
Desenho	Pouco detalhamento dos requisitos do projeto	Entrevistas em profundidade
Preparação dos dados	Baixa qualidade dos dados	Entrevistas em profundidade
Avaliação e testes	Pouca dedicação à implementação robusta em produção	Entrevistas em profundidade
Avaliação e testes	A tecnologia é instável	Brock e Von Wangenheim (2019)
Revisão	Falta de liderança	Brock e Von Wangenheim (2019)
Retrospectiva	Método de gestão incompatível com as características do projeto	Entrevistas em profundidade
Retrospectiva	<i>Turnover</i> elevado de desenvolvedores	Entrevistas em profundidade
Não Aplicável	Riscos de segurança da informação	Brock e Von Wangenheim (2019)
Não Aplicável	Governanças e leis de privacidade dificultam o acesso aos	Entrevistas em profundidade

	dados	
Não Aplicável	Falta de mão de obra qualificada e conhecimento nas tecnologias digitais	Brock e Von Wangenheim (2019)
Não Aplicável	Falta de profissionais com conhecimento do negócio	Entrevistas em profundidade
Não Aplicável	Falta de profissionais com conhecimento técnico adequado	Entrevistas em profundidade
Não Aplicável	Não existem pessoas suficientes peritas na tecnologia	Davenport, Loucks e Schatsky (2017)
Não Aplicável	Indisponibilidade de um parceiro tecnológico adequado	Brock e Von Wangenheim (2019)

Fonte: Próprio autor.

O método proposto por este estudo possui uma etapa prévia de definição de OKRs e dois ciclos: o ciclo de exploração e o ciclo de implantação. Anterior aos ciclos, temos a etapa de definição dos OKRs, que visa direcionar a equipe de desenvolvimento a partir de objetivos e resultados-chave.

No ciclo de exploração são levantadas, testadas e mensuradas oportunidades de projetos, de forma a alimentar uma lista de iniciativas priorizadas de acordo com os interesses da organização. Ao final de cada ciclo de exploração, é entregue a avaliação financeira de uma oportunidade de projeto, em termos de estimativas de esforço e benefícios. Fazem parte deste ciclo as etapas de “ideação”, “prova de conceito” e “Avaliação financeira”.

O ciclo de implantação começa com uma oportunidade de projeto avaliada e priorizada, e tem como principal propósito entregar ao final de cada ciclo uma parte potencialmente utilizável do projeto, ou “incremento”. Este ciclo engloba as etapas de “planejamento”, “desenho”, “preparação dos dados”, “modelagem”, “avaliação e testes”, “revisão” e “retrospectiva”.

Os dois ciclos são considerados assíncronos, pois a duração de cada um pode ser diferente, o desenvolvimento de uma iniciativa estudada em um ciclo de exploração pode levar mais de um ciclo de implantação para ser entregue, as equipes podem ser diferentes, podem existir mais de um ciclo de implantação para um único ciclo de exploração, e por fim, a ordem dos projetos no ciclo de implantação pode ser diferente da ordem em que as oportunidades foram levantadas e mensuradas nos ciclos de exploração.

Em termos de abordagem, o ciclo de exploração é preditivo, devido à previsão de esforço e impacto, enquanto o ciclo de implantação é iterativo, devido à flexibilidade com que o escopo pode ser ajustado a cada ciclo de implantação.

A seguir, descrevem-se as onze etapas que compõem o método proposto e a forma com que buscam abordar os desafios de projetos de aprendizado de máquina.

Definição de OKRs

Em linhas gerais, é a definição de um objetivo único alinhado à estratégia da organização, de modo que todos saibam de maneira clara e transparente quais são os objetivos e resultados que se pretende alcançar, a fim de proporcionar direcionamento estratégico. Essa etapa deve ter envolvimento ativo das lideranças da organização. É com base nos OKRs que as entregas de todas as etapas subsequentes do projeto são pautadas.

A definição de OKRs é especialmente importante para minimizar o impacto dos desafios de “Falta de agilidade organizacional” e “Resistência interna”. O primeiro é minimizado porque a definição de objetivos claros para a organização possibilita um direcionamento claro para as equipes que trabalham em métodos ágeis, e, portanto, possibilita uma atuação mais autônoma de cada equipe. O segundo desafio é minimizado com a utilização dos OKRs pois a definição clara dos objetivos é o primeiro passo para um processo de gestão de mudanças bem-sucedido, que minimiza os impactos das resistências às mudanças (Hiatt, 2006).

