

**CENTRO ESTADUAL DE EDUCAÇÃO TECNOLÓGICA PAULA SOUZA**  
**UNIDADE DE PÓS-GRADUAÇÃO, EXTENSÃO E PESQUISA**  
**MESTRADO PROFISSIONAL EM GESTÃO E TECNOLOGIA EM**  
**SISTEMAS PRODUTIVOS**

**ELCIO TARALLO**

**PROPOSTA DE UM ROADMAP DE UTILIZAÇÃO DE MACHINE LEARNING**  
**PARA PREVISÃO DE DEMANDA DE BENS DE CONSUMO**

**São Paulo**

**Julho/2020**

**ELCIO TARALLO**

**PROPOSTA DE UM ROADMAP DE UTILIZAÇÃO DE MACHINE LEARNING  
PARA PREVISÃO DE DEMANDA DE BENS DE CONSUMO**

Projeto de Dissertação apresentado como exigência parcial para a obtenção do título de Mestre em Gestão e Tecnologia em Sistemas Produtivos do Centro Estadual de Educação Tecnológica Paula Souza, no Programa de Mestrado Profissional em Gestão e Tecnologia em Sistemas Produtivos, sob a orientação do Prof. Dr. Napoleão Galegale.

**São Paulo**

**Julho/2020**

T176p

Tarallo, Elcio Antonio

Proposta de um roadmap de utilização de machine learning para previsão de demanda de bens de consumo / Elcio Antonio Tarallo. – São Paulo: CPS, 2020.  
84 f. : il.

Orientador: Prof. Dr. Napoleão Verardi Galeale

Dissertação (Mestrado Profissional em Gestão e Tecnologia em Sistemas Produtivos). – Centro Estadual de Educação Tecnológica Paula Souza, 2020.

1. Machine learning. 2. Previsão de demanda. 3. Bens de consumo rápido. 4. Roadmap de implementação de tecnologia. 5. Sistema Produtivo. I. Galeale, Napoleão Verardi. II. Centro Estadual de Educação Tecnológica Paula Souza. III. Título.

**ELCIO TARALLO**

**PROPOSTA DE UM ROADMAP DE UTILIZAÇÃO DE MACHINE LEARNING  
PARA PREVISÃO DE DEMANDA DE BENS DE CONSUMO**

---

Prof. Dr. Napoleão Galegale

---

Prof. Dr. Marcelo Duduchi Feitosa

---

Prof. Dr. Adilson Carlos Yoshikuni

São Paulo, 14 de julho de 2020

## **AGRADECIMENTOS**

Ao Walter Yogui, professor da FATEC, mestre pelo Centro Paula Souza, doutorando pela USP, colega de trabalho por alguns anos e amigo de todas as horas, pelas orientações e apoio desde o interesse inicial em cursar o mestrado de Sistemas Produtivos.

Ao Carlos França, colega de trabalho e amigo que indicou empresas e pessoas que tornaram possível a realização da pesquisa.

Ao Bento Ribeiro, empresário e entusiasta da tecnologia de Machine Learning, cujo apoio dado para a elaboração da pesquisa, apenas pela intenção de compartilhar conhecimento e incentivar a pesquisa, viabilizou o projeto.

Ao professor Getúlio Akabane pelas orientações práticas e metas desafiadoras que resultaram em publicação de artigo em revista internacional de prestígio.

Ao professor e orientador Napoleão Galeale pelo talento e flexibilidade para dirigir o trabalho e as mudanças dentro do período estabelecido.

À minha esposa Elaine Tarallo, pelo incentivo desde o primeiro momento de contato com o mestrado até a compreensão pelos períodos de ausência nos eventos familiares.

## RESUMO

TARALLO, E.A. **Proposta de um Roadmap de Utilização de Machine Learning para Previsão de Demanda de Bens De Consumo**. 84 f. Dissertação (Mestrado Profissional em Gestão e Tecnologia em Sistemas Produtivos). Centro Estadual de Educação Tecnológica Paula Souza, São Paulo, 2020.

Pesquisas de mercado mostram grande interesse das empresas em utilizar Machine Learning (ML) para melhorar a acurácia das previsões de demanda, especialmente no setor de bens de consumo em que o ciclo de vida dos produtos é curto, obtendo benefícios como melhor equilíbrio de estoques, redução de ruptura (falta de produtos nos pontos de venda) e redução de perdas por data de validade. Porém, cerca de metade das empresas pesquisadas ainda não tem projetos concluídos nem em andamento, pretendendo iniciar nos próximos anos, sendo uma das principais dificuldades a falta de direcionamento adequado de como implementar soluções de previsão de demanda com ML. Nota-se no mercado e na academia inúmeros trabalhos direcionando sistemas de gestão empresarial (ERP) e relativamente poucos estudos acerca de sistemas analíticos e ML. O objetivo deste trabalho é propor um *roadmap* para implementação de ML aplicado à previsão de demanda de bens de consumo em um sistema produtivo, que facilite a adoção e antecipe a realização de benefícios. A metodologia Design Science Research Method (DSRM) foi utilizada para elaborar, demonstrar e avaliar o *roadmap* em um caso real junto a uma empresa cliente de um provedor de sistemas de ML situada no Estado de São Paulo. Os resultados do estudo mostram que o *roadmap* proposto atingiu os objetivos esperados, facilitando a implementação ao servir de orientação aos envolvidos, reduzindo riscos de baixa qualidade e não atingimento das metas de negócio pela inclusão de controles de qualidade e de prova de conceito, promovendo a utilização efetiva da solução implementada ao engajar líderes e representantes das áreas de negócio. Este estudo contribui com as empresas de bens de consumo para adoção bem sucedida de ML aplicado à gestão de demanda e com a literatura acadêmica pela extensão do conhecimento da ciência de dados ao apresentar um *roadmap* para implementação do ML na previsão de demanda de bens de consumo.

**Palavras-chave:** Machine Learning. Previsão de demanda. Bens de consumo rápido. *Roadmap* de implementação de tecnologia. Sistema Produtivo.

## ABSTRACT

TARALLO, E.A. **Proposed a Roadmap for the Use of Machine Learning to Forecast Demand for Consumer Goods.** 84 f. Dissertation (Professional Master in Management and Technology in Productive Systems). Paula Souza State Technological Education Center, São Paulo, 2020.

Market research shows that companies are very interested in using Machine Learning (ML) to improve its demand forecasts accuracy, especially in the consumer goods sector where the products life cycle is short, obtaining benefits such as better inventories balance, stockouts reduction in points of sale and reduction of losses by expiration date. However, about half of the companies surveyed still do not have completed or even ongoing projects, intending to start in the coming years. One of the main difficulties is the lack of adequate guidance on how to implement demand forecasting solutions with ML. There are countless studies in the market and in the academy directing business management systems (ERP) and relatively few studies about analytical and ML systems. The objective of this work is to propose a roadmap for ML implementation applied to demand forecast for consumer goods in a productive system, which facilitates the adoption and anticipates the benefits realization. The Design Science Research Method (DSRM) methodology was used to develop, demonstrate, and evaluate the roadmap in a real case with a client company of an ML systems provider located in the state of São Paulo. The results of the study show that the proposed roadmap achieved the expected objectives, facilitating implementation by serving as guidance to those involved, reducing risks of low quality and not reaching business goals by including quality controls and proof of concept, promoting the effective use of the implemented solution by engaging leaders and representatives of the business areas. This study contributes to consumer goods companies for successful adoption of ML applied to demand management and to the academy by extending the data science knowledge by presenting a roadmap for implementing ML in consumer goods demand forecasting.

Keywords: Machine Learning. Demand forecast. Fast consumer goods. Technology implementation roadmap. Productive System.

## LISTA DE QUADROS

Quadro 1:	Passos da Pesquisa Bibliográfica .....	16
Quadro 2:	Histórico de Pesquisas sobre Benefícios do ML aplicado à previsão de demanda de bens de consumo .....	21
Quadro 3:	Questões sobre a efetividade do uso do <i>roadmap</i> .....	38
Quadro 4:	Modelo de avaliação de dificuldades e facilitadores de implementação x <i>roadmap</i> .....	39
Quadro 5:	Resultados de negócio obtidos com a implementação da solução de ML .....	45
Quadro 6:	Perfil do time de implementação .....	69
Quadro 7:	Questões de avaliação do artefato <i>roadmap</i> .....	70
Quadro 8:	Pontuação do uso do <i>roadmap</i> .....	72
Quadro 9:	Resultados da avaliação de dificuldades e facilitadores de implementação x <i>roadmap</i> .....	73



## LISTA DE FIGURAS

Figura 1:	Produção e crescimento anual de pesquisas sobre ML .....	17
Figura 2:	Produção total de 2010 a 2017 sobre ML por país .....	17
Figura 3:	ML para previsão de demanda de bens de consumo .....	18
Figura 4:	Distribuição dos artigos por setor de mercado .....	18
Figura 5:	<i>Roadmap</i> estratégico de negócios e tecnologia de uma organização .....	25
Figura 6:	Modelo de <i>roadmap</i> de implementação de inovação .....	26
Figura 7:	Metodologia IBM Analytics Solutions Unified Method (ASUM) .....	28
Figura 8:	Dados e progressão do ML para melhor planejamento de demanda .....	30
Figura 9:	Ciclo de Vida de processo de Ciência de Dados Microsoft TDSP .....	31
Figura 10:	<i>Roadmap</i> com tarefas e artefatos da metodologia Microsoft TDSP .....	32
Figura 11:	Modelo de indicadores de resultados do ML após implementação .....	36
Figura 12:	Visão geral das etapas da DSRM .....	40
Figura 13:	Estrutura do <i>roadmap</i> proposto .....	47
Figura 14:	Conceitos utilizados para a elaboração da estrutura do <i>roadmap</i> proposto.....	47
Figura 15:	<i>Roadmap</i> típico de projetos de ciência de dados .....	49
Figura 16:	<i>Roadmap</i> proposto de utilização de Machine Learning para previsão de demanda de bens de consumo .....	50
Figura 17:	Relação entre <i>roadmap</i> estratégico no nível de empresa x <i>roadmap</i> de implementação .....	51
Figura 18:	Objetivos de negócio da solução de ML.....	67
Figura 19:	Fluxo de dados e interfaces do sistema implantado com uso do <i>roadmap</i> .....	68

## LISTA DE SIGLAS

ANN	Artificial Neural Network ou redes neurais artificiais
CSP	Cloud Service Provider ou fornecedor de serviços em nuvem
DSRM	Design Science Research Method: método de pesquisa Design Science
ERP	Enterprise Resource Planning ou sistema de gestão empresarial
FMCG	Fast Moving Consumer Goods: produtos de consumo rápido
IA	Inteligência Artificial
IOT	Internet of things: internet das coisas
ML	Machine Learning: aprendizado de máquina
PMI	Project Management Institute
POC	Proof of Concept: prova de conceito
SKU	Stock Keeping Unit: unidade de controle de estoque
TI	Tecnologia da Informação

## SUMÁRIO

INTRODUÇÃO .....	12
<b>1 FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>14</b>
1.1 A previsão de demanda nos negócios de bens de consumo .....	14
1.2 O Machine Learning e a evolução das pesquisas sobre a aplicação em previsão de demanda .....	15
1.3 Ganhos obtidos com o ML aplicado à previsão de demanda de bens de consumo .....	18
1.4 Desafios para implementação e a abordagem de <i>roadmap</i> .....	23
1.5 Situação atual da implementação de sistemas analíticos e uso de <i>roadmaps</i> .....	28
<b>2 METODOLOGIA .....</b>	<b>34</b>
2.1 A DSRM .....	34
2.2 Etapa 1 - Identificação do problema e motivações .....	34
2.3 Etapa 2 - Definição dos objetivos de uma solução .....	37
2.4 Etapa 3 - Projeto e desenvolvimento .....	37
2.5 Etapa 4 - Demonstração .....	37
2.6 Etapa 5 - Avaliação .....	38
2.7 Etapa 6 - Comunicação .....	39
2.8 Visão geral .....	39
<b>3 RESULTADOS E DISCUSSÃO DAS ETAPAS DA DSRM .....</b>	<b>41</b>
3.1 Etapa 1 - Problema e motivações .....	41
3.2 Etapa 2 - Objetivos do <i>roadmap</i> de implementação de ML .....	45
3.3 Etapa 3 - Elaboração do artefato <i>roadmap</i> .....	46
3.4 Etapa 4 - Demonstração em campo .....	66
3.5 Etapa 5 - Avaliação pelos envolvidos .....	70
3.6 Etapa 6 - Comunicação ao meio acadêmico e ao mercado .....	73
<b>4 CONSIDERAÇÕES FINAIS .....</b>	<b>74</b>
4.1 <i>Roadmap</i> como facilitador de implementação de sistemas de ML .....	74
4.2 Ganhos de negócio pelo uso de ML na previsão de demanda de bens de consumo .....	77
4.3 Contribuições .....	77
REFERÊNCIAS .....	79

## INTRODUÇÃO

A previsão de demanda é fator crítico de sucesso para as empresas, sendo um componente básico para o planejamento da produção e para a gestão da cadeia de suprimentos, com impacto na competitividade e lucratividade, constituindo informações críticas para decisões de compras, produção, nível de estoques, logística, finanças e marketing (BERTAGLIA, 2016; YUE *et al.*, 2016; MARTÍNEZ *et al.*, 2018; ARVAN *et al.*, 2018).

Bons planejamentos de demanda são ainda mais importantes para o setor de bens de consumo, em que o ciclo de vida dos produtos torna-se cada vez mais curto, além da tendência de individualização e diferenciação, tornando os padrões de demanda mais voláteis e mais difíceis de prever, ao mesmo tempo que as empresas procuram incrementar a acurácia e a confiabilidade dos sistemas de previsão de demanda. Neste cenário, segundo os autores, é necessária a busca por métodos de previsão capazes de tratar grandes variações e relações complexas entre fatores de demanda (MAAß *et al.*, 2014).

Wilson (2018) confirma a busca de novos métodos pelos planejadores de demanda destacando que os elementos que motivam o grande interesse em ML são as novas tecnologias de ML e a capacidade de aplicar automaticamente cálculos matemáticos complexos a um conjunto muito grande de dados (*Big Data*) repetidamente e em velocidades mais rápidas. Sua pesquisa com profissionais de planejamento e previsão questionou quais avanços tecnológicos nos próximos sete anos, até 2025, terão maior impacto nas previsões e no planejamento da demanda, obtendo como resposta de quase 70% dos 200 entrevistados o ML e a Inteligência Artificial (IA).

Na mesma direção, Payne (2018) identificou em sua pesquisa sobre o uso de tecnologias de ML nos processos de Gestão da Cadeia de Suprimentos, com 260 empresas respondentes, que o processo de previsão de demanda é o mais utilizado atualmente pela maioria (45%) e que 43% pretendem adotar em até dois anos, ressaltando que os usuários finais querem obter melhores planos de demanda, com maior acurácia, mas, sem exigir tempo demasiado dos profissionais de planejamento para o sucesso do sistema.

Proctor e Fowler (2019) também mostram o interesse das empresas pelo ML, mas, com uma adoção mais cautelosa por líderes de áreas de Gestão da Cadeia de Suprimentos de 200 empresas, com 14% de projetos ativos, 16% para início em até um ano e 22% em consideração, mas, sem data prevista para início, sendo que 40% das empresas que pretendem adotar ML acreditam que esta tecnologia irá melhorar a acuracidade das previsões.

Embora as pesquisas de mercado mostrem a tendência das empresas em utilizar o ML para aprimorar o planejamento da demanda, alguns autores apresentam desafios para a implementação de soluções.

Tsoumakas (2018) cita algumas dificuldades para adoção do ML para previsão de vendas, como a eventual indisponibilidade de informações históricas detalhadas, o grande número disponível de algoritmos de aprendizado que pode dificultar a escolha e soluções de software que requerem extensa customização, destacando que em grande parte das empresas a função de estimativa da demanda é realizada por especialistas com pouco ou nenhum apoio de sistemas especializados.

Já Crews (2019) aponta problemas de natureza humana e organizacional para a utilização de soluções de previsão de demanda com ML, devido ao baixo engajamento nos projetos de implementação dos principais responsáveis por esta função nas organizações, dificultando a implementação e o uso efetivo posterior pelas áreas de negócio.

Sapp (2018) mostra mais uma razão pela qual as organizações não adotaram ML e IA, por meio de estudos recentes que indicam que três dos cinco principais motivos estão relacionadas à incapacidade de articular um *roadmap* que defina a estratégia e o plano de implementação destas tecnologias.

Assim, a questão de pesquisa norteadora deste trabalho pode ser expressa da seguinte forma: Como obter melhores resultados em projetos de implementação da tecnologia de ML na previsão de demanda de bens de consumo por meio da utilização de um *roadmap*?

Desta forma, em função dos potenciais benefícios, do grande interesse pelas empresas e das dificuldades encontradas, o objetivo deste estudo é propor um *roadmap* para implementação da tecnologia de ML aplicada à previsão de demanda de bens de consumo em um sistema produtivo. Em complemento, foram definidos como objetivos específicos: (i) elaborar o referencial teórico de suporte à pesquisa, (ii) delinear o problema e as motivações para sua solução, (iii) desenvolver o *roadmap*, (iv) demonstrar a efetividade de sua aplicação em campo (caso real), e (v) avaliar a sua utilização.

Foi utilizado como abordagem metodológica para a consecução dos objetivos, o *Design Science Research Method* (DSRM) apoiado por uma pesquisa de campo.

Dessa forma o estudo pretende contribuir com as empresas do setor de bens de consumo facilitando a implementação de uma solução sistêmica de uso contínuo que traga resultados de negócio. O *roadmap* sugerido pretende contribuir com a academia pela extensão do conhecimento para implementação de soluções de ciência de dados com ML.

## 1 FUNDAMENTAÇÃO TEÓRICA

Este capítulo contém o referencial teórico com as dimensões da pesquisa, explorando a importância da previsão de demanda para os negócios de bens de consumo, apresentando a evolução das pesquisas sobre o tema, analisando estudos quanto aos ganhos proporcionados aos diversos tipos de produtos, apresentando a abordagem de *roadmap* de implementação e, finalmente, a situação atual de mercado.

### 1.1 A previsão de demanda nos negócios de bens de consumo

Esta seção apresenta a relevância da previsão de demanda para os negócios de bens de consumo.

Nos negócios em geral, Christopher e Lee (2004) destacam a importância da acurácia na previsão de vendas e seu impacto na gestão da cadeia de suprimentos, mencionando que previsões incorretas geram ineficiência na cadeia podendo aumentar os custos quando a solução adotada pelas empresas para evitar indisponibilidade de produtos é aumentar os estoques.

No setor de bens de consumo, diversos autores destacam as características que tornam ainda mais relevante para os negócios uma boa previsão de demanda.

Nagashima *et al.* (2015), alertam que aumentar estoques em função da falta de uma previsão de demanda mais precisa tem maior impacto nos custos de empresas de produtos como bens de consumo eletrônicos, que têm menor margem de lucro e perdem valor rapidamente. De forma semelhante, os segmentos de moda, vestuário e calçados, entre outros, têm curto ciclo de vida e alta volatilidade de demanda, sendo uma difícil tarefa para os gerentes de vendas, produção e cadeia de suprimentos, prever com acurácia os volumes de vendas (NAGASHIMA *et al.* 2015; YUE *et al.*, 2016).

Tratando-se do setor de varejo de alimentos em geral, a principal causa de desperdício e de ruptura de estoques (falta de produtos) é a imprecisão da previsão de vendas que conduz à pedidos incorretos (ARUNRAJ; AHRENS, 2015). Mais especificamente na indústria de alimentos frescos, incluindo os refrigerados, como laticínios, frutas e sucos, o curto prazo de validade e a necessidade de manter a qualidade nos processos de estocagem e distribuição fazem com que a precisão na previsão de vendas seja um item importante para planejar a produção, minimizar vendas perdidas por falta de produtos, reduzir devoluções por proximidade do fim de validade e melhorar a disponibilidade aos clientes, refletindo, em consequência, nos

resultados da empresa e eventualmente na redução de danos ao meio ambiente quando, por exemplo, evita-se o descarte pela perda do prazo de validade (DOGANIS *et al.*, 2005).

Ochiai (2015), complementa que a precisão na previsão de demanda de alimentos frescos melhora a eficiência da gestão dos pedidos e estoques, possibilitando obter uma redução do volume de descarte em cerca de 40% pelos varejistas deste segmento.

Há ainda uma categoria de bens de consumo com ciclo de vida mais curto, denominada Fast-Moving Consumer Goods (FMCG), ou produtos de consumo rápido, como os alimentos processados, bebidas, enlatados, refrigerantes, salgadinhos, doces e chocolates, bem como produtos de higiene pessoal e limpeza. A vida útil curta se dá em função de rápida deterioração, como carnes, frutas, legumes e produtos lácteos, que são altamente perecíveis, ou, eletrônicos e moda com rápida obsolescência que são atualizados frequentemente e possuem muitas alternativas concorrentes (COHEN *et al.*, 2017).