Ideação

Etapla de levantamento de ideias, possibilidades e oportunidades de utilização do aprendizado de máquina, a fim de alcançar os OKRs. A partir da ideação, tem-se uma lista prévia de oportunidades de projeto que serão testadas na etapa da prova de conceito.

O impacto da “Pouca produção científica sobre assuntos mais específicos” pode ser minimizado pelo uso de técnicas que possam extrair da melhor forma o conhecimento e o potencial criativo de cada integrante do grupo, a exemplo do *brainstorming*, da análise morfológica e do design heurístico de Daly et al. (2016). O desafio “Complexidade da solução maior do que a necessária” também é abordado nessa etapa com técnicas provenientes do *Design Thinking* de Brown (2008), tais como o mapa de empatia, os mapeamentos da jornada do usuário e a construção de *personas*, que posicionam o usuário ou cliente final no centro do processo de desenvolvimento, evitando o desenvolvimento de soluções complexas que não agregam valor.

Prova de conceito

Etapla de avaliação de viabilidade técnica do projeto, tem como objetivos avaliar critérios técnicos como a disponibilidade e qualidade dos dados e potencial de precisão dos modelos estatísticos, além apresentar de uma maneira prática o conceito do projeto de forma a alinhar expectativas e necessidades. Por ser uma demonstração em que se utiliza um protótipo, tem como principal desafio equilibrar a simplicidade e o baixo investimento com a necessidade de demonstrar a aplicabilidade da solução. A prova de conceito fornece subsídios para a etapa de avaliação financeira de forma que as estimativas de custos e esforços possam ser baseadas em um teste prático.

Nessa etapa, são minimizados os impactos dos desafios “Gestores não entendem as tecnologias cognitivas, e como elas funcionam”, “Baixa interpretabilidade dos modelos” e “Falta de gestores com conhecimento técnico adequado”, pois um protótipo ou prova de conceito facilita o entendimento do modelo matemático e sua aplicação, ao demonstrar o funcionamento de forma visual, prática e objetiva.

Já os desafios “O potencial da tecnologia é exagerado por quem vende”, “Dificuldade na integração de projetos cognitivos com processos e sistemas já existentes”, “As tecnologias são imaturas” e “Infraestrutura não atende às necessidades de processamento” são abordados uma vez que a prova de conceito ajuda a evidenciar e a descartar projetos de baixa aplicabilidade ou com risco elevado de não possuírem uma estrutura que os sustentem no longo prazo.

Avaliação financeira

Etapla de viabilidade econômica, ou *business case*, baseada na prova de conceito e experiência prévia. É importante destacar que as horas de projeto devem ser consideradas somente para análise de viabilidade financeira, já que podem atrapalhar a produtividade da equipe se forem utilizadas como ferramenta de controle de escopo. Idealmente, essa etapa deve ser utilizada como referência de viabilidade financeira e não como ferramenta de definição de prazos da iniciativa, dada a abordagem ágil no ciclo de implantação. Após essa etapa, define-se a iniciativa que será desenvolvida e a equipe que irá desenvolvê-la em ciclos ágeis iterativos e adaptativos.

Nesta etapa, é abordada a lacuna da falta de uma fase de viabilidade financeira nos métodos de gestão estudados, além de se contemplar uma solução viável para os desafios “Pouca previsibilidade de prazo e custo”, “Tecnologia e conhecimento são muito caros” e “Investimento insuficiente”, pois uma etapa de Avaliação financeira é uma forma objetiva de aprovar um projeto do ponto de vista financeiro, garantindo que os benefícios do projeto superem os custos. Além disso, é uma forma de estimar os custos do projeto, dando previsibilidade financeira à organização.

Planejamento

Também conhecida como *planning*, é a cerimônia de planejamento e definição das atividades da *sprint* baseada no *Scrum*. É nesse momento que os requisitos do projeto são transformados em atividades, e estas são alocadas na *sprint*. *Sprint* é um período de duas a quatro semanas que proporciona um ciclo de inspeção e adaptação. Ao final da *sprint*, deve-se ter um produto potencialmente utilizável, ou ao menos que possa ser testado, nos casos de maior incerteza quanto à precisão dos modelos estatísticos. É a partir do plano resultante desse evento que a equipe planeja os ciclos ágeis de iteração, e esse plano contemplará as atividades e prazos das próximas etapas do ciclo.

Essa etapa é especialmente importante para manter a comunicação entre os membros da equipe e garantir um alinhamento quanto às atividades que serão realizadas nas *sprints*, portanto, ela aborda o desafio “Dificuldade na comunicação entre pessoas com funções diferentes”. De maneira opcional, a evolução das atividades dentro da *sprint* pode ser acompanhada por meio de reuniões diárias, de acordo com as particularidades de cada equipe e cada projeto.

A abordagem de desenvolvimento iterativo dos projetos com um produto potencialmente utilizável ao final de cada *sprint* atende aos desafios “Dificuldade para gerar resultados no curto prazo” e “Mercado muda mais rápido do que a capacidade de o acompanhar”, já que o desenvolvimento em *sprints* facilita a geração de resultados parciais no curto prazo e a adaptação às mudanças do mercado.

Desenho

Etapla de delineamento da arquitetura ou estratégia de desenvolvimento do projeto, de forma a organizar o processo de desenvolvimento, aumentando a produtividade e diminuindo o retrabalho. Essa etapa é feita somente pelo analista responsável pela codificação do projeto. Esse desenho contempla o plano de atuação mais técnica das próximas etapas (preparação de dados, modelagem e testes)

É essencial definir no projeto o investimento de tempo nessa etapa, pois é nela que o projeto é especificado, atendendo ao desafio “Pouco detalhamento dos requisitos do projeto”. É também nessa etapa que deve ser considerado o plano de “Integração das tecnologias antigas às novas”, que pode ser testado na fase de prova de conceito.

Preparação dos dados

Levantamento e tratamento dos dados, de forma a proporcionar os insumos necessários para a modelagem. Normalmente é a etapa de maior investimento de tempo nos projetos de aprendizado de máquina. A preparação de dados é um pré-requisito para que a modelagem estatística seja feita.

Nessa etapa, os dados são tratados e são resolvidos os problemas de “Baixa qualidade dos dados”, que também podem ser testados na fase de prova de conceito, com o objetivo de testar a viabilidade do projeto, considerando-se a qualidade dos dados.

Modelagem estatística

Etapla de codificação da solução de aprendizado de máquina, consiste no desenvolvimento e implantação de modelos estatísticos. Nessa etapa, devem ser considerados os desenvolvimentos das funcionalidades de infraestrutura, a configuração de ambiente e a automatização das rotinas, de modo a garantir a robustez do projeto em termos de sustentação, continuidade, estabilidade e manutenção do modelo estatístico.

Avaliação e testes

Etapla de avaliação dos resultados do modelo estatístico e testes de consistência. Consiste em avaliar a acurácia dos modelos estatísticos nos casos de aprendizado supervisionado, ou a aplicabilidade dos agrupamentos nos casos de aprendizado não supervisionado. Os testes também são importantes para garantir a consistência da

informação, a uniformidade dos resultados e a qualidade dos dados de entrada. É importante que seja investida uma parcela considerável de tempo nessa etapa para evitar gastos não planejados nas etapas de pós-implantação.

Os impactos relacionados aos desafios “Pouca dedicação à implementação robusta em produção” e “A tecnologia é instável” podem ser minimizados nesta etapa por meio da realização de testes específicos relacionados à implantação em produção e a estabilidade da tecnologia, tais como testes de usabilidade, testes funcionais ou testes unitários.

Revisão

Também conhecida como *review*, é a cerimônia de inspeção das entregas da *sprint* com a equipe e os clientes do projeto; é também utilizada para definir a estratégia e as prioridades para a próxima *sprint*.

Essa etapa gera uma oportunidade importante de inspeção e direcionamento do projeto pela liderança, e, portanto, sua aplicação minimiza os impactos do desafio “Falta de liderança”.