## **1.2 O Machine Learning e a evolução das pesquisas sobre a aplicação em previsão de demanda**

Esta seção apresenta a definição de ML e uma breve visão histórica dos estudos sobre a aplicação do ML para previsão de demanda, de 2010 a 2017, por meio de uma pesquisa bibliométrica.

O ML é classificado por Michalski, Carbonell e Mitchell (1983), em três formas de aprendizado de máquina: a engenharia de sistemas para aprender em aplicações específicas, a análise de algoritmos de aprendizagem e a simulação de processos de aprendizagem humana.

Com a evolução do ML uma miríade de algoritmos foi criada ao longo do tempo, podendo ser divididas em quatro categorias principais: a) Supervised Learning: assume dados completamente rotulados em termos de pares de entrada e saída para treinar um algoritmo individual, b) Unsupervised Learning: tenta encontrar estruturas em dados não rotulados, c) Semi-Supervised Learning: opera com uma mistura de dados rotulados e não rotulados, e d) Reinforcement Learning: baseia-se na ideia de maximizar uma função de recompensa, otimizando ações específicas em um determinado conjunto de parâmetros (MOHRI *et al.*, 2012).

Uma forma de aprendizado de máquina mais poderosa, de conceitos mais complexos, é apresentada por Goodfellow, Bengio e Courville (2015), denominada Deep Learning (DL), que segundo os autores permite aos computadores aprender com a experiência sem necessidade de especificação do conhecimento por um operador humano, entendendo o mundo em termos de uma hierarquia de conceitos com camadas profundas construídas umas sobre as outras.

De fato, Akabane (2018) cita que as redes neurais, o ML e o DL fazem parte do conjunto das tecnologias denominadas cognitivas, que tentam imitar o pensamento humano, capazes de manipular grandes quantidades de informação e de efetuar análises sem preconceitos, de forma impessoal, podendo ser aplicadas em processos de negócio, produtos e na visão organizacional.

Com o objetivo de identificar o interesse da academia pelo tema e a evolução dos estudos sobre a aplicação do ML na previsão de demanda de bens de consumo, bem como quais setores foram contemplados, foi realizada uma pesquisa bibliométrica de artigos nas bases Scopus Elsevier e Web of Science, abrangendo o período de 2010 a 2017, apresentada a seguir. Trinta publicações foram selecionadas para uma revisão sobre os principais benefícios obtidos apresentada na próxima seção.

Os passos percorridos para a análise bibliométrica e seleção de artigos para revisão foram: 1) selecionar artigos com ML; 2) identificar bens de consumo nos artigos com ML; 3) filtrar os que mencionam previsão de demanda e de vendas; 4) excluir artigos duplicados e fora do escopo de análise. Os detalhes de cada passo podem ser vistos no Quadro 1.


**Quadro 1 – Passos da pesquisa bibliográfica**

Passo	Tema	Linguagem de consulta Scopus	Artigos	Linguagem de consulta Web of Science	Artigos
1	Machine Learning	TITLE-ABS-KEY ( "machine learning" OR "learning machine" ) AND DOCTYPE ( ar OR re ) AND PUBYEAR > 2009 AND PUBYEAR < 2018	33925	TÓPICO:( "machine learning" or "learning machine" ) Tempo estipulado: 2010-2017.Índices: SCI-EXPANDED, SSCI, A&HCI, CPCI-S, CPCI-SSH, ESCI.	49914
2	Bens de Consumo	( TITLE-ABS-KEY ( "machine learning" OR "learning machine" ) AND TITLE-ABS-KEY ( product OR goods ) AND DOCTYPE ( ar OR re ) AND PUBYEAR > 2009 AND PUBYEAR < 2018 )	1085	TÓPICO:( "machine learning" or "learning machine" ) AND TÓPICO: ( product or goods ) Tempo estipulado: 2010-2017.Índices: SCI-EXPANDED, SSCI, A&HCI, CPCI-S, CPCI-SSH, ESCI.	4961
3	Previsão de Demanda e Vendas	( TITLE-ABS-KEY ( "machine learning" OR "learning machine" ) AND TITLE-ABS-KEY ( product OR goods ) AND TITLE-ABS-KEY ( "sales forecasting" OR "demand forecasting" OR "demand prediction" OR "forecasting of demand" OR "sales prediction" OR "sales promotion" OR "products sales" OR "product's demand" OR "purchase decisions" ) AND DOCTYPE ( ar OR re ) AND PUBYEAR > 2009 AND PUBYEAR < 2018 )	25	TÓPICO:( "machine learning" or "learning machine" ) AND TÓPICO: ( product or goods ) AND TÓPICO: ( "sales forecasting" or "demand forecasting" OR "demand prediction" or "forecasting of demand" or "sales prediction" or "sales promotion" or "products sales" or "product's demand" or "purchase decisions" ) Tempo estipulado: 2010-2017.Índices: SCI-EXPANDED, SSCI, A&HCI, CPCI-S, CPCI-SSH, ESCI.	36
4	Fora do escopo	( TITLE-ABS-KEY ( "consumer review" OR "customer review" OR "online review" OR "product review" OR "sentiment analysis" OR "word of mouth" OR "recommender system" OR "collaborative filtering" OR passenger OR temperature OR "electric power" OR oil OR "context understanding" ) AND DOCTYPE ( ar OR re ) AND PUBYEAR > 2009 AND PUBYEAR < 2018 ) Obs: 8 artigos selecionados foram excluídos.	17	TÓPICO:( "consumer review" or "customer review" or "online review" or "product review" or "sentiment analysis" or "word of mouth" or "recommender system" or "collaborative filtering" or passenger or temperature or "electric power" or oil or "context understanding" ) Tempo estipulado: 2010-2017.Índices: SCI-EXPANDED, SSCI, A&HCI, CPCI-S, CPCI-SSH, ESCI. Obs: 12 artigos selecionados foram excluídos e 11 duplicados	13

**Fonte:** Resultados da pesquisa, 2020.


A pesquisa para ML em geral apresenta expressivo crescimento anual, mais de 20%, tanto na base Scopus quanto na Web of Science (Figura 1).



**Figura 1 – Produção e crescimento anual de pesquisas sobre ML**


**Fonte:** Resultados da pesquisa, 2020.

A Figura 2 mostra a produção por país destacando-se Estados Unidos e China com produção maior que o dobro de artigos em relação ao 3º e 4º colocados (Reino Unido e Índia). O Brasil aparece na 14ª posição.

**Figura 2 – Produção total de 2010 a 2017 sobre ML por país**


**Fonte:** Resultados da pesquisa, 2020.

Os resultados da pesquisa bibliométrica sobre ML para previsão de demanda de bens de consumo mostra produção crescente até 2012, queda em 2013, retomando o crescimento de 2014 a 2017 (Figura 3). Embora tenha havido um decréscimo em 2013, por motivos não identificados, permanece a tendência de crescimento das pesquisas sobre o tema.

**Figura 3 – ML para previsão de demanda de bens de consumo**

**Fonte:** Resultados da pesquisa, 2020.

A distribuição dos setores de mercado citados nos artigos selecionados pode ser vista na Figura 4, mostrando a maior incidência de estudos (51%) para os segmentos de moda e tecnologia, seguidos por varejo em geral (27%), alimentos de curta validade (12%) e alimentos e bebidas (9%).

**Figura 4 – Distribuição dos artigos por setor de mercado**

**Fonte:** Resultados da pesquisa, 2020.

### 1.3 Ganhos obtidos com o ML aplicado à previsão de demanda de bens de consumo

Os artigos selecionados a partir da análise bibliométrica são analisados nesta seção, acerca dos ganhos do ML quando aplicado aos processos de gestão de demanda de diversos tipos de produtos de consumo. Os trinta artigos selecionados foram consolidados no Quadro 2, com o objetivo de facilitar a consulta sobre as características e resultados obtidos em cada estudo, contendo: ano de publicação, quantidade de citações, autores, título, tipo de negócio

tratado, desafios de negócio endereçados com a solução de ML, benefícios obtidos com a aplicação do ML, técnicas e variáveis de dados utilizadas.

Segundo Kandananond (2012), as previsões de demanda com ML resultam em maior qualidade em relação às técnicas tradicionais, incluindo abordagens conhecidas como o modelo ARIMA (Autoregressive Integrated Moving Average), sobretudo para bens de consumo e com hierarquias complexas de produtos, apresentando menores desvios de erro. Tsoumakas (2018) afirma que as técnicas de aprendizado de máquina são mais eficazes e flexíveis do que as técnicas estatísticas tradicionais para prever séries temporais, porque elas têm maior poder de processamento e capacidade de lidar com variáveis adicionais. Da Silva *et al.* (2017) comenta sobre a utilização de ferramentas para previsão, destacando que é comum a aplicação de métodos de séries temporais em dados históricos de vendas com boa precisão, mas, técnicas estatísticas tradicionais não são as mais adequadas por considerarem que a relação entre as variáveis de entrada e saída é linear (regressão linear), o que geralmente não corresponde à realidade, sugerindo a aplicação de métodos baseados em redes neurais artificiais.

Várias técnicas de aprendizado de máquina são apresentadas pelos autores para obter melhores previsões de vendas. Chen e Ou (2011), utilizaram Extreme Learning Machine (ELM). Já Islek e Oguducu (2015), desenvolveram uma metodologia para previsão de demanda baseada em redes bayesianas. No varejo online, Ponce, Miralles e Martinez (2015), compararam técnicas tradicionais de ML com Artificial Hydrocarbon Networks, que é uma técnica de aprendizado supervisionado. Técnicas de reconhecimento de imagens foram aplicados por Wang *et al.* (2015), por meio de Support Vector Machine (SVM), que são modelos de aprendizagem supervisionados com algoritmos de aprendizagem associados. Kaneko e Yada (2016), aplicaram técnicas de DL alcançando alto nível de precisão na previsão de vendas.

No setor de tecnologia, Lu e Shao (2012), destacam a aplicação de algoritmos de ELM na previsão de vendas mais precisas, resultando na melhora do processo de reabastecimento de uma rede de lojas e acessórios de computação, cuja característica é de obsolescência tecnológica. Lee, Kim, Park e Kang (2014) desenvolveram um modelo de previsão de vendas de produtos inovadores à época (TVs 3D) cuja tecnologia não tinha histórico de vendas, utilizando uma abordagem conjunta de técnicas de ML que resultou em maior acurácia do que outras técnicas disponíveis. Melhorias nas previsões de vendas e na gestão de estoques de produtos de computação foram obtidas pelo uso de SVM combinado com outras técnicas (LU, 2014; LU e CHANG, 2014; CHEN e LU, 2017).

Na indústria de moda, Ren, Chan e Ram (2017) destacam que os produtos são fabricados, consumidos e descartados no curto prazo, a demanda é altamente volátil e a

localização dos estoques é descentralizada, afirmando que o ML para previsão de vendas mostrou resultados positivos pela maior rapidez e confiabilidade. Nessa direção, Yu, Choi e Hui (2011) atenderam a necessidade de negócio de uma loja online de produtos de moda para ter previsões de vendas mais rápidas e com maior frequência. Já Liu *et al.* (2013) mostram uma gestão mais apropriada de estoques para o setor de varejo de moda utilizando ELM. Choi (2014) desenvolveu um algoritmo com maior precisão e rapidez para tomada de decisões na gestão de vendas de varejo de moda. Tehrani e Ahrens (2016), reduziram perdas por descarte ao reduzir o índice de discrepância na previsão de vendas de itens de moda com alta escala de produção. Ganhos como aumento de receita e melhor gestão de estoque podem ser obtidos pela melhor previsibilidade de vendas de lançamentos e produtos sazonais com o uso do ML (FERREIRA, LEE E SIMCHI-LEVI, 2016; TEUCKE *et al.*, 2016).

No caso dos alimentos com curto prazo de validade, Chen e Ou (2011) desenvolveram um modelo de previsão baseado em redes neurais artificiais (ANN) para uma rede de lojas de alimentos perecíveis e refrigerados, destacando que a acurácia da previsão de demanda tem papel crucial para a lucratividade em operações de alimentos preservados em baixa temperatura. Nesse sentido, outros autores mostram redução de perdas com produtos derivados de leite e mercearia de alimentos aplicando técnicas como SVM e Heterogeneous Mixture Learning (DA SILVA *et al.*, 2017; OCHIAI, 2015). Em relação à indústria de alimentos e bebidas, Fujimaki *et al.* (2016) construíram um modelo que agrega ML para previsão de demanda à técnicas de otimização de preços, para uma empresa de varejo de bebidas, resultando em aumento de receita estimado em 16%. Já Tsoumakas (2018) apresenta as vantagens da utilização de técnicas de ML pelo setor de alimentos, como a minimização de estoques, a eliminação de produtos expirados nas lojas e redução de perda de vendas falta de produtos nos pontos de venda.

Comum aos diversos setores, as promoções de vendas são tratadas por alguns autores que enfatizam as dificuldades para obter maior previsibilidade em um ambiente dinâmico e complexo de ações promocionais simultâneas e concorrentes, apresentando em seus estudos os ganhos pelo uso do ML para produtos sazonais (cerveja), não sazonais (leite), outras bebidas e produtos de limpeza (SOGUERO *et al.*, 2012; PINHO, OLIVEIRA e RAMOS, 2016).

Finalmente, com vistas a obtenção de ganhos com o uso do ML em previsão de demanda a seleção de variáveis de dados a serem utilizadas nos modelos de previsão é crucial considerando que uma variedade de fatores influencia as vendas de um produto: seus próprios atributos, histórico de vendas, descontos concedidos, níveis de estoque, promoções, indicadores climáticos, indicadores econômicos, feriados e fatores regionais (GUO, WONG e LI, 2013; LU, 2014; QU *et al.*, 2017).

**Quadro 2 – Histórico de pesquisas sobre benefícios do ML aplicado à previsão de demanda de bens de consumo**

Se q.	Ano	Ci ta ções	Autores	Título	Tipo de Negócio	Desafios do Negócio	Benefícios	Técnicas de <i>Machine Learning</i> (ML)	Variáveis relevantes
1	2017		Da Silva I.D., Moura M.D.C., Didier Lins I., López Droguett E., Braga E.	Non-Stationary Demand Forecasting Based on Empirical Mode Decomposition and Support Vector Machines	logurtes	Curta validade dos produtos	Reduzir perdas	<i>Empirical Mode Decomposition</i> (EMD), <i>Particle Swarm Optimization</i> (PSO) e <i>Support Vector Machines</i> (SVM)	Histórico da demanda agregada de dois produtos: vol. de vendas, histórico de vendas de 2005 a 2009, em três capitais do Brasil.
2	2017		Lee T.-S., Lu C.-J., Cheng T.-F.	Hotel sales forecasting based on variable selection techniques and extreme learning machine	Hotel	Capacidade fixa, altos custos, inventário perecível	Maior eficácia de gerenciamento de vendas	<i>Stepwise Regression</i> , <i>Genetic Algorithm</i> , <i>Greedy Algorithm</i> e <i>Extreme Learning Machine</i> (ELM)	Histórico de vendas, indicadores macroeconômicos e indicadores técnicos
3	2017		Qu T., Zhang J.H., Chan F.T.S., Srivastava R.S., Tiwari M.K., Park W.-Y.	Demand prediction and price optimization for semi-luxury supermarket segment	Supermercado semi-luxo	Produtos de alto valor com demanda sazonal e suscetível	Previsão semanal da demanda	<i>Regression tree/Random forest</i>	Dados de vendas de lojas em dois anos e meio, incluindo feriados, descontos, estoque e fatores regionais
4	2017	1	Chen I.-F., Lu C.-J.	Sales forecasting by combining clustering and machine-learning techniques for computer retailing	Varejo de computadores	Desempenho de vendas e gestão de estoque	Melhora da acurácia da previsão de vendas	<i>Support Vector Regression</i> (SVR) e <i>Extreme Learning Machine</i> (ELM)	Dados reais de vendas de PCs, Notebooks e telas LCD
5	2017		Netisopakul P., Leenawong C.	Multiple linear regression using gradient descent: A case study on Thailand car sales	Indústria de automóveis	Planejamento de produção em função da flutuação na venda	Resultados semelhantes aos de ferramentas estatísticas	<i>Gradient Descent</i> (GD)	Histórico de dez anos de venda de carros, PIB, Taxa de empréstimo de 12 meses, estação do ano, eventos
6	2017		Ren, SY; Chan, HL; Ram, P	A Comparative Study on Fashion Demand Forecasting Models with Multiple Sources of Uncertainty	Varejo de moda <i>Fast Fashion</i>	Demanda altamente volátil e múltiplas unidades de estoque	Rapidez e confiabilidade da previsão de vendas	<i>Extreme Learning Machine</i> (ELM) e <i>Grey Model</i> (GM)	Histórico de vendas, pontos de venda
7	2016	17	Ferreira K.J., Lee B.H.A., Simchi-Levi D.	Analytics for an online retailer: Demand forecasting and price optimization	Loja <i>online</i> de moda	Previsão de demanda e precificação de produtos nunca vendidos (maioria)	Aumento da receita em 9,7% (decisões de preço multiproduto em base dia)	<i>Regression Tree</i> (previsão de demanda) e técnicas de otimização de preços	Histórico de vendas, estoque inicial, eventos de marca, estrutura hierárquica e atributos de produto
8	2016	3	Tehrani, AF; Ahrens, D	Enhanced predictive models for purchasing in the fashion field by using kernel machine regression equipped with ordinal logistic regression	Varejo de moda	Prever quais produtos terão altas vendas	Redução de perdas (write off) e aumento de receita	<i>Kernel Machines</i> e abordagem probabilística (robusta para <i>Outliers</i> )	Dados de vendas, catálogos
9	2016		Teucke, M; Ait-Alla, A; El-Berishy, N; Beheshti-Kashi, S; Lutjen, M	Forecasting of Seasonal Apparel Products	Indústria de moda	Obter previsões mais precisas a tempo de tomar decisões de produção & falta de histórico de vendas	Melhoria dos volumes de produção & Redução de falta ou de excedente de estoques	<i>Artificial Neural Network</i> (ANN), <i>Extreme Learning Machine</i> (ELM), <i>Evolutionary Neural Network</i> (ENN), combinação com <i>Fuzzy Logic</i>	Pedidos Antecipados dos varejistas (antes da produção), Pedidos durante o período de vendas
10	2016		Kaneko, Y; Yada, K	A Deep Learning Approach for the Prediction of Retail Store Sales	Lojas de Varejo	Melhor previsão de vendas e gerenciamento das lojas	Precisão de previsão de vendas de 86% (melhor que anterior)	<i>Deep Learning</i>	Dados diários de vendas de três anos dos pontos de venda
11	2016		Pinho, JM; Oliveira, JM; Ramos, P	Sales Forecasting in Retail Industry Based on Dynamic Regression Models	Varejo	Dificuldade para previsão de vendas em função das promoções	Melhor previsão de vendas considerando promoções	Modelo de Regressão Dinâmica	Dados de vendas de 3,5 anos de lojas de varejo
12	2016	1	Fujimaki R., Muraoka Y., Ito S., Yabe A.	From prediction to decision making - Predictive optimization technology	Varejo de bebidas	Melhorar confiabilidade de predições e tomada de decisões	Melhores previsões, aumento de vendas em 16% (estimado)	<i>Heterogeneous Mixture Learning Technology</i>	Histórico de vendas em loja
13	2015	1	Ochiai K.	Predictive analytics solution for fresh food demand using heterogeneous mixture learning technology	Mercearias com produtos de curta validade	Redução do custo de descarte de produtos não vendidos	Automação de pedidos, otimização de estoques nas lojas, redução de perda de alimentos	<i>Heterogeneous Mixture Learning Technology</i>	Desempenho de vendas por período, produtos descartados, produtos faltantes, clima e campanhas
14	2015	4	Wang Y., Chattaraman V., Kim H., Deshpande G.	Predicting Purchase Decisions Based on Spatio-Temporal Functional MRI Features Using Machine Learning	Diversos (prever decisões de compra de clientes)	Planejamento em função das decisões de compra do consumidor	Decisões com base na predição de estoques de compra dos clientes com 71% de acurácia	<i>Recursive Cluster Elimination based Support Vector Machine</i> (RCE-SVM)	Dados espaço-temporais de imagens de produtos (Ressonância magnética funcional-fMRI), sinais cerebrais, decisões
15	2015		Wu J., Zheng S.	Forecasting for fast fashion products based on web search data by using OS-ELM algorithm	Varejo de moda <i>Fast Fashion</i>	Demanda altamente volátil e ciclo de vida muito curto de produtos	Maior acurácia que modelos estatísticos tradicionais e prever o ponto de inflexão na tendência popular	<i>Extreme Learning Machine</i> (ELM)	Histórico de vendas, dados da internet (consumidores, tendências)
16	2015	1	Islek, I; Oguducu, SG	A Retail Demand Forecasting Model Based on Data Mining Techniques	Varejo (com depósitos de	Previsão de demanda de vários produtos e vários depósitos	Aumento considerável do desempenho e acurácia das	Algoritmo <i>Bayesian Network</i>	Tamanho da Região, armazém, quantidade de clientes, tipo de

					produtos distribuídos regionalmente)		previsões		produto
17	2015	1	Ponce, H; Miralles-Pechuan, L; Martinez-Villasenor, MD	Artificial Hydrocarbon Networks for Online Sales Prediction	Vendas de varejo online	Alta dinâmica e competição de mercado	Potencial de melhor previsão de vendas	<i>Artificial Hydrocarbon Networks (AHN)</i> - aprendizado supervisionado	Histórico de vendas online
18	2014	16	Lee H., Kim S.G., Park H.-W., Kang P.	Pre-launch new product demand forecasting using the Bass model: A statistical and machine learning-based approach	TV 3D	Previsão de demanda para novos produtos	Acurácia da previsão de demanda	<i>Multiple Linear Regression, K Nearest Neighbor Regression, Artificial Neural Networks, Support Vector Regression, Classification and Regression Tree, Gaussian Process Regression</i>	Dados de atributos de produto e difusão de produto
19	2014	28	Lu, CJ	Sales forecasting of computer products based on variable selection scheme and support vector regression	Varejo de produtos de computação	Produtos altamente substituíveis com mudanças drásticas de demanda	Melhorar eficácia do gerenciamento de vendas	<i>Multivariable Adaptive Regression Splines (MARS) e Support Vector Regression (SVR)</i>	Dados de vendas semanais e indicadores técnicos de mercado de ações
20	2014	28	Choi, TM; Hui, CL; Liu, N; Ng, SF; Yu, Y	Fast fashion sales forecasting with limited data and time	Varejo de moda (vendas rápidas)	Pouco tempo para tomada de decisões e previsões, dados limitados	Previsão de demanda para modelo de moda rápida ( <i>fast fashion</i> )	<i>Extreme Learning Machine (ELM) e Grey Model (GM)</i>	Dados de venda reais e artificiais
21	2014		Lu, CJ; Chang, CC	A Hybrid Sales Forecasting Scheme by Combining Independent Component Analysis with K-Means Clustering and Support Vector Regression	Venda de produtos de TI	Confiabilidade da previsão de vendas	Modelo de previsão melhor que os anteriores	<i>Independent Component Analysis (ICA), K-Means Clustering e Support Vector Regression (SVR)</i>	Dados de venda
22	2013	19	Guo Z.X., Wong W.K., Li M.	A multivariate intelligent decision-making model for retail sales forecasting	Varejo	Previsão de vendas mais precisas	Previsão de reabastecimento precisa melhorando a eficiência da cadeia de suprimentos	<i>Multivariate Intelligent Decision-Making Model (MID), Harmony Search-Wrapper-Based Variable Selection (HWVS) e Multivariate Intelligent Forecaster (MIF)</i>	Histórico de preço de venda, estilo, material, estratégia de promoção, quantidade comprada, data de saída, vida útil, volume inicial de vendas, clima, índice econômico
23	2013	2	Liu, N; Ren, SY; Choi, TM; Hui, CL; Ng, SF	Sales Forecasting for Fashion Retailing Service Industry: A Review	Varejo de moda	Previsão de vendas de produtos de muita volatilidade e curto ciclo de vida	Gestão apropriada de estoques	<i>Artificial NN (ANN), Fuzzy, Evolutionary NN (ENN), Extreme Learning Machine (ELM), Extended ELM (EELM)</i>	Dados de vendas, características de produtos, tendências de moda
24	2012	19	Lu C.-J., Shao Y.E.	Forecasting computer products sales by integrating ensemble empirical mode decomposition and extreme learning machine	Venda de produtos de computação	Demanda incerta, rápida obsolescência.	Acurácia, economia, competitividade, relacionamento canal e satisfação de clientes	<i>Ensemble Empirical Model Decomposition (EEMD) e Extreme Learning Machine (ELM)</i>	Dados de vendas dos produtos
25	2012		Guo, ZX; Li, M; Wong, WK; Guo, X	Intelligent multivariate sales forecasting using wrapper approach and neural networks	Varejo	Previsão de vendas com base em vendas antecipadas	Previsões superiores com <i>Extreme Learning Machine (ELM)</i>	<i>Harmony Search-Wrapper-based Variable Selection (HWVS) com Extreme Learning Machine (ELM)</i>	Vendas antecipadas, volumes de venda de produtos
26	2012	7	Lu, CJ; Shao, YJE	Forecasting Computer Products Sales by Integrating Ensemble Empirical Mode Decomposition and Extreme Learning Machine	Venda de produtos de computação	Acurácia na previsão de vendas	Superou outros quatro modelos de previsão de vendas de computadores	<i>Ensemble Empirical Model Decomposition (EEMD) e Extreme Learning Machine (ELM)</i>	Dados de venda de produtos
27	2012	2	Soguero-Ruiz C., Gimeno-Blanes F.-J., Mora-Jiménez I., Martínez-Ruiz M.P., Rojo-Álvarez J.-L.	On the differential benchmarking of promotional efficiency with machine learning modelling (II): Practical applications	Leite e Cerveja	Estimar vendas em ambiente complexo de atividades promocionais simultâneas e concorrentes	Maior previsibilidade de promoções (eficiência promocional)	<i>k-Nearest Neighbours, General Regression Neural Networks, Multilayer Perceptron (MLP), e Support Vector Machines (SVM)</i>	Dados de vendas, mudanças de preço, características de promoções
28	2012	5	Kandananond K.	A comparison of various forecasting methods for autocorrelated time series	Empresa de produtos de consumo	Dificuldade na previsão - estrutura complexa de produtos	Maior qualidade de previsão de vendas (SVM melhor que ANN e ARIMA)	<i>Artificial Neural Network (ANN) e Support Vector Machine (SVM)</i>	Demanda atual de seis produtos diferentes
29	2011	41	Yu Y., Choi T.-M., Hui C.-L.	An intelligent fast sales forecasting model for fashion products	Varejo de moda e Loja online de moda	Grande variedade de produtos (SKUs) e necessidade de previsão rápida	Previsão mais rápida	<i>Extreme Learning Machine (ELM)</i>	Volume de vendas, cores, tamanho, preço
30	2011	39	Chen F.L., Ou T.Y.	Sales forecasting system based on Gray extreme learning machine with Taguchi method in retail industry	Varejo	Melhorar acurácia da previsão de vendas: satisfação dos clientes, reduzir destruição de produtos, aumentar receita e planejar a produção.	Melhora na acurácia da previsão de vendas	<i>Gray relation analysis (GRA) e Extreme Learning Machine (ELM) ou GELM</i>	Dados de vendas reais e previsão do tempo

Fonte: Resultados da pesquisa, 2020.

#### 1.4 Desafios para implementação e a abordagem de *roadmap*

Os desafios encontrados pelas empresas para implementar de soluções de ML que possam trazer os ganhos esperados são apresentados nesta seção, destacando a abordagem de *roadmap* como ferramenta facilitadora.

Domingos (2012) estudou problemas comuns enfrentados por pesquisadores e desenvolvedores, destacando que o desenvolvimento bem-sucedido de aplicações de ML requer grande quantidade de “arte”, difícil de encontrar em manuais ou livros didáticos, destacando temas a serem considerados como: a escolha do algoritmo adequado, a utilização de vários modelos de aprendizado, a engenharia das funcionalidades, uma maior quantidade de dados é mais importante do que melhores algoritmos, entre outros.

Sun *et al.* (2017), ainda sobre questões técnicas, realizaram um estudo sobre os erros ocorridos em programas de ML, em função da disponibilidade de várias ferramentas e bibliotecas de código aberto, acessadas facilmente por desenvolvedores sem conhecer os detalhes do algoritmo. O estudo afirma que os mantenedores dessas ferramentas e bibliotecas têm mais foco na correção e na funcionalidade de seus algoritmos, do que na manutenção do código em um nível de alta qualidade, resultando em ferramentas de baixa qualidade que podem causar um enorme impacto nos produtos de software que usam algoritmos de ML.

Além dos temas técnicos, aspectos comportamentais e organizacionais que dificultam a implementação e a adoção de um sistema no dia-a-dia dos negócios são levantados por alguns autores.

Crews (2019) apresenta três problemas principais que afetam a implementação de soluções de ML para efetuar previsões de comportamento futuro, do mercado ou do consumidor, que são de natureza humana e organizacional: descrença nas previsões, falta de contexto estratégico e resistência à delegação da função de previsão. Para superar estes desafios o autor sugere o envolvimento dos líderes da organização, de especialistas em marketing, produtos e clientes, na definição, desenvolvimento dos algoritmos e interpretação dos resultados.

Proctor e Fowler (2019) identificaram em sua pesquisa com 200 empresas os principais obstáculos para implementar transformação digital na gestão da cadeia de suprimentos, incluindo ML e IA: 30% reportaram o medo das mudanças, 25% preocupam-se com a qualidade e/ou falta de dados e 24% têm aversão ao risco.

Complementando a análise dos desafios de implementação, alguns estudos definem como vital para viabilizar a implementação a existência de direcionadores estratégicos nas

empresas para o uso das tecnologias de ML e IA, bem como ferramentas de orientação para a implementação.

Sapp (2018) recomenda que para obter benefícios em problemas reais das empresas pelo uso de ML e IA é necessário definir uma estratégia de adoção, estabelecendo componentes fundamentais como planejar processos de gerenciamento e de qualidade de dados. Segundo o autor um *roadmap* de implementação é necessário, sugerindo uma estratégia construída a partir da experiência existente em análise de dados (Analytics) incorporando gradativamente novas tecnologias de ML e IA.

Na mesma direção, embora tratando-se de sistemas de gestão empresarial do tipo ERP (*Enterprise Resource Planning*), os profissionais precisam ser guiados por um *roadmap* coerente para a implementação bem sucedida de sistemas (CHOFREH *et al.*, 2014).

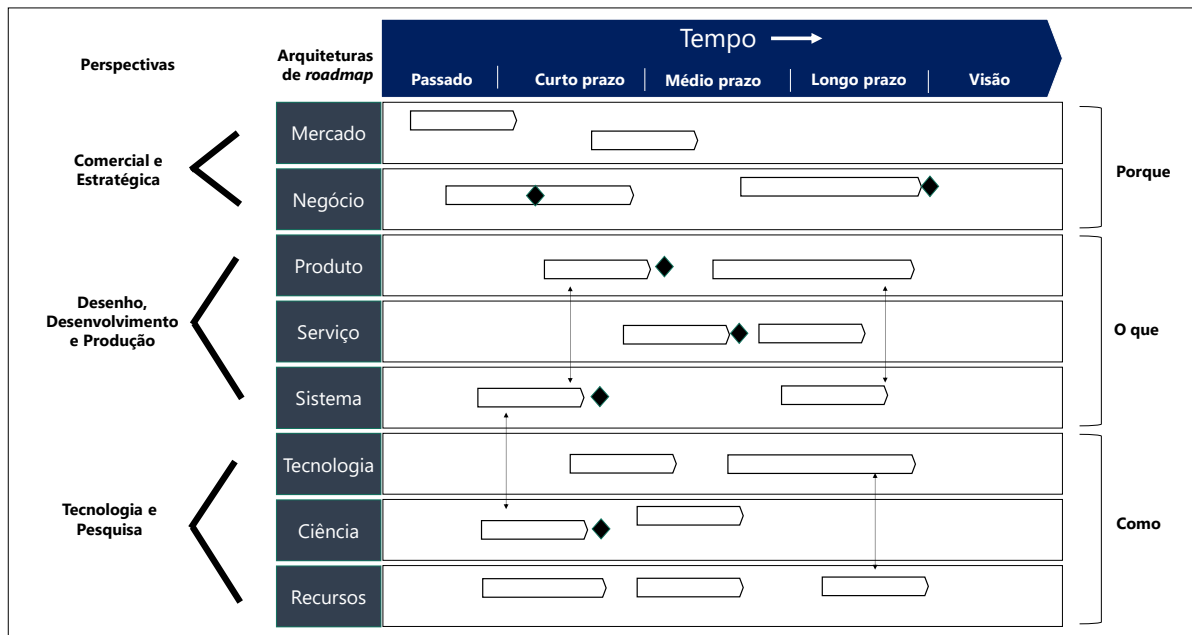
Os conceitos e tipos de *roadmap* são apresentados a seguir no sentido de avaliar como podem endereçar os desafios de implementação identificados.

A abordagem de *roadmapping*, segundo Laat e McKibbin (2003), tem sido adotada desde os anos 70 nos níveis de produto, tecnologia, empresa, setor e políticas, sendo um conceito flexível e escalável que pode ser customizado para atender diferentes contextos estratégicos e de inovação.

Nos aspectos de tecnologia e negócios, Phaal e Muller (2009) também destacam a flexibilidade como uma das principais vantagens da abordagem de *roadmap*, capaz de suportar diferentes assuntos em vários níveis de granularidade desde componentes de um sistema até setores de mercado e campos da ciência. Argumentam que um *roadmap* pode assumir várias formas, embora a mais utilizada seja a estrutura em um gráfico visual de múltiplas camadas baseado no tempo, permitindo que as várias funções e perspectivas de uma organização sejam alinhadas e fornecendo um modelo estruturado para abordar três questões principais: para onde queremos ir, onde estamos agora e como podemos chegar lá (Figura 5).



**Figura 5 – Roadmap estratégico de negócios e tecnologia de uma organização**



**Fonte:** Adaptado de Phaál e Muller, 2009.

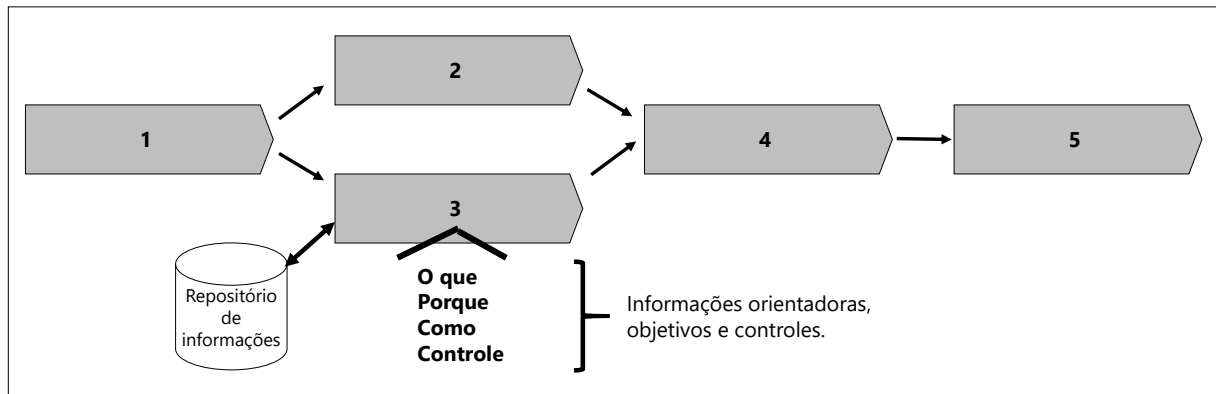
Giebel *et al.* (2009) propõem a integração da abordagem *quality gates* aos *roadmaps* dos ciclos de vida de empresas e produtos, baseada nos métodos de controle de qualidade e *stage gates* desenvolvida no final dos anos 80: *quality gates* são pontos de controle, orientados a resultados em processos de desenvolvimento e de negócios, controlando o cumprimento de objetivos predefinidos. Os autores postulam que a integração dos *quality gates* aos *roadmaps* podem facilitar o processo de inovação por: selecionar o local correto dos pontos de controle; selecionar e avaliar os critérios corretos em cada ponto de controle; aplicar regras apropriadas para as decisões nos pontos de controle; apoiar a criatividade e aumentar a velocidade, melhorando a qualidade e minimizando o retrabalho.

Alguns autores destacam o caráter estratégico dos *roadmaps*, orientados para suportar as iniciativas estratégicas e de inovação das organizações nos estágios iniciais do processo de inovação, sendo o gerenciamento de projetos indicado para apoiar a implementação das soluções habilitadoras do plano estratégico, embora a semelhança entre as arquiteturas permita que um *roadmap* estratégico evolua para um plano de projeto (PHAAL; MULLER, 2009; MOEHRLE; ISENMANN; PHAAL, 2013)

Já Perry e Uys (2010) consideram os *roadmaps* para iniciativas de inovação em diversos níveis, além do estratégico, definindo-os como roteiros construídos em etapas que fornecem uma estrutura orientadora para equipes de projetos colaborativas, facilitando a execução de um

conjunto de atividades predefinidas de alto nível para alcançar objetivos comuns. Segundo os autores um *roadmap* pode suportar atividades como: o planejamento para inovação, a implementação da inovação, a gestão do conhecimento e a gestão do ciclo de vida do objeto da inovação (empresa, produto, tecnologia, projeto, etc.), podendo haver relação entre eles quando um *roadmap* faz parte de outro. Um modelo de *roadmap* (Figura 6) é proposto pelos autores com os seguintes elementos: a) uma estrutura de alto nível que consiste nos sinalizadores ou pontos de passagem desejados ("onde"); b) objetivos indicando "o que" almejar para alcançar um ponto de passagem; c) descrições e informações orientadoras que definem os melhores métodos práticos sobre 'como' alcançar os pontos de passagem; d) controles para gerenciar a eficiência e a eficácia; e) repositório para coletar informações enquanto percorre um caminho.

**Figura 6 – Modelo de *roadmap* de implementação de inovação**



**Fonte:** Adaptado de Perry e Uys, 2010.

Ainda sobre implementação da inovação e gestão do ciclo de vida, Chofreh *et al.* (2014) argumentam que o *roadmap* pode ser visto como um modelo que fornece uma estrutura holística e coerente, na qual o desenvolvimento e a evolução do negócio ou sistema e seus componentes podem ser explorados, mapeados e comunicados, defendendo então a necessidade do uso de *roadmap* na implementação de sistemas de gestão empresarial (ERP) para que sejam atingidos os objetivos técnicos e organizacionais. Quanto à perspectiva de gerenciamento de projetos os autores concluíram que práticas de gestão de projetos como as definidas pelo *Project Management Institute* (PMI) não são comumente aplicadas nos *roadmaps*, apresentando maior incidência o gerenciamento de escopo e os processos de planejamento e execução.

A participação dos principais interessados e da equipe do projeto é importante para o desenvolvimento de bons *roadmaps*, representando as diferentes perspectivas, podendo ser

elaborados por acadêmicos e profissionais e aplicados então por profissionais de média e alta gerência para tomar decisões (KOSTOFF *et al.* 2004; CHOFREH *et al.* 2014).

Quanto aos sistemas analíticos e de ciência de dados, onde se enquadram os sistemas com ML e IA, *roadmaps* de implementação já são encontrados nos anos 90 como o *Cross-Industry Standard Process for Data Mining* (CRISP-DM).

Shearer (2000) descreve a CRISP-DM, concebida em 1996, como um *roadmap* composto por seis fases: entendimento do negócio, entendimento dos dados, preparação dos dados, modelagem, avaliação e implantação, com objetivo de auxiliar na condução de projetos tanto por novatos quanto por profissionais experientes em *Data Mining*.

Saltz e Dewar (2019) notaram que as descrições atuais de modelos de processos para executar projetos de ciência de dados são muito semelhantes, adotando uma abordagem focada em tarefas e técnicas necessárias para analisar dados, com basicamente os mesmos passos definidos no método CRISP-DM: entendimento do negócio, entendimento e preparação dos dados, modelagem, avaliação e implantação.

Sob o aspecto de adoção de inovações tecnológicas, Bendavid e Cassivi (2012) consideram a Prova de Conceito (POC) como uma etapa crítica do processo de inovação e, uma vez que os problemas e oportunidades foram identificados, classificados e os conceitos da solução definidos, as partes interessadas no projeto passam para a fase de POC. Nesta fase um protótipo é desenvolvido e testado para demonstrar a viabilidade do conceito para desenvolvedores e adotantes, avaliando as vantagens relativas da tecnologia, sua real complexidade, experimentando com a tecnologia, simulando algumas transações e, finalmente, observando seu impacto nos processos de negócio.

No contexto de implementação de tecnologia da informação (TI), Jobin, Le Masson e Hooge (2020) destacam que algumas empresas que buscam implementar um novo software ou solução de TI não se limitam em basear o processo de escolha apenas em fichas técnicas, apresentações ou demonstrações prontas, envolvendo-se com potenciais fornecedores através de uma POC. Isto permite que a empresa cliente tenha uma primeira visão da eficiência futura, compatibilidade e aceitação do usuário da solução, da confiabilidade e capacidade do potencial fornecedor, afirmando que desta forma a POC permite a avaliação e ao mesmo tempo a exploração. Empresas de TI também vêm promovendo a execução de POCs no sentido de tranquilizar os clientes sobre o valor e a viabilidade da aplicação de sua tecnologia de ponta (Big Data, IA, *blockchain*, IoT, ...).

## 1.5 Situação atual da implementação de sistemas analíticos e uso de *roadmaps*

Abordagens e *roadmaps* específicos para implementação de soluções analíticas, com ML e IA, encontradas em sítios de empresas fornecedoras de serviços e tecnologia são mostradas a seguir, oferecendo uma visão geral sobre a situação atual do mercado.