Retrospectiva

Cerimônia para discutir melhorias do processo de gestão. Tem como finalidade adequar a forma de trabalho às particularidades de cada equipe. Não deve ser confundida com a *Review*, já que a retrospectiva tem como foco o aperfeiçoamento dos processos internos de comunicação e do método de trabalho da equipe SMILE. Essa etapa é a última de cada iteração do ciclo de implantação e prepara o início de um novo ciclo. Essa etapa é também especialmente importante para a melhoria contínua do método de gestão, levando em conta as particularidades da equipe e do projeto. A aplicação correta dessa etapa minimiza o desafio “Método de gestão incompatível com as características do projeto” já que a melhoria contínua atende às particularidades de cada projeto.

4.2.2 Papéis

A definição de papéis do método SMILE é inspirada no *Scrum* de Schwaber e Sutherland (2017), que consiste basicamente do *SMILE Master* (derivado do *Scrum Master*), *Product Owner* e desenvolvedores.

O *SMILE Master* tem como principal função fomentar a produtividade da equipe por meio da gestão do processo SMILE, ajudando a solucionar os problemas derivados do método de gestão, bem como definindo as regras do processo, tais como a duração dos eventos e das *sprints* e os participantes de cada evento. Já o *Product Owner* tem como principal função entender os requisitos do projeto e definir a ordem de desenvolvimento de suas funcionalidades, atuando como um representante do cliente final. Por fim, os desenvolvedores são os responsáveis pelo desenvolvimento propriamente dito das funcionalidades, incluindo as etapas de desenho, preparação dos dados, modelagem, avaliação e testes.

Uma vantagem do SMILE é a flexibilidade de alocação das equipes nos ciclos de exploração e implantação, já que se pode alocar uma equipe (*squad*) em cada ciclo, proporcionando uma especialização, ou, nos casos de escassez de mão de obra, a mesma equipe pode atuar nos dois ciclos de forma intermitente, alternando entre os ciclos de exploração e desenvolvimento à medida que uma oportunidade viável é identificada no ciclo de exploração.

4.2.3 Comparativo entre o SMILE e os demais métodos

O Quadro 4 apresenta uma comparação das etapas dos métodos estudados na revisão bibliográfica e o método SMILE. O quadro evidencia uma característica importante do SMILE: A antecipação da etapa de entendimento dos dados por meio da prova de conceito,

dando uma vantagem para o SMILE na questão de previsibilidade de custos, fornecendo para a etapa de avaliação financeira dados importantes para as estimativas de custos e prazos. Outra característica que pode ser observada no quadro é um detalhamento maior das etapas em uma ótica que abrange as atividades específicas do desenvolvimento de softwares de aprendizado de máquina, inspirados no CRISP-DM, e atividades voltadas para a gestão do projeto, inspiradas no Scrum e no método Híbrido.

Quadro 4 - Método SMILE em comparação com demais métodos

Cascata PMI (2018)	Cascata Royce (1987)	Ágil PMI (2017)	Scrum Schwaber e Sutherland (2017)	Híbrido Cooper e Sommer (2018)	KDD Fayyad, Piatetsky-Shapiro e Smyth (1996)	SEMMA SAS Institute (2020)	CRISP-DM Chapman et al. (2000)	SMILE Próprio Autor (2022)
Trabalho anterior ao projeto	-----	-----	-----	-----	-----	-----	<i>Entendimento do negócio</i>	OKRs
	-----	-----	-----	Ideação	Pré-KDD	-----		Ideação
	-----	-----	-----	Conceito		-----		Prova de conceito
	-----	-----	-----	Business Case	-----	-----		Avaliação financeira
Início do Projeto	-----	-----	-----	-----	-----	-----	-----	
Organização e preparação	Requisitos de sistema	<i>Requisitos</i>	<i>Planning</i>	-----	-----	-----	-----	<i>Planejamento</i>
	Requisitos de software			-----	-----	-----	-----	
Execução do trabalho	Análise	<i>Análise</i>	<i>Daily</i>	<i>Desenvolvimento</i>	<i>Seleção</i>	Amostragem	<i>Entendimento dos dados</i>	Prova de conceito*
					-----	Exploração		
	Desenho do programa	<i>Desenho</i>			-----	-----	-----	<i>Desenho</i>
	-----	-----			<i>Pré-processamento</i>	Modificação	<i>Preparação de dados</i>	<i>Preparação dos dados</i>
					<i>Transformação</i>			
	Codificação	<i>Construção</i>			<i>Mineração de dados</i>	Modelo	<i>Modelagem</i>	<i>Modelagem</i>
	Teste	<i>Teste</i>		<i>Teste</i>	<i>Interpretação / Validação</i>	Avaliação	<i>Avaliação</i>	<i>Avaliação e testes</i>
Conclusão do projeto	Operação	-----	<i>Review</i>	Lançamento	Pós-KDD	-----	<i>Implantação</i>	<i>Revisão</i>
-----	-----	-----	<i>Retrospectiva</i>	-----	-----	-----	-----	<i>Retrospectiva</i>