A IBM (2016) elaborou a metodologia *Analytics Solutions Unified Method* (ASUM) para implementação de soluções analíticas, estabelecendo processos, etapas, atividades de desenvolvimento, papéis e responsabilidades, modelos e diretrizes, cujas fases são apresentadas na Figura 7. Os principais benefícios pretendidos pelo *roadmap* são reduzir o risco de implantações, ter alcance e escala organizacional.

**Figura 7 – Metodologia IBM Analytics Solutions Unified Method (ASUM)**

Fase	Descrição geral
<b>Análise</b>	Definir o que a solução tem que cumprir, em termos de atributos funcionais e não funcionais (desempenho, usabilidade, etc). Obter acordo entre todos os participantes sobre os requerimentos.
<b>Projeto</b>	Definir todos os componentes de solução e suas dependências, identificar recursos e instalar um ambiente de desenvolvimento. Sprints de prototipação iterativa são usados quando aplicável para esclarecer requerimentos.
<b>Configuração e Construção</b>	Configurar, construir e integrar componentes baseados em uma abordagem iterativa e incremental. Utiliza planos de teste e validação multiambiente baseados no método de testes V-Model.
<b>Implantação (Deploy)</b>	Criar um plano de execução e manutenção da solução, incluindo uma agenda de suporte. Migrar para o ambiente de produção, configurar e comunicar a implantação para os usuários das áreas de negócio.
<b>Operação e Otimização</b>	Significa o uso da solução de Analytics da IBM. Operar inclui as tarefas de manutenção e pontos de controle após a implantação ( <i>rollout</i> ) que facilita a aplicação com sucesso da solução e preserva sua integridade.
<b>Gestão de projeto</b>	Consiste no processo que apoia com gerenciamento e monitoramento do progresso e manutenção do projeto.

**Fonte:** Adaptado de IBM, 2016.

Segundo a empresa Altexsoft (2019), utilizar o ML implica em fazer escolhas entre os diferentes métodos estatísticos e soluções de ML, dependendo do horizonte de planejamento, da disponibilidade de dados e da complexidade da implementação, mencionando que a aplicação empresarial mais comum do ML em conjunto com métodos estatísticos é a análise preditiva (previsão de cenários). Destaca ainda que a análise preditiva permite não somente estimar a demanda, mas, compreender o que impulsiona as vendas e como os clientes provavelmente se comportam sob certas condições, combinando informações da empresa com

indicadores econômicos, eventos promocionais, mudanças climáticas e outros fatores que afetam as preferências do cliente e as decisões de compra, facilitando a detecção de novas oportunidades de mercado e análises mais granulares sobre a demanda futura.

Quanto às principais operações executadas por sistemas de análise preditiva a empresa lista os seguintes passos: a) agregar dados históricos e novos de diferentes fontes, incluindo sistemas de Gestão Empresarial (ERP) e de Relacionamento com Clientes (CRM), pontos de venda (POSs), sensores, estudos de demanda de clientes, mídias sociais, pesquisas de marketing; b) limpeza de dados; c) determinar qual algoritmo de previsão se adapta melhor ao seu produto; d) construir modelos preditivos para identificar resultados prováveis e descobrir relações entre vários fatores; e e) modelos de monitoramento para medir os resultados dos negócios e melhorar a precisão das previsões. Algumas desvantagens são apontadas pela empresa, como o fato de a análise preditiva envolver algoritmos complexos de aprendizado de máquina, e por ser mais apropriada para gerar previsões não menores que um mês, destacando que para períodos mais curtos as ferramentas de detecção de demanda são mais apropriadas.

Toolsgroup (2019) comenta sobre a capacidade do ML de aprender a partir da experiência (dados), sem a necessidade de ser programado explicitamente, em um processo iterativo típico composto pelos seguintes passos: a) Coleta de Dados: aquisição e armazenamento de dados relevantes estruturados e não estruturados; b) Preparação de Dados: análise exploratória, limpeza, transformação, engenharia de recursos, seleção, dos de teste e treinamento; c) Seleção de Modelo: escolha apropriada dos algoritmos *Supervised*, *Unsupervised* ou *Reinforcement Learning*, como por exemplo: K-Means Clustering, Decision Trees ou Neural Networks; d) Treinamento: treinar o modelo com o conjunto de dados de treinamento; e) Avaliação: medir o desempenho do modelo treinado no conjunto de dados de teste contra uma métrica de avaliação definida, como por exemplo definir um percentual mínimo de precisão de previsão a ser alcançado; f) Ajuste: processo empírico de mudança dos parâmetros do algoritmo para melhorar o desempenho do modelo e g) Produção: implantar o modelo treinado em um sistema produtivo (ambiente de produção).

Adicionalmente aos processos típicos do ML, alerta que o aproveitamento bem sucedido desta tecnologia nos processos de planejamento de demanda requer preparação cuidadosa, sugerindo: a) definir objetivos específicos de início: quais métricas base devem ser melhoradas e porque; b) adotar abordagem em fases: estabelecer uma base de trabalho como, por exemplo, o modelo de previsão e as tecnologias de ML que possam operar de forma integrada e automática, iniciando com os dados históricos existentes e posteriormente utilizando fontes externas de dados e técnicas mais sofisticadas de ML; c) considerar as quatro dimensões dos

dados: volume estatisticamente significativo, granularidade que permita análise de correlações, qualidade que pode ser obtida por programas de governança de dados e variedade de fontes; d) operacionalizar a solução de ML para sustentação ao longo do tempo: escolher modelos auto adaptáveis evitando o ajuste constante feito por especialistas e manter a solução conectada com demais sistemas; e) montar um time com as pessoas certas: a automação do ML permite que os planejadores trabalhem de forma mais estratégica e menos operacional, porém, para preparar os modelos e aferir os resultados são necessários recursos que conheçam o negócio e seus processos. A Figura 8 apresenta as principais considerações do autor sobre a aplicação de dados necessários de acordo com a progressão da abrangência do ML para previsão de demanda.

**Figura 8 – Dados e progressão do ML para melhor planejamento de demanda**

Aumento da percepção da demanda ↓	<b>Progressão do ML</b>		<b>Como aplicar dados</b>
	<b>Linha de base diária</b>	1. Modelo auto adaptativo para probabilidade da previsão  Tendências, sazonalidade, calendários e padrão de vendas diárias  2. Promoções comerciais Efeitos de eventos de mídia Introdução de novos produtos	Aplicar a tecnologia correta para “pequenos dados” para criar versão base de um modelo adaptativo para probabilidade de previsão usando histórico de demanda  Melhorar a versão base do modelo de probabilidade pela aplicação de Machine Learning nos dados históricos para obter uma linha de base mais robusta e confiável que modele com maior acurácia os fenômenos que formam a demanda. Dados incrementais incluem histórico e promoções futuras, eventos de mídia, mas ainda utilizando largamente histórico de demanda, atributos de produtos e outros dados mestres.
	<b>Modelagem da demanda</b>	3. Detecção de demanda externa  4. Ações e eventos especiais Inteligência de mercado	Procurar por correlações adicionais utilizando dados externos como o clima, indicadores, dados de caixas / pontos de venda, mídias sociais, pesquisas, IoT, etc.  Informações de usuários de negócio e modelagem de eventos.

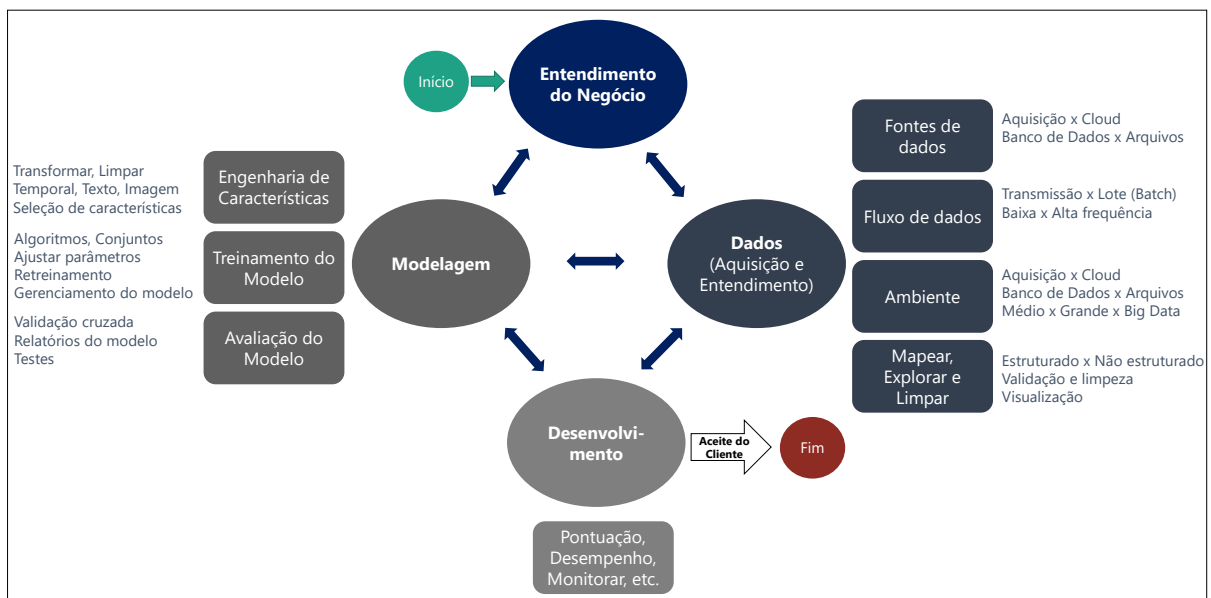
**Fonte:** Adaptado de Toolsgroup, 2019.

Bernardi, Mavridis e Estevez (2019), a partir da análise em cerca de 150 aplicações desenvolvidas com ML descrevem a abordagem de desenvolvimento e implantação utilizada, concluindo que um projeto baseado em ML é um processo iterativo, orientado por hipóteses, integrado a outras disciplinas, composto pelas seguintes fases: a) Absorção do ML; b) Modelagem de desempenho *offline*; c) Desenho do Modelo; d) Implementação e e) Monitoramento.

Etaati (2019) apresenta tecnologias para desenvolvimento de soluções com ML, sugerindo a aplicação do ciclo de vida para projetos de ciência de dados proposto pela

Microsoft. Microsoft (2020) propõe sua metodologia para entregar soluções analíticas preditivas com uso de ML ou IA, denominada Team Data Science Process (TDSP), com o objetivo de auxiliar empresas a obter o máximo de benefícios de suas iniciativas em soluções analíticas. Os componentes chave são uma estrutura de projeto padronizada; infraestrutura e recursos; ferramentas e utilitários; e um *roadmap* para desenvolvimento e implantação com base em um Ciclo de Vida de Ciência de Dados (Data Science Life Cycle). Este ciclo de vida descreve os cinco estágios normalmente executados pelos projetos, geralmente de forma iterativa: a) Entendimento do negócio, b) Aquisição e entendimento dos dados, c) Modelagem, d) Desenvolvimento e entrega e e) Aceitação pelo cliente, apresentados de forma visual na Figura 9.

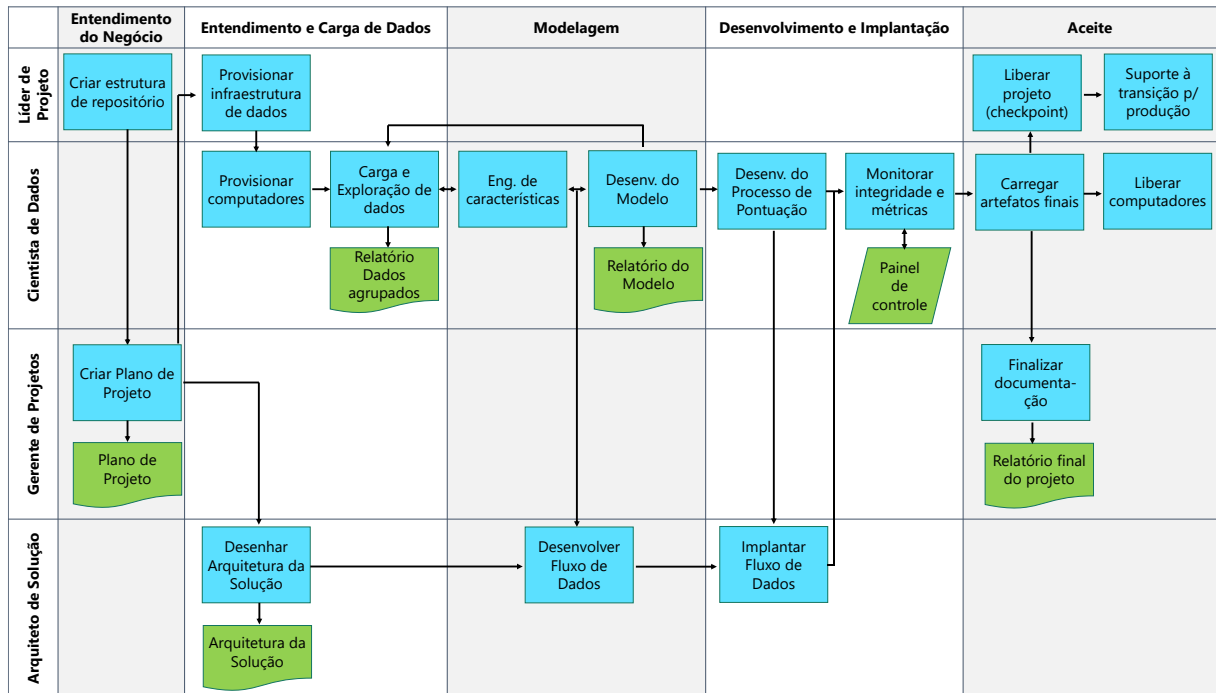
**Figura 9 – Ciclo de vida de processo de Ciência de Dados Microsoft TDSP**



**Fonte:** Adaptado de Microsoft, 2020.

A Figura 10 mostra o *roadmap* da TDSP em uma visão sequencial de atividades e responsáveis, com as tarefas (em azul) e artefatos (em verde), associados a cada estágio do ciclo de vida (eixo horizontal) e às funções do projeto no eixo vertical.

**Figura 10 – Roadmap com tarefas e artefatos da metodologia Microsoft TDSP**



**Fonte:** Adaptado de Microsoft, 2020.

A empresa Opex (2020) apresenta uma abordagem de implantação de soluções analíticas (ML ou IA), baseada em uma plataforma (*framework*) com modelos de dados e algoritmos pré-definidos a serem parametrizados e ajustados pelas empresas que adquirirem a solução, comercializada como um serviço (SaaS – *Solution as a Service*), contemplando as etapas de desenho da solução, desenvolvimento e produção.

Mikhailouskaya (2020) apresenta o *roadmap* da empresa Science Soft para implementação de solução de Big Data em cinco etapas: transformar necessidades de negócios em casos de uso, projetar uma arquitetura de Big Data, integrar Big Data com aplicativos e sistemas existentes, trabalhar na qualidade dos dados e treinar usuários. Para soluções de ML a empresa Science Soft indica como passos principais: preparação de dados, implementação de ML pelo treinamento e teste de modelos para melhorar acurácia nas previsões, adoção pelos usuários por meio da condução de treinamentos e suporte para evoluções.

Llamasoft (2020) oferece uma plataforma criada para análise da cadeia de suprimentos estendida, com acesso a mais de 550.000 conjuntos de dados de séries temporais de fatores causais externos, incluindo dados climáticos e econômicos, formando assim uma solução prévia com variáveis de demanda já disponíveis, combinando técnicas de previsão estatística com algoritmos proprietários de ML, o que pode acelerar a implantação em seus clientes. A solução pode ser acessada centralizadamente, extraindo e preparando continuamente dados obtidos nos



sistemas da cadeia de suprimentos armazenados em infraestrutura computacional em nuvem (*cloud system*).

Em relação aos ambientes computacionais e ferramentas para a implementação de soluções com ML, pode-se destacar o estudo de Gualtieri e Carlsson (2018) para a empresa de pesquisa Forrester, que identificou fornecedores de soluções empresariais de ML e análise preditiva possíveis de serem utilizadas por times de projeto multidisciplinares, compostos por representantes do negócio, cientistas de dados, engenheiros de dados e desenvolvedores de software. Estas soluções deveriam ser compostas por: ferramentas para analisar dados; um ambiente de trabalho para construir modelos preditivos usando algoritmos de ML; uma plataforma para treinar, implantar e gerenciar resultados e modelos analíticos; e ferramentas de colaboração para o time de projeto. O estudo selecionou treze empresas, segundo critérios próprios dos pesquisadores, com maior capacidade para atender às necessidades de desenvolvimento corporativo de aplicações: Dataiku, Datawatch, FICO, IBM, KNIME, MathWorks, Microsoft, RapidMiner, Salford Systems (Minitab), SAP, SAS, TIBCO Software e World Programming.

Sapp (2018) sugere a possibilidade de acelerar as iniciativas de implementação de sistemas que incorporem tecnologias de ML e IA aproveitando-se das ofertas de fornecedores de serviços em nuvem (CSPs), mencionando aqueles considerados líderes por possuírem um *roadmap* estratégico robusto e boa oferta de serviços baseados em ML e IA aplicáveis aos negócios: Amazon Machine Learning, Google Cloud Machine Learning Engine, IBM Watson Studio e Microsoft Azure Machine Learning Studio.

## **2 METODOLOGIA**

A metodologia utilizada neste trabalho é a Design Science Research Methodology (DSRM), detalhada a seguir, por ter foco na solução de um problema a ser resolvido por meio de um artefato.

Uma visão geral dos métodos e passos executados pode ser vista ao final do capítulo na Figura 12.

### **2.1 A DSRM**

Segundo Lacerda *et al.* (2013), a DSRM tem objetivo prescritivo, orientada à solução de problemas, com o propósito de projetar sistemas que ainda não existem ou modificar situações existentes para alcançar melhores resultados, podendo gerar artefatos de diversos tipos como Constructos, Modelos, Métodos, Instanciações e Proposições de Projeto.

Hevner (2007) ressalta a natureza pragmática do método de pesquisa DSRM, adequado para produzir e avaliar um artefato de TI para a solução de um problema.

Peffer, Tuunanen, Rothenberger e Chatterjee (2007) afirmam que a DSRM é uma disciplina orientada para a criação de artefatos, composta por seis etapas: 1) identificação de problemas e motivações; 2) definição dos objetivos de uma solução; 3) projeto e desenvolvimento; 4) demonstração; 5) avaliação e 6) comunicação; demonstrando uma metodologia para aplicação em sistemas de informação.

Os tópicos a seguir apresentam a descrição de cada etapa da DSRM e os resultados são mostrados no capítulo 3.

### **2.2 Etapa 1 - Identificação do problema e motivações**

Nesta etapa da DSRM busca-se o máximo possível de informações para a compreensão do problema e das motivações (LACERDA *et al.*, 2013). Para atingir este objetivo foi identificado o problema e realizada uma pesquisa bibliográfica, seguida de revisão da literatura e pesquisa de campo, descritas a seguir.

### **2.2.1 Problema a ser resolvido**

O problema a ser resolvido por um artefato, conforme descrito anteriormente na Introdução, foi consolidado na questão de pesquisa: Como obter melhores resultados em projetos de implementação da tecnologia de ML na previsão de demanda de bens de consumo por meio da utilização de um *roadmap*?

A pesquisa para levantamento de informações que caracterizam o problema é apresentada no capítulo Fundamentação Teórica, nas seções Desafios para Implementação e Situação Atual.

### **2.2.2 Motivações - Benefícios do ML identificados na literatura**

Uma das motivações para o estudo são os ganhos que podem ser obtidos pelo uso de soluções de ML para a previsão de demanda de bens de consumo, apresentados no capítulo Fundamentação Teórica por meio de uma análise bibliométrica seguida de revisão da literatura de abordagem qualitativa.

A abordagem bibliométrica, através da qual a ciência é retratada pelos resultados obtidos, baseia-se na noção de que a essência da pesquisa científica é a produção de conhecimento e que a literatura científica é uma manifestação desse conhecimento (OKUBO, 1997). Já Guedes e Borschiver (2005) definem a análise bibliométrica como uma ferramenta quantitativa que visa minimizar a subjetividade inerente à indexação e recuperação de informações, produzindo conhecimento em uma determinada área. Em relação à revisão da literatura, Creswell (2014) propõe que seja apresentada uma síntese dos principais estudos sobre a questão de pesquisa, podendo ser utilizada para indicar que o autor conhece a literatura sobre o tema em questão, bem como as últimas publicações.

A análise efetuada apresenta a evolução recente do tema ML aplicado na previsão de demanda dos diversos setores de bens de consumo, quais foram os benefícios alcançados, principais técnicas utilizadas, tipos de produtos e problemas de negócio endereçados.

### **2.2.3 Motivações - Benefícios do ML identificados em casos reais**

Ainda sobre os ganhos pelo uso de soluções de ML para a previsão de demanda de bens de consumo, uma pesquisa de campo foi realizada em uma empresa fornecedora de soluções de

ML apurando resultados obtidos em casos reais por meio de dados secundários compartilhados por clientes que utilizam o sistema.

A empresa fornece um sistema de ML para apoio aos processos de planejamento de compras e abastecimento, a partir de previsões de demanda mais precisas fornecidas pelo sistema. Localizada na cidade de São Paulo, a empresa tem clientes de médio e grande porte, nacionais e multinacionais, de diversos setores incluindo alimentos refrigerados, alimentos industrializados, moda, cosméticos, redes de varejo, entre outros, cujos escritórios centrais no Brasil são situados em sua maioria no estado de São Paulo. A escolha da empresa se deu por conveniência, em função do tipo de solução fornecida, da localização, da relevância de seus clientes e da disposição do principal executivo em colaborar com a pesquisa.

Os ganhos após a implementação foram medidos por indicadores chave identificados na literatura: aumento de vendas, redução de ruptura (falta de produtos nos pontos de venda), redução de perdas (descarte por vencimento ou liquidação) e diminuição do nível de estoque.

A Figura 11 mostra o modelo utilizado para apurar os indicadores, com o segmento da empresa cliente, a data de implementação, se possuía previamente um *roadmap* estratégico de tecnologia, o percentual de melhora alcançado para cada indicador, o período de apuração, além dos autores pesquisados para os temas de *roadmap* estratégico e ganhos com o ML.

**Figura 11 – Modelo de indicadores de resultados do ML após implementação**

RESULTADOS DE IMPLEMENTAÇÕES								
EMPRESA		SETOR OU PRODUTO	RESULTADOS					
Empresa	Plano estratégico?	Setor ou Tipo de Produto	Previsão Demanda	Aumento Vendas	Redução Ruptura	Redução Perdas	Nível Estoque	Período de apuração
Num. Seq.	Sim	Alimentos processados	%	%	%	%	%	meses ou ano
	Não	Alimentos perecíveis						
		Moda						
		Eletrônicos e Tecnologia						
		Higiene e Limpeza						
		Duráveis e Semi						
FUNDAMENTAÇÃO TEÓRICA (AUTORES)								
Roadmap Estratégico		Benefícios x Setores						
Giebel (2009); Moehrle, Isenmann e Phaal (2013); Phaal e Muller (2009); Sapp (2018).		Arvan et al. 2018; Bertaglia, 2016; Cohen et al. (2017); Da Silva et al. (2017); Lu e Shao (2012); Martinez et al., 2018; Payne (2018); Proctor e Fowler (2019); Wilson (2018); Yue et al., 2016.						

**Fonte:** Resultados da pesquisa, 2020.

### 2.3 Etapa 2 - Definição dos objetivos de uma solução

Na Etapa 2 da DSRM devem ser estabelecidos os objetivos da solução (artefato) a ser desenvolvido, em função do problema e das motivações observadas na etapa anterior.

Em face das dificuldades pesquisadas para adoção e implementação de tecnologia de ML e dos potenciais benefícios que um sistema de uso contínuo pode trazer, foram definidos o tipo de artefato a ser elaborado (*roadmap*) e os objetivos que deve cumprir, detalhados no capítulo de resultados.

### 2.4 Etapa 3 - Projeto e desenvolvimento

A Etapa 3 prevê a elaboração do desenho e o desenvolvimento da solução, ou artefato de TI, para a resolução dos problemas identificados e o atingimento dos objetivos estabelecidos nas fases anteriores.

Para a execução desta fase, além da fundamentação teórica sobre *roadmaps*, foi realizada pesquisa de campo junto à empresa fornecedora de sistema de ML mencionada na Etapa 1.

O processo de elaboração do artefato (*roadmap*) consistiu no desenho inicial pelo pesquisador a partir do estudo realizado e, refinamento posterior junto ao Diretor de Tecnologia e sua equipe, por meio de entrevistas semiestruturadas, agregando a experiência adquirida em diversos projetos.

### 2.5 Etapa 4 - Demonstração

O método DSRM define a Etapa 4 para demonstração da solução elaborada.

A demonstração da utilização do *roadmad*, desenvolvido na etapa anterior, ocorreu durante a implementação do sistema de ML pela empresa fornecedora em um dos seus clientes. O *roadmap* foi utilizado pela equipe de implementação composta por representantes da fornecedora e da empresa cliente, sendo os resultados da demonstração detalhados no capítulo de resultados.

## 2.6 Etapa 5 - Avaliação

Na etapa 5 da DSRM o artefato demonstrado na etapa anterior deve ser avaliado. A Avaliação é definida como o processo de verificação do comportamento do artefato no ambiente para o qual foi projetado, em relação às soluções que se propôs alcançar (LACERDA *et al.*, 2013).

Para avaliar a efetividade da utilização foram realizadas entrevistas pelo pesquisador junto ao time que utilizou o *roadmap* durante a implementação demonstrada na etapa anterior. Os dados foram levantados junto à equipe da fornecedora em função da limitação do acesso aos representantes do cliente.

As questões para as entrevistas semiestruturadas foram organizadas de acordo com os objetivos estabelecidos para o *roadmap* na Etapa 2 da DSRM. As respostas obtidas foram pontuadas de forma a facilitar a avaliação do uso do artefato proposto: Concordo fortemente = 1, Concordo = 0,5 e Discordo ou Desconheço = 0.

A estruturação dos resultados da avaliação é apresentada no Quadro 3, contendo os objetivos do *roadmap*, as questões que endereçam cada objetivo, os autores que fundamentam as questões, a quantidade de respostas obtidas (entrevistados), o total de pontos da questão obtido pela soma da pontuação de cada respondente, o total de pontos de cada objetivo e, o percentual de atingimento configurado pelo percentual da pontuação alcançada para o objetivo em relação ao máximo possível de pontos.

**Quadro 3 – Questões sobre a efetividade do uso do *roadmap***

Objetivos do <i>roadmap</i>	Questão	Fundamentação	Quantidade de respostas	Pontuação total da questão	Pontuação total do objetivo	% de atingimento
Descrição de cada objetivo	Questão de verificação do atingimento do objetivo	Autores que fundamentam a questão	Quantidade de entrevistados	Soma de pontos das respostas de cada entrevistado	Soma de pontos das questões do objetivo	Percentual da pontuação atingida em relação ao máximo possível
	(continua)					
(continua)						

**Fonte:** Resultados da pesquisa, 2020.

Ainda no sentido de avaliar a efetividade da aplicação do *roadmap* foram listadas as principais dificuldades de implementação de ML pesquisadas, bem como itens facilitadores, e como o *roadmap* endereçou cada ponto, apresentando uma análise qualitativa cuja estrutura pode ser vista no Quadro 4.

O Quadro 4 contém a descrição de cada item de dificuldade ou facilitador, os autores relacionados ao item, o nível de atendimento do *roadmap* para cada item medido em três níveis: endereça fortemente, parcialmente ou não endereça, além de uma descrição resumida sobre como o *roadmap* endereça o item. Os níveis foram preenchidos pelo pesquisador de acordo com as respostas e comentários obtidos nas entrevistas estruturadas.

**Quadro 4 – Modelo de avaliação de dificuldades e facilitadores de implementação x *roadmap***

Fundamentação	Descrição das dificuldades e facilitadores	O Roadmap endereça			Como o roadmap endereça as dificuldades e facilitadores
		Forte-mente	Parcial-mente	Não en-dereça	
DIFICULDADES DE IMPLEMENTAÇÃO					
Autores	Descrição da dificuldade				Comentários com base nas entrevistas
FACILITADORES DE IMPLEMENTAÇÃO					
Autores	Descrição do facilitador				Comentários com base nas entrevistas

**Fonte:** Resultados da pesquisa, 2020.

## 2.7 Etapa 6 - Comunicação

A comunicação da solução (artefato) desenvolvido, demonstrado e avaliado, é prevista na etapa 6 da DSRM.

A divulgação dos resultados e do uso do artefato pode ser feita por meio de dissertações, teses ou artigos.

## 2.8 Visão geral

A Figura 12 apresenta uma visão geral da metodologia aplicada neste trabalho, com os passos da DSRM e os métodos complementares utilizados para cumprir cada etapa.

**Figura 12 – Visão geral das etapas da DSRM**

<b>Etapas</b>	<b>Objetivo</b>	<b>Ações e métodos auxiliares</b>
<b>1 Identificação do problema e motivação</b>	Identificar os problemas a serem resolvidos e as motivações para o desenvolvimento de um artefato, buscando o máximo possível de informações.	<ul style="list-style-type: none"> <li>• Realizar pesquisa bibliométrica nas bases Scopus Elsevier e Web of Science sobre ML em previsão de demanda</li> <li>• Revisar literatura sobre os ganhos para o setor de bens de consumo</li> <li>• Realizar pesquisa de campo secundária sobre ganhos obtidos por empresas que implementaram ML para previsão de demanda de bens de consumo</li> <li>• Pesquisar na literatura sobre dificuldades de implementação</li> <li>• Pesquisar no mercado a situação atual de implementação</li> </ul>
<b>2 Definir os objetivos da solução</b>	Estabelecer os objetivos de uma solução (artefato) a ser desenvolvido, em função do problema e das motivações observadas na etapa anterior.	<ul style="list-style-type: none"> <li>• Definir o tipo de artefato a ser elaborado e os objetivos que deve cumprir</li> </ul>
<b>3 Desenho e desenvolvimento</b>	Desenhar e desenvolver uma solução, ou artefato de TI, para a resolução dos problemas identificados e o atingimento dos objetivos estabelecidos nas fases anteriores.	<ul style="list-style-type: none"> <li>• Desenhar modelo do artefato com base na fundamentação teórica</li> <li>• Complementar o modelo do artefato a partir da experiência de uma empresa fornecedora de sistemas de ML por meio de pesquisa de campo</li> </ul>
<b>4 Demonstração</b>	Demonstrar a solução elaborada.	<ul style="list-style-type: none"> <li>• Apresentar um caso real de utilização do artefato em um projeto de implementação do sistema de ML pela empresa fornecedora em um de seus clientes</li> </ul>
<b>5 Avaliação</b>	Apresentar os resultados do uso do artefato.	<ul style="list-style-type: none"> <li>• Avaliar os resultados do uso do artefato por meio de entrevistas semiestruturadas com os participantes da implementação, com base nos objetivos estabelecidos na Etapa 2</li> </ul>
<b>6 Comunicação</b>	Comunicar as características e resultados do uso do artefato.	<ul style="list-style-type: none"> <li>• Comunicar o artefato por meio dissertações, teses ou artigos.</li> </ul>

**Fonte:** Resultados da pesquisa, 2020.



### **3 RESULTADOS E DISCUSSÃO DAS ETAPAS DA DSRM**

Este capítulo apresenta os resultados do estudo pela aplicação das seis etapas definidas na metodologia DSRM: identificação do problema e motivações para a elaboração de uma solução ou artefato, definição dos objetivos do artefato, desenho e desenvolvimento, demonstração, avaliação e comunicação.

#### **3.1 Etapa 1 - Problema e motivações**

Esta seção contém os resultados da primeira etapa da DSRM, identificando o problema a ser resolvido e as motivações para o trabalho.

##### **3.1.1 Problema - Dificuldades de implementação de soluções de ML**

O principal problema a ser resolvido, identificado neste estudo, é a dificuldade que as empresas apresentam para implementar uma solução de ML e, em consequência, obter os ganhos esperados.

Entre as dificuldades, a escolha do algoritmo adequado foi mencionada em função da grande variedade disponível podendo retardar a decisão de adoção da tecnologia e causar atrasos nos prazos de implementação.

Da mesma forma ferramentas de baixa qualidade oferecidas pelo mercado afetam a implementação, a evolução e a manutenção de uma solução.

Em relação aos dados são necessárias séries históricas suficientes para realizar as análises preditivas com ML, com nível de granularidade adequado, variáveis significativas internas e externas, o que nem sempre as empresas conseguem obter.

Sobre aspectos humanos e organizacionais, a importância do trabalho colaborativo entre pessoal técnico e de negócios para o desenvolvimento de uma solução é destacado por alguns autores para o sucesso da implementação de um sistema.

Outro item de natureza humana apontado na literatura como fator crítico de sucesso é o envolvimento de líderes e gestores na implementação, tanto na fase de implementação quanto para a utilização efetiva posterior do sistema suportando os processos de gestão de demanda.

O medo das mudanças que novas tecnologias e processos podem trazer, além da aversão ao risco associado à novas soluções, também foram apontados como barreiras para implementação.

Finalmente, a ausência de *roadmaps* pelas empresas, tanto no nível estratégico de tecnologia quanto para implementação de inovações, é citada como um dos principais motivos de não implementação de soluções de ML e IA.

O *roadmap* é definido por alguns autores como um guia para a implementação bem sucedida de sistemas, para que seja atingidos os objetivos técnicos e organizacionais, porém, sua utilização é encontrada com maior frequência em sistemas ERP do que em sistemas analíticos e de ciência de dados.

### **3.1.2 Motivações - Ganhos do ML identificados na literatura**

Este tópico apresenta uma das motivações para o estudo, por meio de um resumo dos ganhos que podem ser obtidos com a utilização de sistemas de ML aplicados à previsão de demanda de bens de consumo, a partir de pesquisa bibliográfica e da revisão da literatura apresentadas na Fundamentação Teórica.

A pesquisa bibliométrica demonstra grande interesse pelo tema ML na academia com mais de 80.000 artigos publicados em oito anos referenciados nas bases de dados Web of Science e Scopus Elsevier, com predominância de pesquisadores dos Estados Unidos e China. Nota-se em grande parte dos artigos o foco na elaboração e comparação entre algoritmos de ML nos diversos campos da ciência.

Mais especificamente sobre pesquisas voltadas para ganhos do ML aplicado em previsão de demanda de bens de consumo, há crescimento de 2010 a 2012, queda de 2012 a 2013 e volta a tendência de crescimento a partir de 2013, sendo trinta artigos selecionados para análise.

É possível observar nos estudos analisados a busca das empresas pela melhoria na precisão das previsões de venda, com benefícios em economia de custos de estoques, maior eficiência da cadeia de suprimentos, redução de perdas por descarte de produtos e melhora de receita por atender melhor às demandas dos clientes.

Os segmentos de negócio com maiores benefícios observados foram os de bens de consumo rápido (FMCG), com curta validade e rápida obsolescência (ciclo de vida rápido), ou produtos inovadores para os quais não há dados históricos para estudos de regressão. Os principais setores mencionados foram de alimentos, produtos perecíveis, lojas de varejo, produtos de computação e produtos de moda como vestuário e calçados.

Pode-se observar também que o ML para previsão de demanda atinge maiores níveis de precisão do que técnicas estatísticas tradicionais. Esta vantagem ocorre especialmente quando novas variáveis de dados são incluídas nos modelos de estimativa, além das séries históricas de vendas comumente utilizadas, contemplando informações externas à empresa como clima (realizado e previsto), eventos regionais, feriados, indicadores econômicos e tendências de moda; informações internas sobre estoques ao longo do tempo, atributos e data de validade dos produtos; ações de mercado como campanhas de marketing, propaganda e promoções; informações obtidas na internet como o comportamento dos clientes observado pela busca de produtos e pelos registros de opiniões.

Este aumento expressivo da quantidade de variáveis, do volume de dados das séries temporais e da complexidade de análise do relacionamento entre os fatores, favorece a utilização de redes neurais artificiais e ML.

Entre os benefícios obtidos em consequência da maior acurácia das previsões, destaca-se a melhora na gestão dos estoques a partir de decisões mais adequadas de produção e de distribuição. A redução dos índices de ruptura (falta de itens nas lojas) também é mencionada, bem como a maior disponibilidade de produtos nos pontos de venda, proporcionando o aumento de receita e de satisfação dos clientes. Outro ganho citado para o varejo é a maior qualidade no gerenciamento geral das lojas, com ênfase nos processos de reabastecimento.

Nos negócios de alimentos frescos, previsões mais precisas foram obtidas com ML permitindo reduzir o nível de perdas de produtos por expiração da data de validade. Quando se tratam de refrigerados os benefícios são ainda maiores em função dos custos evitados de armazenamento e transporte especializado.

O setor de itens de moda, incluindo vestuário, calçados e acessórios, está entre os mais estudados, trazendo como principal desafio evitar a perda de produtos não vendidos ocasionada pelas constantes mudanças nas tendências e nas preferências dos consumidores. Técnicas mais recentes de ML se mostraram adequadas tanto pela melhor previsibilidade quanto pela rapidez de processamento, capazes de gerar estimativas de acordo com a frequência de lançamentos de novas coleções.

A pesquisa mostrou que fabricantes e varejistas de produtos tecnológicos, que podem ser substituídos rapidamente por novos lançamentos, obtêm benefícios pela melhor gestão das vendas e dos estoques. Adicionalmente, melhores previsões foram obtidas para produtos inovadores que, portanto, não possuem histórico de vendas.

Finalizando a análise observa-se que as ações promocionais têm grande importância para todos os setores, em função do nível significativo de participação nas vendas de bens de

consumo rápido, porém, tornam a tarefa de realizar estimativas mais complexa devido às diversas combinações possíveis entre tipos de promoção, produtos, períodos, clientes e regiões, além dos impactos em itens não participantes das promoções. Estudos recentes, de 2012, 2014, 2016 e 2017, mostram vantagens do uso de ML para melhoria da eficiência promocional, com maior previsibilidade e melhores resultados.

### **3.1.3 Motivações - Ganhos do ML apresentados em casos reais**

Ainda tratando das motivações para o estudo, este tópico apresenta os ganhos que podem ser obtidos a partir de dados de casos reais de utilização de um sistema com ML para previsão de demanda em empresas de bens de consumo. Os dados foram obtidos por meio de informações compartilhadas pelos clientes da empresa fornecedora de soluções, objeto da pesquisa de campo.

As métricas de ganho apuradas podem ser vistas no Quadro 5, analisadas a seguir.

A variação da métrica de acurácia da previsão de demanda não foi possível de ser obtida, pois, os clientes não tinham a medição anterior à implementação do sistema, embora duas empresas declararam que a margem de erro com o sistema é inferior aos padrões do mercado.

Quanto ao aumento de vendas apenas uma empresa mediu o aumento, em cerca de 17%, embora seja possível afirmar que as reduções de ruptura observadas tendem a aumentar as vendas.

Os índices de redução de ruptura e perdas foram significativos, variando entre 16% e 90%. O nível de estoque também apresenta reduções e, quando aumenta é compensado por aumento de vendas ou redução de ruptura.

Portanto, os benefícios observados nos casos reais confirmam a pesquisa teórica realizada apresentando os indicadores com resultados mais significativos quanto à redução de ruptura e redução de perdas por data de validade de alimentos.

**Quadro 5 – Resultados de negócio obtidos com a implementação da solução de ML**

EMPRESA	SETOR OU PRODUTO	RESULTADOS					
Empresa	Setor ou Tipo de Produto	Previsão Demanda	Aumento Vendas	Redução Ruptura	Redução Perdas	Nível Estoque	Período de apuração
Emp1	Fabricação e varejo de chocolates	não media	não informado	-83%	-65%	-31%	2017
Emp2	Varejo - Móveis e decoração	não media	17,00%	-89%	n/a	+2%	2018
Emp3	Varejo - Eletro e Móveis	não media	não informado	-29%	n/a	-6%	2019
Emp4	Varejo - Lojas de departamentos	não media	não informado	-16%	n/a	-20%	2019
Emp5	Fabr. e distr. de lácteos refrigerados	não media	não informado	-62%	-54%	-9%	2019
Emp6	Lojas de Fast Food	Erro 26,24% (baixo)	não informado	-90%	n/a	+30%	2020
Emp7	Varejo (C&C e Auto Serviço)	Erro 20,27% (baixo)	não informado	não media	n/a	-30%	2020

**Fonte:** Resultados da pesquisa, 2020.

### 3.2 Etapa 2 - Objetivos do *roadmap* de implementação de ML

Nesta seção são definidos os objetivos da solução / artefato para endereçar o problema identificado na seção anterior, constituindo o segundo passo da metodologia DSRM.

O principal objetivo pretendido para a solução / artefato é servir como ferramenta de orientação para a implementação de um sistema produtivo com ML para previsão de demanda de bens de consumo, reduzindo dificuldades mencionadas na literatura, facilitando a adoção e antecipando a realização dos benefícios esperados.

Dessa forma, um *roadmap* de implementação é proposto tendo como principais metas:

- Orientar as atividades de profissionais de negócio e técnicos envolvidos na implementação, indicando as principais fases, produtos e responsáveis;
- Reduzir riscos de implementação provendo mecanismos para tomada de decisão sobre temas como: qualidade de dados, escolha de algoritmos e atendimento de requisitos de negócio;
- Incentivar o engajamento das lideranças de negócio na implementação e consequente adoção do sistema como principal fonte de informação para a gestão da demanda (delegação da função de previsão de demanda);
- Promover o alinhamento da inovação a ser implementada com o *roadmap* estratégico e tecnológico da organização.

### 3.3 Etapa 3 - Elaboração do artefato *roadmap*

Esta seção detalha a solução elaborada para atingir os objetivos definidos na seção anterior, correspondendo ao terceiro passo da DSRM (desenho e desenvolvimento da solução). A elaboração do *roadmap* levou em conta os fundamentos teóricos e a experiência da empresa fornecedora de sistemas de ML.

Os tópicos a seguir apresentam a estrutura do *roadmap* proposto em fases e etapas, o detalhamento de cada fase e, no último tópico, comentários sobre o uso opcional de práticas de gestão de projetos e de mudanças em paralelo às fases do *roadmap*.