Preditivo * Etapa representada no quadro fora da ordem em que é executada, pois antecipa atividades de entendimento e análise.
Iterativo

Fonte: Adaptado de Azevedo e Santos (2008), Shafique e Qaiser (2014), Saltz e Sutherland (2019) e Cooper e Sommer (2018).

4.3 AVALIAÇÃO DO MÉTODO DE GESTÃO

Nessa etapa, uma apresentação do método SMILE acompanhada da descrição de cada etapa foi enviada para os entrevistados. O meio utilizado para o envio foi o e-mail, para dar tempo e liberdade para os entrevistados avaliarem conceitualmente a aplicabilidade e eficácia do método. Ao todo, sete dos 19 entrevistados retornaram o e-mail. Todos avaliaram positivamente o SMILE, em termos de aplicabilidade e eficácia. Cada entrevistado comentou itens diferentes para discussões e melhorias, que foram tabulados no Quadro 5.

Quadro 5 – Avaliação do método pelos entrevistados

Entrevistado	Ramo da empresa	Profissão	Comentário	Avaliação quanto à aplicabilidade
1	Consultoria	Gerente de Analytics	Gestão da mudança: Comentou a importância de métodos de gestão de mudança para aumentar a chance de sucesso na transição para o método proposto. Os métodos de gestão de mudanças são procedimentos que têm como objetivo ajudar profissionais e equipes a passarem por mudanças de processos que afetam significativamente a forma de trabalho, levando em consideração aspectos comportamentais do ser humano. Um exemplo de método de gestão de mudança conhecido é o ADKAR (<i>Awareness, Desire, Knowledge, Ability, Reinforcement</i>), cujas letras representam os passos que devem ser seguidos para facilitar o processo de transição.	Positiva
2	Têxtil	Cientista de dados	Estimativa da acurácia: Reforçou a dependência de profissionais experientes na etapa de prova de conceito dada a dificuldade de estimar a acurácia de um modelo estatístico em um curto período de tempo. É necessária uma experiência considerável para conseguir simplificar o processo a ponto de ter significado e ao mesmo tempo caber na etapa de exploração.	Positiva
3	Aviação	Analista de TI	Pós-Implantação: Reforçou a necessidade do planejamento da pós-implantação, incluindo a etapa de transição do projeto da equipe de desenvolvimento para a de sustentação. A depender das características do projeto, pode ser determinado um período de acompanhamento minucioso da entrega da sprint pela equipe de desenvolvimento, com tarefas voltadas ao monitoramento, documentação e desenvolvimento de funcionalidades de estabilização do projeto. Também foi dada ênfase à necessidade da participação de representantes do negócio e da equipe que irá assumir a sustentação no período de transição do projeto para a sustentação, bem como nas etapas de testes, para garantir o atendimento das necessidades do cliente e a estabilidade do projeto na pós-implantação.	Positiva
7	Educação	Professor	Técnicas de Ideação: Sugeriu a utilização de técnicas do <i>Design Thinking</i> nas etapas “Definição de OKRs” e “Ideação” para auxiliar o processo criativo. Para Dorst (2011), <i>Design Thinking</i> é um paradigma para lidar com problemas em diversas áreas de atuação, e consiste em uma abordagem voltada ao cliente que encoraja a experimentação, prototipação e criatividade. Dentre as técnicas dessa abordagem, poderiam ser aplicadas nas fases de criação o Mapa de empatia, para o entendimento dos comportamentos e necessidades do cliente, e o <i>Brainstorm</i> , técnica para gerar novas ideias em grupo.	Positiva
9	Tecnologia da informação	CTO	Engenharia de software: Frisou a necessidade de que projetos de aprendizado de máquina tenham o devido investimento de tempo nas disciplinas da Engenharia de software, principalmente nas que impactam diretamente na robustez e estabilidade do software, tais como a definição correta da arquitetura, o uso de padrões de programação e procedimentos específicos de testes.	Positiva
14	Tecnologia da informação	Engenheiro de aprendizado de máquina	Entregável de cada sprint: Foi relatado que projetos de aprendizado de máquina possuem uma complexidade maior do que projetos comuns de software, e que, portanto, possuem uma dificuldade maior de entregar ao fim de cada sprint um produto que possa ser utilizado. Dessa forma, foi sugerida uma abordagem mais flexível na definição de entrega de cada sprint. A abordagem sugerida mantém o objetivo de tentar sempre implementar um programa que possa ser utilizado ao final de cada sprint, no entanto, permitindo flexibilizações quando necessário, como por exemplo na primeira sprint do projeto, que tem uma carga maior de exploração e preparação dos dados que serão utilizados no modelo estatístico.	Positiva
19	Varejo	Engenheiro de aprendizado de máquina	Otimização dos modelos estatísticos: Foi reforçada a possibilidade de otimizar os modelos estatísticos com a utilização de técnicas mais avançadas a cada iteração. A implantação seguiria de maneira simplificada nas primeiras <i>sprints</i> , com foco na implantação de um modelo minimamente viável; no entanto, a solução pode ser otimizada a cada <i>sprint</i> , até que o modelo atenda às necessidades do negócio, ou que a otimização não compense mais financeiramente.	Positiva