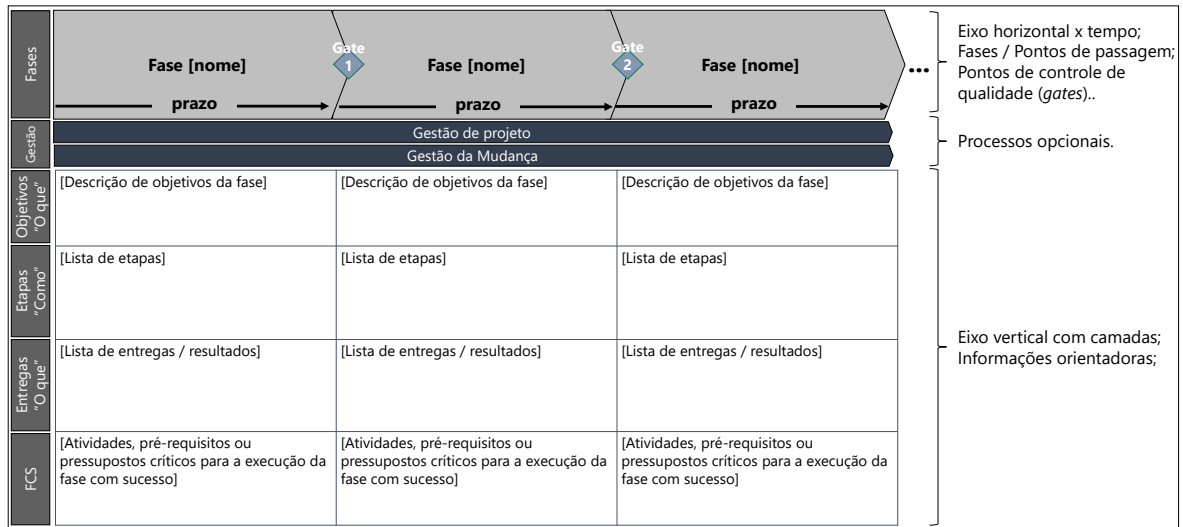
#### 3.3.1 Estrutura do *roadmap* proposto

O artefato denominado “Roadmap de utilização de Machine Learning para previsão de demanda de bens de consumo” foi elaborado durante a pesquisa de campo junto a uma empresa fornecedora de soluções ao longo de uma implementação em cliente.

O primeiro passo da elaboração foi desenhar a estrutura com base em princípios identificados na fundamentação teórica como: a) um gráfico visual de múltiplas camadas baseado no tempo (PHAAL; MULLER, 2009); b) uma estrutura de alto nível com pontos de passagem indicando "onde", objetivos indicando "o que", descrições, informações orientadoras indicando “como” e controles (PERRY; UYS, 2010) e c) incorporação da abordagem de *quality gates* (GIEBEL *et al.*, 2009).

Fatores críticos de sucesso (FCS) para a execução de cada fase foram incluídos na estrutura como forma de orientação e controle, obtidos na literatura e na pesquisa de campo. Uma camada de gestão foi incluída com duas frentes de trabalho a serem executadas em paralelo às fases do *roadmap*: uma para gerenciamento do projeto e outra para tratar mudanças organizacionais e de processos de negócio ocasionadas pela adoção do sistema. Estas frentes de gestão são opcionais pela empresa onde será implementada a solução, não detalhadas no *roadmap*. A estrutura proposta é apresentada na Figura 13.

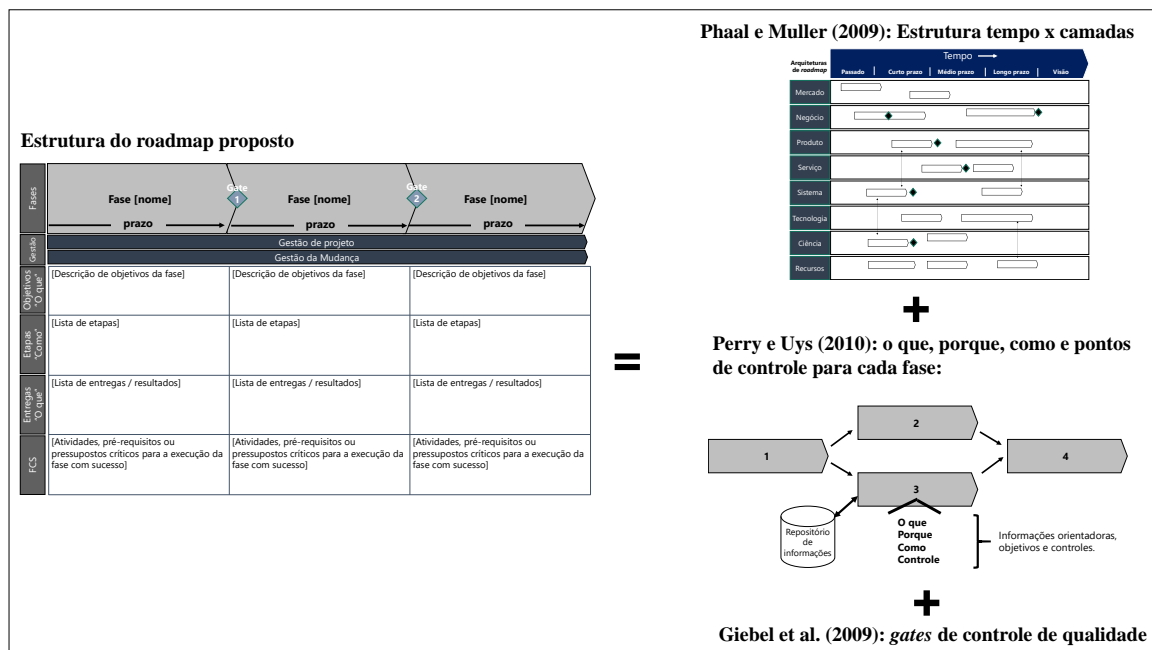
**Figura 13 – Estrutura do roadmap proposto**



**Fonte:** Resultados da pesquisa, 2020.

A Figura 14 mostra uma ilustração sobre a combinação das teorias utilizadas na elaboração da estrutura, descritas nos parágrafos anteriores, cujo objetivo foi obter a melhor apresentação visual, em uma página, facilitando assim a comunicação, incluindo também os princípios de um *roadmap* de implementação quanto à orientação das atividades e passagens de fase, além de pontos de controle de qualidade.

**Figura 14 – Conceitos utilizados para a elaboração da estrutura do roadmap proposto**



**Fonte:** Resultados da pesquisa, 2020.

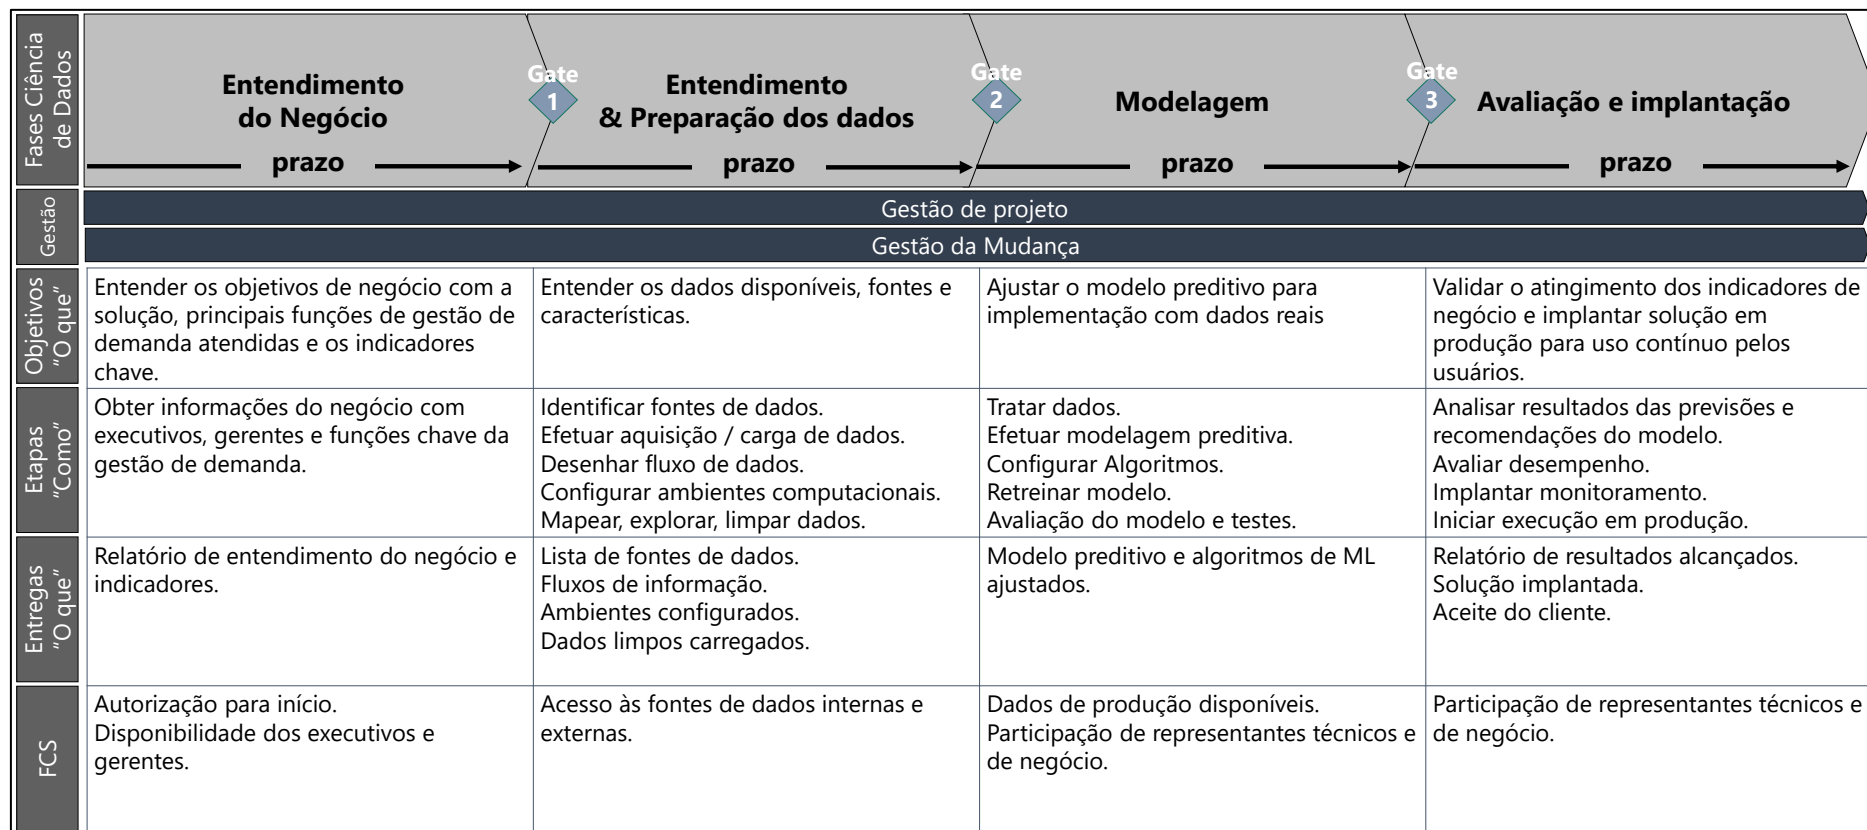
A partir da estrutura proposta o *roadmap* foi preenchido de acordo com as fases frequentemente utilizadas em projetos de ciência de dados, de acordo com Saltz e Dewar (2019), apresentado na Figura 15: entendimento do negócio, entendimento e preparação dos dados, modelagem, avaliação e implantação. Este modelo típico de projetos de ciência de dados serviu como referência para a elaboração do *roadmap* de ML.

O modelo foi alterado então para incorporar a experiência real da empresa fornecedora, refletindo o ciclo de vida da solução por meio das fases: Alinhamento, Prova de Conceito (Preparação e Simulação), Piloto e Expansão (Figura 16). O *roadmap* proposto tem como objetivo orientar e facilitar a execução de atividades nos projetos de implantação de soluções de ML para previsão de demanda com foco gerencial, sem detalhar tarefas técnicas que fazem parte do ciclo de vida do desenvolvimento de sistemas. Também não constitui uma metodologia para gestão de projetos, podendo a empresa cliente aplicar seu próprio método de gerenciamento em paralelo à execução do *roadmap*.

Um exemplo ilustrativo do relacionamento entre um *roadmap* estratégico, no nível de empresa, e o de implementação proposto, no nível de sistema, é apresentado na Figura 17.

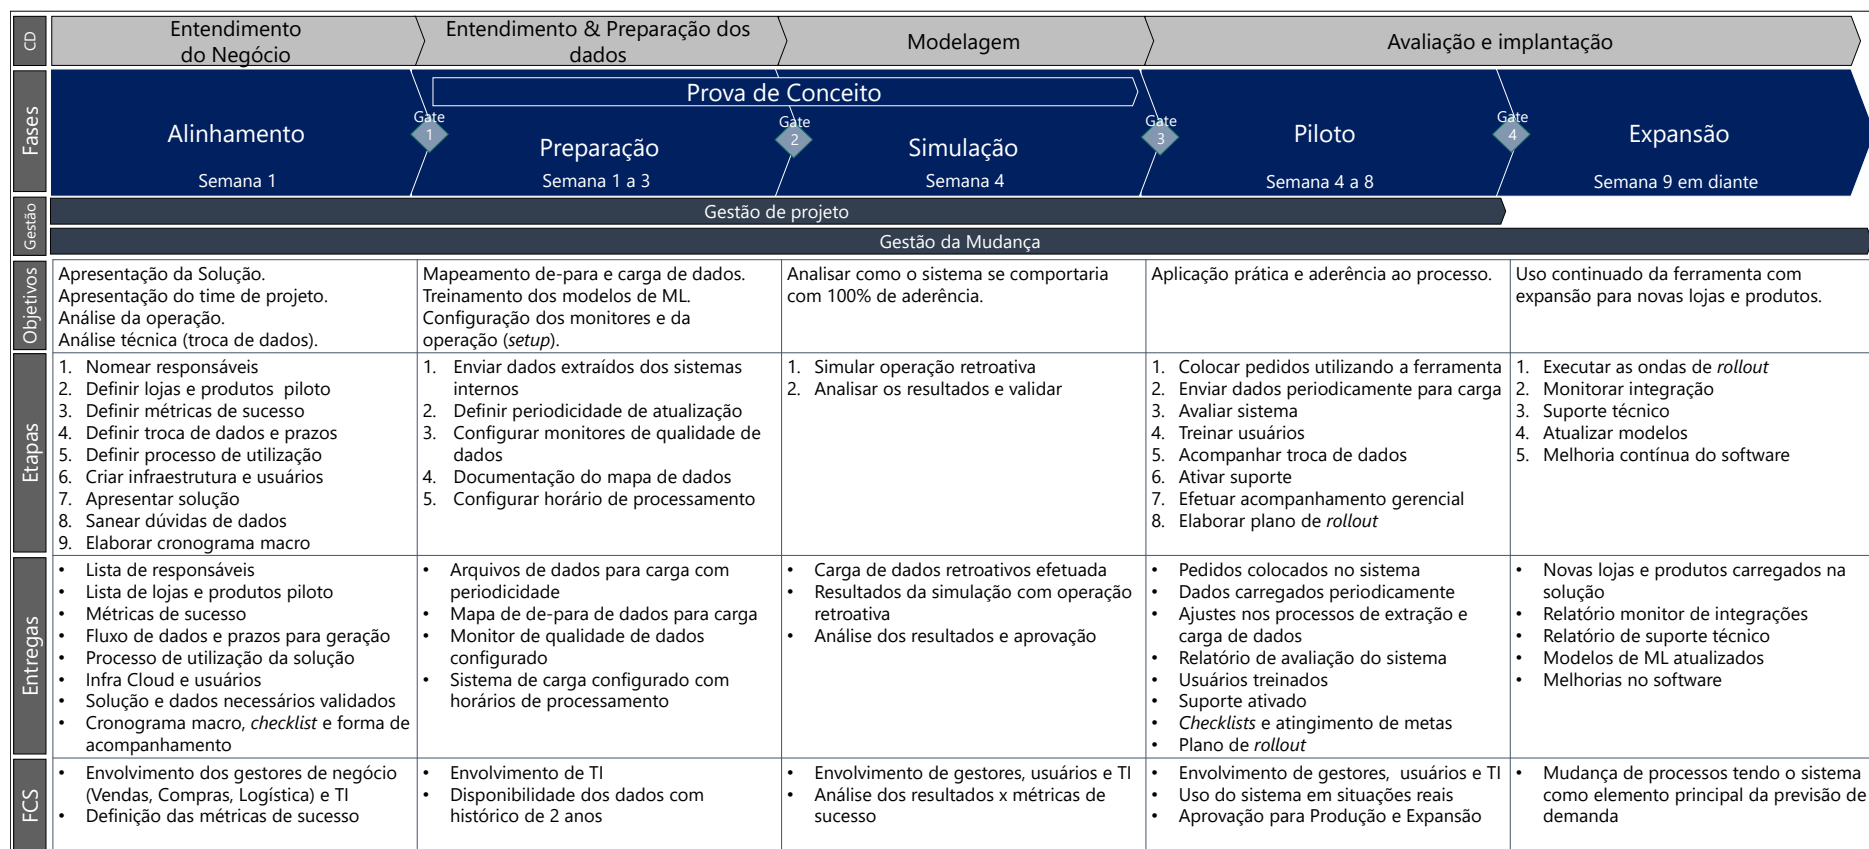


**Figura 15 – Roadmap típico de projetos de ciência de dados**



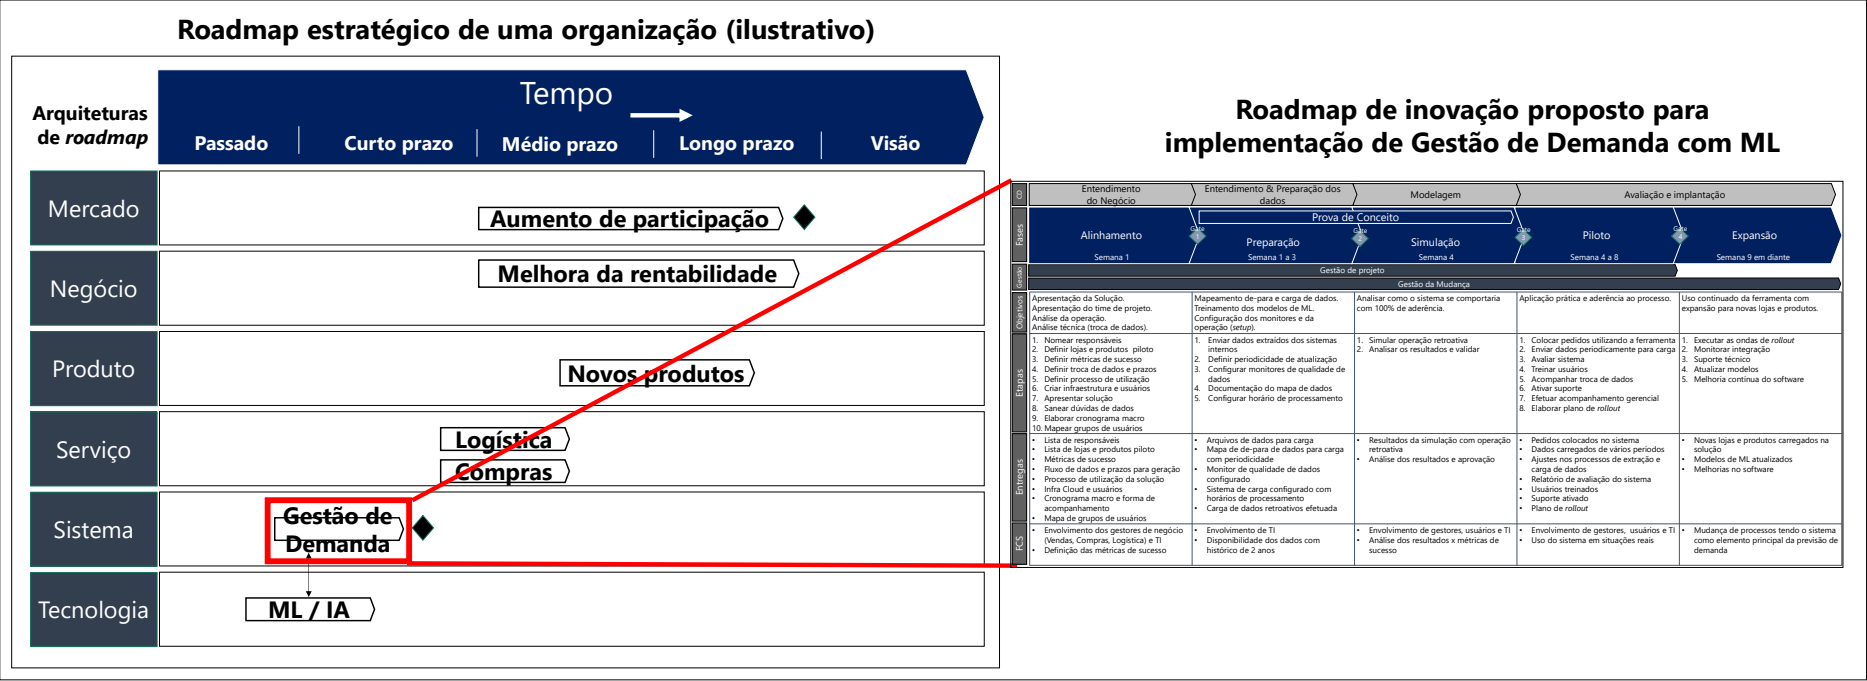
**Fonte:** Resultados da pesquisa, 2020.

**Figura 16– Roadmap proposto de utilização de Machine Learning para previsão de demanda de bens de consumo**



**Fonte:** Resultados da pesquisa, 2020.

Figura 17 – Relação entre *roadmap* estratégico no nível de empresa x *roadmap* de implementação



Fonte: Resultados da pesquisa, 2020.

### **3.3.2 Detalhamento das fases do *roadmap***

As fases, etapas e produtos do *roadmap* proposto são detalhados a seguir:

#### **Fase 1 - Alinhamento**

Objetivos:

- Promover o alinhamento entre o time de projeto e os interessados sobre a solução a ser implementada, seus objetivos, fases, atividades e responsáveis:
  - Apresentar a solução.
  - Apresentar o time de projeto (fornecedora e cliente).
  - Efetuar uma análise da operação / processos de negócio.
  - Efetuar análise técnica (troca de dados).

FCS (Fatores Críticos de Sucesso):

- Envolvimento dos gestores de negócio (Vendas, Compras, Logística) e TI.
- Definição das métricas de sucesso da solução.

#### *Etapa 1 - Nomear responsáveis*

Atividades:

- Nomear responsáveis e definir papéis do time da empresa fornecedora.
- Nomear responsáveis e definir papéis do time cliente.

Entregas:

- Lista de responsáveis: nome, função no projeto, principais responsabilidades, produtos a gerar, produtos e fases a aprovar.

### *Etapa 2 - Definir lojas e produtos piloto*

#### Atividades:

- Definir quais produtos serão tratados pelo sistema nas fases de Simulação e Piloto.
- Definir quais lojas serão tratadas pelo sistema nas fases de Simulação e Piloto.

#### Entregas:

- Lista de produtos (nome e SKU).
- Lista de lojas (nome, endereço).

### *Etapa 3 - Definir métricas de sucesso*

#### Atividades:

- Definir valores esperados para as métricas:
  - Margem de erro da previsão de demanda.
  - Aumento de vendas (opcional).
  - Redução de ruptura.
  - Redução de perdas por validade (opcional).
  - Nível de estoque loja.

#### Entregas:

- Lista das métricas de sucesso com percentuais esperados.

### *Etapa 4 - Definir troca de dados e prazos*

#### Atividades:

- Definir principais grupos de dados a serem extraídos e carregados no sistema.
- Definir período a ser coberto na fase de Simulação.

- Definir prazos e frequência para a geração dos dados nas fases de Simulação e Piloto.

Entregas:

- Lista de arquivos de dados e variáveis a serem gerados e carregados.
- Fluxo macro de extração e carga de dados.

#### *Etapa 5 - Definir processo de utilização*

Atividades:

- Definir processo macro de uso do sistema junto aos responsáveis por: estimativa de demanda, planejamento de vendas, marketing, compras / estoque.

Entregas:

- Fluxo do processo de utilização da solução (planejamento de vendas, pedidos de compra, pedidos de abastecimento).

#### *Etapa 6 - Criar infraestrutura e usuários*

Atividades:

- Configurar a infraestrutura da solução para o cliente no provedor de *cloud*.
- Criar usuários e permissões no sistema para as fases de Simulação e Piloto.

Entregas:

- Sistema configurado no provedor de *cloud*.
- Usuários configurados.

### *Etapa 7 - Apresentar solução*

#### Atividades:

- Apresentar principais processos e telas do sistema aos líderes e usuários de negócio e TI.

#### Entregas:

- Solução apresentada aos membros do projeto e interessados.

### *Etapa 8 - Sanear dúvidas de dados*

#### Atividades:

- Identificar variáveis de dados faltantes nos sistemas internos (TI).
- Esclarecer significado e conteúdo de variáveis com eventuais dúvidas (TI, Negócios).

#### Entregas:

- Lista de arquivos de dados e variáveis atualizada.

### *Etapa 9 - Elaborar cronograma macro*

#### Atividades:

- Definir datas para o cumprimento das fases e etapas previstas no *roadmap* de implementação.
- Elaborar *checklist* com as tarefas principais.
- Definir forma de acompanhamento do progresso (ex: reuniões semanais, acompanhamento das atividades realizadas, métricas atingidas e qualidade dos dados)

Entregas:

- Cronograma macro com datas previstas para as fases do *roadmap*.
- *Checklist* de atividades (lista ou Kanban).

*Ponto de controle 1*

Atividades:

- Verificar se as métricas de sucesso foram definidas e aprovadas pela liderança.
- Verificar se foi elaborada a lista de arquivos, variáveis e o fluxo de extração e carga.
- Verificar se não há variáveis de dados importantes faltantes ou não esclarecidas.

## **Fase 2 – Prova de Conceito**

Objetivos:

- Avaliar se a solução atenderá aos objetivos de negócio do cliente por meio da execução de um ciclo de planejamento de demanda executado com dados reais.
- Os focos principais desta fase do *roadmap* de implantação são avaliar a qualidade dos dados, a disponibilidade de dados históricos e verificar se as recomendações geradas pelo sistema em relação à previsão de demanda, pedidos de compra e reposição de estoques, atenderão às expectativas do cliente, trazendo melhores resultados do que as soluções existentes.

FCS (Fatores Críticos de Sucesso):

- Disponibilidade dos dados com histórico de 2 anos e granularidade no nível dia, SKU, loja, vendas, estoque, preço, campanhas de marketing e temperatura / clima (se houver).
- Envolvimento de gestores, usuários e TI.
- Análise dos resultados x métricas de sucesso.



## **Fase 2.1 - Prova de Conceito - Preparação**

Objetivos:

- Mapeamento de-para e carga de dados.
- Treinamento dos modelos de ML.
- Configuração dos monitores e da operação (setup).

### *Etapa 1 - Enviar dados extraídos dos sistemas internos*

Atividades:

- Criar programas de extração dos sistemas internos.
- Executar as extrações e fornecer arquivos para carga.

Entregas:

- Arquivos de dados disponíveis para carga.

### *Etapa 2 - Definir periodicidade de atualização*

Atividades:

- Definir periodicidade de extração para cada arquivo.
- Validar periodicidade para os processos de estimativa do sistema.

Entregas:

- Lista de arquivos para carga atualizados com periodicidade.

### *Etapa 3 - Configurar monitores de qualidade de dados*

Atividades:

- Definir regras de qualidade para os arquivos / variáveis de dados.
- Configurar monitor de qualidade de dados de acordo com as regras definidas.

Entregas:

- Módulo monitor de qualidade configurado de acordo com as regras definidas.

*Etapa 4 - Documentação do mapa de dados*

Atividades:

- Identificar as variáveis dos arquivos de carga x variáveis do sistema.
- Documentar significado, de-para e regras de conversão.

Entregas:

- Mapa de de-para de dados para carga.

*Etapa 5 - Configurar horário de processamento*

Atividades:

- Definir horários / janelas para extração dos arquivos dos sistemas fonte.
- Definir horários / janelas para carga no sistema.
- Configurar horários de processamento das cargas.

Entregas:

- Horários de processamento de carga configurados no sistema (*schedule*).

### *Ponto de controle 2*

#### Atividades:

- Verificar se o mapa de dados está completo e aprovado.
- Verificar se todos os arquivos previstos foram gerados.

### **Fase 2.2 - Prova de Conceito - Simulação**

#### Objetivos:

- Analisar como o sistema se comportaria com 100% de aderência.

#### *Etapa 1 - Simular operação retroativa*

#### Atividades:

- Carregar dados de período anterior.
- Executar operação retroativa utilizando o sistema com dados de período anterior.

#### Entregas:

- Carga de dados de período retroativo efetuada.
- Resultados da simulação com operação retroativa.

#### *Etapa 2 - Analisar os resultados e validar*

#### Atividades:

- Analisar os resultados do sistema comparando com as previsões e resultados anteriores efetuadas sem o sistema.

Entregas:

- Análise das recomendações do sistema x situação real retroativa (vendas, pedidos de compra, pedidos de abastecimento) e aprovação.

*Ponto de controle 3*

Atividades:

- Verificar se as métricas da simulação atendem aos valores definidos para as métricas de sucesso.

### **Fase 3 - Piloto**

Objetivos:

- Aplicação prática e aderência ao processo em operação com dados reais e atuais.

FCS (Fatores Críticos de Sucesso):

- Envolvimento de gestores, usuários e TI.
- Uso do sistema em situações reais.
- Aprovação das métricas para prosseguir com a fase de Expansão.

*Etapa 1 - Colocar pedidos utilizando a ferramenta*

Atividades:

- Executar simulações com o sistema.
- Colocar no sistema os pedidos de compra e abastecimento de acordo com as estimativas de demanda / vendas por loja.

Entregas:

- Pedidos colocados no sistema.

*Etapa 2 - Enviar dados periodicamente para carga*

Atividades:

- Executar processo periódico de extração de dados dos sistemas internos (TI).
- Enviar dados periodicamente para área de arquivos de carga.
- Executar processo de carga agendado / configurado no sistema.

Entregas:

- Dados carregados periodicamente na base de dados do sistema.

*Etapa 3 - Avaliar sistema*

Atividades:

- Executar todas as funções do sistema (estimativas, recomendações de pedidos e análises).
- Acompanhar resultados nas lojas piloto.
- Gerar relatório de avaliação com base nas métricas de sucesso.

Entregas:

- Relatório evolutivo de avaliação dos resultados do sistema e aprovação ao final do Piloto.

#### *Etapa 4 - Treinar usuários*

##### Atividades:

- Acompanhar operação do sistema pelos usuários.
- Esclarecer dúvidas e fornecer orientações para o uso do sistema.

##### Entregas:

- Usuários treinados.

#### *Etapa 5 - Acompanhar troca de dados*

##### Atividades:

- Acompanhar processo de carga de dados.
- Acompanhar sistema de monitoramento da qualidade de dados.
- Acompanhar integração para geração de pedidos nos sistemas internos (se houver).
- Efetuar ajustes no processo de extração se necessário (TI).
- Efetuar ajustes nos processos de carga, monitoramento da qualidade e integração de pedidos se necessário (fornecedora).

##### Entregas:

- Ajustes nos processos de extração, carga e integração de dados.

#### *Etapa 6 - Ativar suporte*

##### Atividades:

- Definir contatos do cliente para acionamento do suporte.
- Ativar “conta” do cliente no sistema de monitoramento e suporte.

Entregas:

- Suporte ativado.

*Etapa 7 - Efetuar acompanhamento gerencial*

Atividades:

- Promover reuniões com lideranças de negócio e TI para apresentar o acompanhamento do sistema e esclarecer dúvidas.
- Realizar reuniões de acompanhamento de progresso das atividades e metas.

Entregas:

- Relatório de acompanhamento das métricas de sucesso.
- *Checklist* atualizado.
- Cronograma macro atualizado.

*Etapa 8 - Elaborar plano de rollout*

Atividades:

- Definir novas lojas e produtos a serem incluídas no sistema.
- Elaborar plano de expansão com as lojas e produtos a serem incluídos mensalmente.

Entregas:

- Plano de *rollout* (novas lojas e produtos a cada mês).

#### *Ponto de controle 4*

##### Atividades:

- Verificar se o sistema foi usado plenamente pelos usuários em situações reais.
- Verificar se as métricas de sucesso foram atingidas na fase Piloto.
- Verificar se houve aprovação das operações do sistema pelos usuários.
- Verificar se houve envolvimento e aprovação do sistema e dos resultados pelos líderes de negócio / responsáveis pelas funções de previsão de demanda, pedidos e abastecimento.

#### **Fase 4 - Expansão**

##### Objetivos:

- Uso continuado da ferramenta com expansão para novas lojas e produtos.

##### FCS (Fatores Críticos de Sucesso):

- Mudança de processos tendo o sistema como elemento principal da previsão de demanda.

#### *Etapa 1 - Executar as ondas de rollout*

##### Atividades:

- Incluir mensalmente no sistema os produtos e lojas planejados.
- Alterar rotinas de extração de dados para incluir novos produtos e lojas.

##### Entregas:

- Novas lojas e produtos carregados mensalmente na solução.



### *Etapa 2 - Monitorar integração*

#### Atividades:

- Executar automaticamente monitor de integrações e de qualidade de dados.
- Apontar erros ocorridos nas cargas e integrações (ex: inconsistências).
- Efetuar ajustes nos processos de carga e integração.

#### Entregas:

- Relatório do monitor de integrações.
- Ajustes efetuados nos processos de carga e integração.

### *Etapa 3 - Suporte técnico*

#### Atividades:

- Prestar suporte técnico a partir de chamados do cliente.

#### Entregas:

- Relatório mensal de suporte técnico efetuado.

### *Etapa 4 - Atualizar modelos*

#### Atividades:

- Verificar se os novos produtos incluídos no *rollout* têm características diferentes e necessitam atualização dos modelos preditivos.
- Atualizar modelos para atender aos novos produtos.
- Efetuar treinamento dos modelos de ML.

Entregas:

- Modelos de ML atualizados.

#### *Etapa 5 - Melhoria contínua do software*

Atividades:

- Atualizar programas, telas, modelos na solução do cliente de acordo com as evoluções ocorridas no sistema base da fornecedora

Entregas:

- Melhorias no sistema disponíveis para uso do cliente

### **Fases paralelas - Gestão do projeto e Mudança organizacional**

Em paralelo às fases do *roadmap* de implementação ocorrem as tarefas de Gestão de Projeto e Gestão da Mudança Organizacional, de acordo com metodologias próprias da organização cliente.

Não há obrigatoriedade de utilizar um método específico de gestão de projetos, bastando que haja um cronograma ou plano de datas, que as atividades e entregas sejam controladas e, que seja comunicado aos envolvidos o andamento do projeto.

A gestão da mudança organizacional e de processos é de responsabilidade do executivo líder do projeto pelo cliente. A participação das lideranças e usuários chave no projeto de implementação facilita a aceitação das mudanças que são intensificadas na fase de Expansão.

### **3.4 Etapa 4 - Demonstração em campo**

Esta seção contém o quarto passo da DSRM, demonstrando a viabilidade de uso do *roadmap* proposto em uma implementação real.


Os dois tópicos a seguir apresentam as características do sistema implementado com o uso do *roadmap* e detalhes do projeto de implementação (contexto).

### 3.4.1 Características do sistema implementado com uso do *roadmap*

O sistema fornecido pela empresa pesquisada oferece uma solução de planejamento, monitoramento e recomendações para a gestão da cadeia de suprimentos, por meio de uma plataforma tecnológica baseada em ML, com modelos de dados e algoritmos base pré-elaborados do tipo Gradient Boosting, operando no modelo SaaS (Solution as a Service) hospedado em plataforma AWS (Amazon Web Services), utilizando sistema de banco de dados Elastic Search e linguagem principal de programação Python.

Os principais objetivos de negócio da solução são, a partir de uma melhor previsão do comportamento da demanda, recomendar as quantidades ideais para os pedidos de compra e de reabastecimento (Figura 18).

**Figura 18 – Objetivos de negócio da solução de ML**



**Fonte:** Resultados da pesquisa, 2020.

A plataforma contempla funcionalidades com foco em otimização de pedidos, reposição, previsão de vendas e monitoramento de demanda. A partir dos dados fornecidos pela empresa cliente o sistema calcula a estimativa de demanda futura, auxiliando na elaboração de ordens de compra mais adequadas, na definição do melhor mix e volume de produtos por cliente, por região e, na gestão da reposição de estoques em depósitos e lojas.

A quantidade de compras ideal trata da aquisição, ou importação, e distribuição para os Centros de Distribuição no curto, médio e longo prazo, considerando os espaços disponíveis para armazenagem, restrições financeiras e logísticas.

Quantidades ideais de reabastecimento são sugeridas para lojas e distribuidores considerando campanhas, promoções, estratégias de marketing, sazonalidades e indicadores macroeconômicos.

As principais variáveis de dados obtidas dos sistemas internos da empresa cliente são: vendas, estoque e preço no nível de granularidade de data, produto (SKU) e loja, além de informações sobre campanhas de marketing e vendas, em um período histórico de dois anos.

Os usuários têm acesso a telas de parametrização e painéis de indicadores construídos sobre uma ferramenta padrão de mercado de Business Intelligence (BI). Variáveis externas como o clima são informados ao sistema por digitação, através das telas de interface do sistema, ou carga de arquivos, por meio de um módulo de importação (*hub* de dados exógenos).

Uma visão geral do fluxo de dados e principais interfaces para os usuários do sistema é apresentada na Figura 19.

**Figura 19 – Fluxo de dados e interfaces do sistema implantado com uso do *roadmap***



**Fonte:** Resultados da pesquisa, 2020.

### 3.4.2 Contexto de aplicação do *roadmap*

A demonstração do uso do *roadmap* proposto ocorreu durante a implementação do sistema de ML, descrito no tópico anterior, em uma empresa fabricante e distribuidora de produtos alimentícios refrigerados e congelados, incluindo derivados de leite e proteína animal.

Os produtos escolhidos para as fases de Prova de Conceito e Piloto foram Embutidos, Margarina, Cortes premium, Congelados.

A empresa possui um Centro de Distribuição e 326 lojas, sendo os principais desafios de negócio a resolver com o novo sistema: a redução de perda por data de validade dos produtos e redução de ruptura (falta de produtos nas lojas).

A equipe de projeto pode ser vista no Quadro 6, composta por representantes da empresa fornecedora: o Presidente, atuando no relacionamento executivo, o Diretor de Tecnologia, liderando a implementação, e um Analista de Implantação responsável pelas integrações, além da empresa cliente: um representante das áreas de negócio (Líder de Negócio), um Analista de TI, responsável por fornecer os arquivos de dados solicitados e, um Cientista de Dados para efetuar definições e análise dos dados a serem carregados no sistema.

O período de implantação do projeto foi de 05/02/2020 a 15/05/2020 e as entregas foram geradas de acordo com as entregas previstas no *roadmap*, embora com atrasos nas fases de Alinhamento e Preparação.

A partir de março o trabalho passou a ser executado majoritariamente de forma remota, com ao menos uma reunião formal (virtual) semanal de acompanhamento das fases e entregas previstas no *roadmap*, além das aprovações necessárias para os pontos de controle. Ferramentas adicionais foram utilizadas para o controle das atividades, como *checklists* e painel Kanban.

**Quadro 6 – Perfil do time de implementação**

#	Pertence à Fornecedor ou Cliente	Cargo	Papel na implementação	Responsabilidades na implementação	Jr PI Sr
1	Fornecedora	Presidente	Patrocinador	Relacionamento executivo, aprovações executivas	Sr
2	Fornecedora	Diretor de Tecnologia	Líder do Projeto	Liderança do projeto	Sr
3	Fornecedora	Analista de Implantação	Analista de Implantação	Mapear dados, desenvolver integrações c/ sistemas internos, configurar o sistema	Jr
4	Cliente	Gerente (Customer Services)	Líder de Negócio	Definições de negocio, estratégia de implantação e evolução, aprovações	Sr
5	Cliente	Cientista de Dados	Analista de dados	Analisar integração de dados e resultados das fases de Simulação e Piloto	Jr
6	Cliente	Analista de TI	Analista de integrações	Gerar extrações de dados internos para carga no sistema	Jr

**Fonte:** Resultados da pesquisa, 2020.

### 3.5 Etapa 5 - Avaliação pelos envolvidos

O quinto passo da DSRM consistiu na avaliação da efetividade do uso do *roadmap*, por meio de um questionário respondido em entrevistas semiestruturadas. Para cada objetivo estabelecido para o *roadmap*, definidos na Etapa 2 da DSRM, foram elaboradas questões de avaliação mencionando os respectivos autores que fundamentam as questões (Quadro 7).