Fonte: Próprio autor.

5 CONCLUSÕES

Este trabalho teve como objetivo a criação de um método para gestão de projetos de aprendizado de máquina que abordasse as principais lacunas identificadas pela literatura, bem como os desafios específicos enfrentados por gestores de projetos dessa natureza. A partir do levantamento bibliográfico dos principais desafios do aprendizado de máquina e das técnicas de gestão utilizadas atualmente, ficou evidenciado que os métodos utilizados possuem diversas lacunas, não atendendo aos principais desafios levantados pela literatura.

Para confirmar os desafios da literatura, levantar eventuais desafios não abordados e gerar um aprofundamento no entendimento do problema, foram realizadas entrevistas em profundidade com profissionais do ramo do aprendizado de máquina. A partir dos resultados dessas entrevistas e da pesquisa bibliográfica, ficou evidenciada a necessidade de um método de gestão que trate especificamente das particularidades dos projetos de aprendizado de máquina.

Sendo assim, foi criado o método SMILE (*Structured Machine Learning Employment*), que prescreve as etapas do projeto desde sua concepção até sua implantação, levando em consideração as técnicas de coordenação dos times envolvidos. O método é dividido nos ciclos de exploração e implantação, que confere uma característica híbrida ao processo de gestão, aproveitando a previsibilidade e controle dos métodos clássicos nos ciclos de exploração, e a flexibilidade dos métodos ágeis nos ciclos de implantação.

O método proposto abordou os principais desafios identificados na revisão da literatura e nas entrevistas de profundidade, buscando aproveitar as vantagens dos métodos clássicos, ágeis e de mineração de dados em uma abordagem híbrida específica para projetos de aprendizado de máquina.

Por fim, o SMILE foi avaliado pelos entrevistados quanto à sua aplicabilidade, sendo que o resultado positivo obtido evidencia o seu potencial em trazer resultados expressivos para as organizações.

Como sugestão para trabalhos futuros, o método ora proposto poderia ser investigado de forma quantitativa, por meio da execução de uma pesquisa com um número maior de participantes para identificar estatisticamente a sua aplicabilidade em contextos específicos. Outra oportunidade é uma abordagem empírica na avaliação do modelo, já que a avaliação dos entrevistados ocorreu apenas sobre o modelo teórico sem aplicá-lo na prática. Por fim, com base nos temas sugeridos pelos entrevistados, o modelo proposto poderia ser expandido além da implantação, com etapas relacionadas a todo o ciclo de vida do projeto, a exemplo da etapa de sustentação.

REFERÊNCIAS

- Ahmed, A., Ahmad, S., Ehsan, N., Mirza, E., & Sarwar, S. Z. (2010, June). Agile software development: Impact on productivity and quality. In *2010 IEEE International Conference on Management of Innovation & Technology* (pp. 287-291). IEEE.
- Ahmed, B., Dannhauser, T., & Philip, N. (2018, September). A lean design thinking methodology (LDTM) for machine learning and modern data projects. In *2018 10th Computer Science and Electronic Engineering (CEECE)* (pp. 11-14). IEEE.
- Azevedo, A., & Santos, M. F. (2008). KDD, SEMMA and CRISP-DM: a parallel overview. IADS-DM. Disponível em: https://www.researchgate.net/publication/220969845_KDD_semma_and_CRISP-DM_A_parallel_overview. Acesso em: 12 abr. 2022.

Balakrishnan, T., Chui, M., Hall, B., & Henke, N. (2020). *The state of AI in 2020*. Mckinsey global publishing. Disponível em: <http://ceros.mckinsey.com/global-ai-survey-2020-a-desktop>. Acesso em: 12/4/2021.

Beck, K., Beedle, M., Van Bennekum, A., Cockburn, A., Cunningham, W., Fowler, M., ... & Thomas, D. (2001). Manifesto for agile software development. Disponível em: <https://www.agilealliance.org/agile101/the-agile-manifesto/>. Acesso em: 29 jun. 2020.

Blomster, M., & Koivumäki, T. (2022). Exploring the resources, competencies, and capabilities needed for successful machine learning projects in digital marketing. *Information Systems and e-Business Management*, 20(1), 123-169.

Boynton, P. M., & Greenhalgh, T. (2004). Selecting, designing, and developing your questionnaire. *BMJ - British Medical Journal*, 328(7451), 1312-1315.

Brace, I. (2018). *Questionnaire design: How to plan, structure and write survey material for effective market research*. London, Kogan Page Publishers.

Brock, J. K. U., & Von Wangenheim, F. (2019). Demystifying AI: What digital transformation leaders can teach you about realistic artificial intelligence. *California Management Review*, 61(4), 110-134.

Brown, T. (2008). Design thinking. *Harvard business review*, 86(6), 84.

Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). CRISP-DM 1.0: Step-by-step data mining guide. *SPSS inc*, 9(13), 1-73.

Chotiganta, P. (2021). *The study of KPI and OKR in the employees' performance evaluation in Thai context*. Master's thesis (Master of Management) - College of Management, Mahidol University, Nakhon Pathom.

Cooper, R. G. (2016). Agile–Stage-Gate Hybrids: The Next Stage for Product Development Blending Agile and Stage-Gate methods can provide flexibility, speed, and improved communication in new-product development. *Research-Technology Management*, 59(1), 21-29.

Cooper, R. G., & Sommer, A. F. (2016). Agile-Stage-Gate: New idea-to-launch method for manufactured new products is faster, more responsive. *Industrial Marketing Management*, 59, 167-180.

Cooper, R. G., & Sommer, A. F. (2018). Agile–Stage-Gate for Manufacturers: Changing the Way New Products Are Developed Integrating Agile project management methods into a Stage-Gate system offers both opportunities and challenges. *Research-Technology Management*, 61(2), 17-26.

Daly, S. R., Seifert, C. M., Yilmaz, S., & Gonzalez, R. (2016). Comparing ideation techniques for beginning designers. *Journal of Mechanical Design*, 138(10), 101108.

Davenport, T., Loucks, J., & Schatsky, D. (2017). Cognitive technologies survey. Deloitte Development LLC, London. Disponível em:

<https://www2.deloitte.com/content/dam/Deloitte/us/Documents/deloitte-analytics/us-da-2017-deloitte-state-of-cognitive-survey.pdf>. Acesso em: 25 jan. 2022.

Easterby-Smith, M. P. V., Thorpe, R., & Lowe, A. (2001). *Management Research: An Introduction*. (2nd ed.) Sage Publications Ltd.

Eljayar, A., & Busch, J. S. (2021). Agile-Stage-Gate Approach: Exploratory Research on the Structure, Roles, and Responsibilities. *Athens Journal of Technology and Engineering*, 8(1), 39-90.

Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). From data mining to knowledge discovery in databases. *AI magazine*, 17(3), 37-37.

Google Trends (2022a). *Interesse em machine learning e data science*. Mountain View: Google LLC, [2022] Disponível em: <https://trends.google.com/trends/explore?date=all&q=machine%20learning,data%20science>. Acesso em: 30 abr. 2022.

Google Trends (2022b). *Interesse em scrum e agile*. Mountain View: Google LLC, [2022] Disponível em: <https://trends.google.com/trends/explore?date=all&q=scrum,agile>. Acesso em: 30 abr. 2022.

Han, J., Kamber, M., & Pei, J. (2011). *Data mining: concepts and techniques*. 3rd ed. Burlington: Morgan Kaufmann Publishers.

Hiatt, J. (2006). *ADKAR: a model for change in business, government, and our community*. Prosci.

Malhotra, N. K. (2010). *Marketing research: An applied orientation*. 6th ed. New Jersey: Pearson Education.

Martínez-Plumed, F., Contreras-Ochando, L., Ferri, C., Hernández-Orallo, J., Kull, M., Lachiche, N., ... & Flach, P. (2019). CRISP-DM twenty years later: From data mining processes to data science trajectories. *IEEE Transactions on Knowledge and Data Engineering*, 33(8), 3048-3061.

Mello, F. S. H. (2018). *OKRs from Mission to Metrics: How Objectives and Key Results Can Help Your Company Achieve Great Things*. Independently published.

Mitchell, T. M., & Mitchell, T. M. (1997). *Machine learning* (Vol. 1, No. 9). New York: McGraw-hill.

Pathak, Y., Shukla, P. K., Tiwari, A., Stalin, S., & Singh, S. (2020). Deep transfer learning based classification model for COVID-19 disease. *IRBM*, 43(2), 87–92

Plotnikova, V., Dumas, M., & Milani, F. (2020). Adaptations of data mining methodologies: a systematic literature review. *PeerJ Computer Science*, 6, e267.

PMI (2017). *Agile practice guide*. Newton Square: Project Management Institute.

PMI (2018). *Guia do conhecimento em gerenciamento de projetos*. 6. ed. Newtown Square: Project Management Institute.

Royce, W. W. (1987). Managing the development of large software systems: concepts and techniques. In *Proceedings of the 9th international conference on Software Engineering* (pp. 328-338).

Saltz, J. S., & Hotz, N. (2020, December). Identifying the most common frameworks data science teams use to structure and coordinate their projects. In *2020 IEEE International Conference on Big Data (Big Data)* (pp. 2038-2042). IEEE.

Saltz, J., & Sutherland, A. (2019, December). SKI: an Agile framework for data science. In *2019 IEEE International Conference on Big Data (Big Data)* (pp. 3468-3476). IEEE.

Saltz, J. S. (2015, October). The need for new processes, methodologies and tools to support big data teams and improve big data project effectiveness. In *2015 IEEE International Conference on Big Data (Big Data)* (pp. 2066-2071). IEEE.

Saltz, J. S., & Krasteva, I. (2022). Current approaches for executing big data science projects—a systematic literature review. *PeerJ Computer Science*, 8, e862.

Saltz, J., & Crowston, K. (2017). Comparing data science project management methodologies via a controlled experiment. In *50th Hawaii International Conference on System Sciences*.

SAS Institute (2020). *Introduction to SEMMA*. Cary: SAS Institute. Disponível em: <https://documentation.sas.com/?docsetId=emref&docsetTarget=n061bzurmej4j3n1jnj8bbjjm1a2.htm&docsetVersion=15.2&locale=en>. Acesso em: 12 out. 2020.

Schwaber, K., & Sutherland, J. (2017). *The scrum guide*. Cambridge: Scrum.Org. Disponível em: <https://scrumguides.org/index.html> Acesso em: 10 out. 2021.

Shafique, U., & Qaiser, H. (2014). A comparative study of data mining process models (KDD, CRISP-DM and SEMMA). *International Journal of Innovation and Scientific Research*, 12(1), 217-222.

Takeuchi, H., & Nonaka, I. (1986). The new new product development game. *Harvard business review*, 64(1), 137-146.

Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data mining: practical machine learning tools and techniques with Java implementations*. 3rd ed. Burlington: Morgan Kaufmann Publishers.