**Quadro 7 – Questões de avaliação do artefato *roadmap***

Objetivos do <i>roadmap</i>	Questão	Fundamentação
a) Orientar as atividades de profissionais de negócio e técnicos	1-A definição clara das fases, etapas, entregas e responsáveis em um <i>roadmap</i> de implementação serve como orientação aos envolvidos, técnicos e de negócio? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	Perry e Uys (2010) Saltz e Dewar (2019) Shearer (2000)
	2-Na sua opinião o <i>roadmap</i> de implementação facilita / acelera o andamento da implementação ao definir fases, produtos, responsáveis e pontos de controle? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	
	3- Os passos executados e produtos entregues ocorreram de acordo com o <i>roadmap</i> ? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	
	4-As fases, etapas, produtos, responsáveis e pontos de controle do <i>roadmap</i> estão adequados e suficientes para orientar a implementação da solução? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	
	5-Na sua opinião, o <i>roadmap</i> serve como instrumento de comunicação entre todos os envolvidos, no sentido de deixar claro o caminho a ser percorrido, responsabilidades e resultados esperados? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	
b) Reduzir riscos de implementação	6-Na sua opinião o <i>roadmap</i> reduz riscos de implementação ao indicar pontos de verificação de qualidade de dados, do modelo preditivo / algoritmos e atendimento dos requisitos de negócio? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	Giebel et al. (2009) Perry e Uys (2010)
	7-Houve aprovação formal dos responsáveis pelas verificações nos pontos de controle do <i>roadmap</i> por parte da empresa cliente? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	
c) Incentivar o engajamento das lideranças de negócio	8-Na sua opinião o <i>roadmap</i> de implementação com fases, entregas e responsabilidades facilita o engajamento das lideranças de negócio interessadas na solução? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	Chofreh et al. (2014) Crews (2019) Kostoff et al. (2004)
	9-O principal responsável da empresa cliente pelas estimativas de demanda aprovou as projeções e recomendações do sistema nas fases de Prova de Conceito e Homologação? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	
d) Promover alinhamento com o <i>roadmap</i> estratégico	10-Na sua opinião é importante para o sucesso da implementação e adoção da solução pela empresa cliente a existência prévia de um <i>roadmap</i> estratégico de negócios e tecnologia que inclua ML e IA? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	Laat e McKibbin (2003) Moehrle et al. (2013) Phaal e Muller (2009)
	11-A empresa cliente possuía um <i>roadmap</i> estratégico de negócios e tecnologia antes de adotar a solução de ML para previsão de demanda? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	
	12-A solução fornecida estava alinhada com o plano de negócios e tecnologia da empresa cliente? Concordo fortemente ( ) Concordo ( ) Discordo ( ) Comentários	

**Fonte:** Resultados da pesquisa, 2020.

As questões foram respondidas por três profissionais da fornecedora que participaram da implementação, cujos resultados são apresentados no Quadro 8 contendo a soma da pontuação de cada resposta e de cada objetivo, bem como o percentual de atingimento em relação à pontuação máxima. As respostas obtidas nas entrevistas também foram consideradas para uma análise qualitativa observada nos comentários a seguir.

Os resultados das entrevistas mostram que o primeiro objetivo, de orientar as atividades do time de projeto, técnicos e de negócio, foi atingido (97%), bem como confirmou a expectativa de servir como ferramenta de comunicação entre todos os envolvidos.

O *roadmap* foi considerado não completamente adequado e suficiente por um respondente, sugerindo tornar mais claro o entendimento das entregas e atividades da fase Expansão.

A redução de riscos de implementação, que é o segundo objetivo do *roadmap*, por meio dos pontos de controle de qualidade de dados e de atingimento de métricas de negócio, exigindo aprovação formal de representantes do cliente, foi considerada eficiente, atingindo a pontuação máxima (100%).

Os entrevistados consideraram que o *roadmap* reduz riscos de continuidade de trabalhos com baixa qualidade ou sem atingir as metas de negócio quando comparado com suas experiências em projetos que não utilizaram o artefato.

O terceiro objetivo, quanto ao engajamento das lideranças, obteve pontuação satisfatória (92%).

Na opinião de um respondente o fator que causa maior engajamento são os resultados de negócio atingidos, embora considere que o *roadmap* promove uma relação positiva com as lideranças ao tornar claras as fases, metas e resultados.

O alinhamento entre *roadmap* estratégico e de implementação, quarto objetivo, obteve resultado inferior aos demais (78%).

Um dos entrevistados entende que a existência prévia de um *roadmap* estratégico de tecnologia e negócios, prevendo ML e IA, não influencia na implementação e na adoção efetiva da nova solução e tecnologia, desde que os resultados esperados de negócio sejam atingidos. Os demais consideraram que a predisposição da empresa refletida num plano estratégico facilita a aceitação, tanto pelas lideranças quanto pelos usuários, especialmente na fase de Expansão do sistema.

### Quadro 8 – Pontuação do uso do *roadmap*

Objetivos do <i>roadmap</i>	Questão	Quant. de respostas	Pontuação total da questão	Pontuação total do objetivo	% de atingimento
a) Orientar as atividades de profissionais de negócio e técnicos	1-A definição clara das fases, etapas, entregas e responsáveis em um <i>roadmap</i> de implementação serve como orientação aos envolvidos, técnicos e de negócio?	3	3	14,5	97%
	2-Na sua opinião o <i>roadmap</i> de implementação facilita / acelera o andamento da implementação ao definir fases, produtos, responsáveis e pontos de controle?	3	3		
	3- Os passos executados e produtos entregues ocorreram de acordo com o <i>roadmap</i> ?	3	3		
	4-As fases, etapas, produtos, responsáveis e pontos de controle do <i>roadmap</i> estão adequados e suficientes para orientar a implementação da solução?	3	2,5		
	5-Na sua opinião, o <i>roadmap</i> serve como instrumento de comunicação entre todos os envolvidos, no sentido de deixar claro o caminho a ser percorrido, responsabilidades e resultados esperados?	3	3		
b) Reduzir riscos de implementação	6-Na sua opinião o <i>roadmap</i> reduz riscos de implementação ao indicar pontos de verificação de qualidade de dados, do modelo preditivo / algoritmos e atendimento dos requisitos de negócio?	3	3	6	100%
	7-Houve aprovação formal dos responsáveis pelas verificações nos pontos de controle do <i>roadmap</i> por parte da empresa cliente?	3	3		
c) Incentivar o engajamento das lideranças de negócio	8-Na sua opinião o <i>roadmap</i> de implementação com fases, entregas e responsabilidades facilita o engajamento das lideranças de negócio interessadas na solução?	3	2,5	5,5	92%
	9-O principal responsável da empresa cliente pelas estimativas de demanda aprovou as projeções e recomendações do sistema nas fases de Prova de Conceito e Homologação?	3	3		
d) Promover alinhamento com o <i>roadmap</i> estratégico	10-Na sua opinião é importante para o sucesso da implementação e adoção da solução pela empresa cliente a existência prévia de um <i>roadmap</i> estratégico de negócios e tecnologia que inclua ML e IA?	3	2	7	78%
	11-A empresa cliente possuía um <i>roadmap</i> estratégico de negócios e tecnologia antes de adotar a solução de ML para previsão de demanda?	3	2		
	12-A solução fornecida estava alinhada com o plano de negócios e tecnologia da empresa cliente?	3	3		

**Fonte:** Resultados da pesquisa, 2020.

Após a avaliação da pontuação dos questionários, uma avaliação de caráter qualitativo foi efetuada a partir da lista das principais dificuldades de implementação e facilitadores identificados na literatura e no mercado. O Quadro 9 apresenta as dificuldades, os elementos facilitadores, os autores de referência e as respostas obtidas nas entrevistas, identificando como o *roadmap* endereça cada item listado.

É possível observar no Quadro 9 que os principais objetivos do *roadmap* avaliados nas entrevistas foram cumpridos. Dos dez itens de dificuldade de implementação, quatro foram endereçados fortemente e seis parcialmente. Quanto aos fatores que facilitam a implementação, os quatro temas listados foram atendidos fortemente.

Adicionalmente, a importância da fase de Prova de Conceito (POC) é destacada como forma de validar a inovação tecnológica e reduzir riscos de implementações mal sucedidas

Ainda no sentido de redução de riscos, a utilização de uma solução previamente construída evita riscos de utilização de componentes de software não maduros.

Quanto aos aspectos de natureza humana e organizacional, o medo das mudanças, a aversão ao risco e a necessidade de engajamento dos envolvidos foram apontados na pesquisa como fatores importantes para o sucesso da implementação e adoção, sendo endereçados fortemente pelo *roadmap*.



### Quadro 9 – Resultados da avaliação de dificuldades e facilitadores de implementação x *roadmap*

Autores	Descrição das dificuldades e facilitadores	O Roadmap endereça:			Como o roadmap endereça as dificuldades e facilitadores:
		Forte-mente	Parcial-mente	Não en-dereça	
DIFICULDADES DE IMPLEMENTAÇÃO					
Sapp (2018)	Incapacidade de articular um roadmap que defina a estratégia e o plano de implementação	X			Modelo pronto e adaptável que Inclui fases de implementação e expansão
Tsoumakas (2018)	Função de estimativa da demanda realizada por especialistas	X			Promove a participação efetiva dos especialistas na implementação
Crews (2019)	Descrença nas previsões	X			Promove a participação de especialistas e prevê fases de simulação (comparativos) e piloto
	Resistência à delegação da função de previsão	X			Exige aprovação executiva do sistema e promove adoção gradativa (Fase Expansão)
	Falta de contexto estratégico		X		Promove o alinhamento com objetivos de negócio e tecnologia, desde que exista um <i>roadmap</i> estratégico prévio
Tsoumakas (2018); Proctor e Fowler (2019)	Qualidade de dados e/ou falta de dados históricos		X		Pontos de controle não permitem avançar sem dados de qualidade e suficientes
Tsoumakas (2018)	Dificuldade de escolha de algoritmos		X		Sugere a adoção de uma solução pré-construída a ser validada pelos resultados de negócio
Domingos (2012)	Dificuldade de escolha de modelos de aprendizado		X		Sugere a adoção de uma solução pré-construída que pode ser validada tecnicamente
Sun <i>et al.</i> (2017)	Ferramentas e bibliotecas de software de baixa qualidade		X		Fases de Simulação e Evolução permitem a implementação da mudança gradativamente
Proctor e Fowler (2019)	Medo das mudanças e aversão ao risco		X		
FACILITADORES DE IMPLEMENTAÇÃO					
Kostoff et al. 2004; Chofreh et al. 2014	Bons <i>roadmaps</i> são elaborados pelos interessados e pela equipe de	X			Elaborado pelo pesquisador e a equipe de implementação
Bendavid e Cassivi (2012); Jobin, Le Masson e Hooge (2020)	A POC é uma etapa crítica em processos de inovação para demonstrar a viabilidade e em projetos de TI com novas tecnologias	X			Fase de Prova de Conceito (POC) prevista incluindo simulação retroativa para comparação das previsões anteriores x com uso do sistema
Crews (2019)	Envolvimento dos líderes da organização, de especialistas em marketing, produtos e clientes	X			Promove a participação de líderes e especialistas, tanto na utilização quanto nas validações
Chofreh <i>et al.</i> (2014)	Os profissionais precisam ser guiados por um <i>roadmap</i> coerente para a implementação de sistemas ERP	X			Semelhante aos <i>roadmaps</i> para ERP, serve como guia para o time de implementação de solução de ML em previsão de demanda

Fonte: Resultados da pesquisa, 2020.

### 3.6 Etapa 6 - Comunicação ao meio acadêmico e ao mercado

A última etapa da DSRM é a divulgação do *roadmap* proposto.

Este relatório de dissertação para a comunidade acadêmica é uma das formas de comunicação utilizadas.

Publicações em periódicos, congressos, sítios acadêmicos e profissionais serão solicitadas buscando a ampliação da divulgação do artefato.

No meio empresarial, os gestores da empresa fornecedora passaram a utilizar o *roadmap*, dessa forma comunicando e disseminando a utilização em seus clientes, desde a fase de apresentação e venda da solução de ML até a implementação.

## 4 CONSIDERAÇÕES FINAIS

Este capítulo contém as considerações do pesquisador sobre os resultados obtidos no estudo e o atendimento aos objetivos estabelecidos.

A primeira seção trata do objetivo principal do trabalho, ou seja, a elaboração de um roadmap, os resultados obtidos com sua utilização e principais características.

Em seguida, um resumo dos ganhos de negócio para as empresas ao implementar uma solução de ML para previsão de demanda, motivando a iniciativa e o uso do roadmap.

A última seção apresenta as contribuições do estudo à pesquisa acadêmica e ao mercado.

### 4.1 *Roadmap* como facilitador de implementação de sistemas de ML

Os resultados deste trabalho possibilitaram responder à questão de pesquisa sobre como alcançar melhores resultados em projetos de implementação da tecnologia de ML na previsão de demanda de bens de consumo, por meio da utilização de um *roadmap*. O *roadmap* proposto foi elaborado a partir de análise da literatura, de pesquisa da situação de mercado e da experiência de uma empresa implementadora de sistemas com ML, sendo orientado à implementação e para uso em nível gerencial. Sua demonstração e avaliação em um caso real mostrou bons resultados ao atingir os objetivos da implementação, servindo como um guia aos envolvidos, promovendo o engajamento dos principais interessados e reduzindo riscos relacionados à baixa qualidade.

A utilização da metodologia DSRM permitiu atender aos objetivos específicos de: (i) elaborar o referencial teórico de suporte à pesquisa, (ii) delinear o problema e as motivações para sua solução, (iii) desenvolver o roadmap, (iv) demonstrar a efetividade de sua aplicação em campo (caso real), e (v) avaliar a sua utilização.

O referencial teórico (i) apresenta os ganhos que podem ser obtidos com o uso do ML na previsão de demanda de bens de consumo e o grande interesse das empresas. Entretanto, mostra também as dificuldades encontradas pelas empresas para a implementação de sistemas com esta tecnologia, fazendo com que adiem seus planos de implementação.

Assim, o principal problema a ser endereçado (ii) é a falta de orientação para implementação de sistemas produtivos com uso de ML. Para resolver este problema foi definido um artefato no formato de *roadmap*, com o objetivo principal de servir como ferramenta orientadora para a implementação de um sistema produtivo com ML para previsão de demanda

de bens de consumo, reduzindo dificuldades mencionadas na literatura, facilitando a adoção e antecipando a realização dos benefícios esperados.

O *roadmap* foi desenvolvido (iii) a partir de práticas encontradas na literatura e na situação de mercado, enriquecido com a experiência de implementações de um sistema pré-elaborado por uma empresa fornecedora em seus clientes, com foco em otimização de compras e de reposição de estoques a partir de melhores previsões de demanda com ML.

A demonstração (iv) e a avaliação (v) do *roadmap* foram efetuadas em um ambiente real de implementação de um sistema de ML para previsão de demanda pela empresa fornecedora em um de seus clientes, com a participação de técnicos experientes da fornecedora, além de técnicos, usuários e líderes de negócio da empresa cliente fabricante de alimentos refrigerados, cujos resultados são comentados a seguir.

A avaliação dos resultados da utilização do *roadmap* pode ser feita a partir das metas específicas definidas para o artefato na Etapa 2 da DSRM: orientar as atividades, reduzir riscos de implementação, incentivar o engajamento das lideranças e promover o alinhamento com *roadmap* estratégico.

Os resultados das entrevistas mostram que o *roadmap* elaborado atende ao objetivo proposto para o artefato de facilitar a implementação, ao cumprir a meta de orientar as atividades dos envolvidos e tornar claras as responsabilidades.

Quanto à meta de redução de riscos, a inclusão de uma fase de Prova de Conceito e de pontos de controle de qualidade foram considerados fatores chave. Um dos principais diferenciais observados no *roadmap* proposto em relação à literatura e à situação de mercado foi a inclusão da fase denominada Prova de Conceito, evitando que um projeto prossiga quando a empresa não possui dados adequados, com qualidade e volume suficiente para obter os resultados de negócio esperados, evitando custos adicionais e o desgaste da equipe envolvida. Já os pontos de controle de qualidade, com checklists de verificação, auxiliam o time de projeto a ter foco nos requisitos necessários para o sistema e não prosseguir com itens faltantes ou sem qualidade.

O engajamento das lideranças e de representantes das áreas de negócio a partir do *roadmap* foi considerado efetivo pelo time de implementação, por exigir a participação ativa do cliente. A participação foi observada durante todas as fases do *roadmap* (Alinhamento, Prova de Conceito, Piloto e Expansão), promovendo a utilização do sistema implementado e a adoção como principal fonte de informação para a gestão da demanda. Soluções de ML e IA atuais devem permitir a atuação de times multidisciplinares no projeto de implementação, com

profissionais técnicos, de dados e de negócio atuando em conjunto, o que é contemplado no *roadmap* proposto por meio da definição das responsabilidades de cada tipo de profissional nas fases e produtos gerados, servindo como ferramenta de comunicação aos interessados.

A meta de alinhar a implementação ao *roadmap* estratégico e tecnológico da organização cliente foi considerada importante pelos entrevistados, mas, não imprescindível. Embora a falta de um *roadmap* estratégico contemplando ML e IA é mencionada na literatura como fator inibidor para adoção de ML pelas empresas, a pesquisa de campo mostrou que a existência prévia do plano estratégico é importante, especialmente na fase de Expansão, porém, não imprescindível.

Algumas características do *roadmap* proposto são destacadas a seguir quanto ao alinhamento com o referencial teórico, o tipo de sistema contemplado, limitações e melhorias possíveis.

O artefato foi elaborado de acordo com a estrutura e conceitos propostos por diversos autores. As fases e etapas estão alinhadas com os *roadmaps* para implementação de sistemas analíticos encontrados em publicações científicas e em soluções de mercado, com destaque para o entendimento do negócio, a compreensão e a modelagem dos dados.

O *roadmap* proposto considera preferencialmente a adoção de um sistema de mercado por conter alguns itens facilitadores para a implementação de sistemas de previsão de demanda com ML identificados nesta pesquisa, como: a) plataformas de solução oferecidas por empresas de tecnologia e serviços, à serem parametrizadas e adaptadas em cada cliente; b) algoritmos de ML disponíveis nos sítios e nos serviços prestados por fornecedores de centros de dados em nuvem (*cloud systems*) e c) ambientes computacionais em nuvem utilizados sob demanda. Adicionalmente, uma plataforma ou solução de mercado reduz uma das dificuldades mencionadas para adoção de ML que é a escolha entre a grande quantidade de algoritmos disponíveis.

Embora elaborado com foco na previsão de demanda de bens de consumo, com métricas de sucesso específicas para este segmento, a partir da implementação de um sistema de mercado, o *roadmap* proposto é possível de ser utilizado para outras soluções que envolvam ML e análises preditivas, desde que sejam adaptadas as métricas e termos específicos.

Uma limitação observada neste trabalho é a demonstração do *roadmap* em uma única implementação real, o que pode motivar novos estudos sobre a utilização em outras empresas com diferentes tipos de produtos de consumo.

Uma possível melhoria foi identificada durante a avaliação, consistindo em incluir atividades na fase de Expansão que tornem mais claras as ações necessárias para promover as

mudanças organizacionais e de processos, podendo envolver parceiros externos, facilitando assim a utilização plena da solução e o alcance dos benefícios de negócio.

#### **4.2 Ganhos de negócio pelo uso de ML na previsão de demanda de bens de consumo**

É possível observar na literatura que prever o comportamento do consumidor é um fator crítico de sucesso ao longo do tempo para as empresas, que buscam constantemente o aprimoramento de processos e novas tecnologias que possibilitem o aumento da acuracidade da previsão de demanda e, em consequência, melhorar o planejamento de produção, os resultados de vendas e a eficiência logística.

A capacidade de tratamento de grandes volumes de dados e da combinação dos múltiplos fatores (variáveis) que influenciam as vendas, faz com que as técnicas de ML sejam uma opção vantajosa para as empresas do setor de bens de consumo, face a crescente digitalização do varejo em que cada vez mais informações estão disponíveis sobre o comportamento de compra dos consumidores, incluindo suas reações à diferentes produtos e ofertas, coletadas nas lojas ou canais de internet, por meio de imagens ou do histórico de navegação nos sites de comércio eletrônico.

As características de rapidez de processamento e de tratamento de inúmeras variáveis de atributos de produtos favorecem o uso pelas empresas de moda, bem como algoritmos capazes de prever com maior precisão a demanda de itens inovadores, que também atendem necessidades do ramo de tecnologia.

Os benefícios mais relevantes encontrados nesse estudo pela aplicação de ML à previsão de demanda, foram a redução de perdas de alimentos por término data de validade e a redução do índice de ruptura, ou falta de produtos desejados pelos clientes nos pontos de venda.

#### **4.3 Contribuições**

Este estudo contribui com as empresas do setor de bens de consumo no processo de decisão de adoção e implementação, por meio de um *roadmap*, de uma solução tecnológica com ML aplicado na melhoria do nível de acurácia de previsão de demanda.

Para as empresas de bens de consumo que ainda não estão seguras quanto aos benefícios de negócio que um sistema de ML para previsão de demanda pode trazer, este estudo oferece uma análise sobre os setores e produtos com maior potencial de benefício e quais os tipos de resultados podem ser obtidos em gestão de vendas, estoques e logística.

A falta de orientações para as empresas de como implementar sistemas analíticos com ML e IA, é contemplada pelo *roadmap* elaborado neste estudo a partir de casos reais, de recomendações encontradas na literatura e de práticas adotadas pelo mercado. O *roadmap* indica as principais fases, etapas, entregas e fatores críticos, bem como endereça dificuldades de implementação identificadas na pesquisa como o engajamento dos principais interessados e a redução de riscos de implementação por baixa qualidade de dados ou resultados de negócio insatisfatórios.

A contribuição acadêmica se dá pela extensão do conhecimento da ciência de dados ao apresentar um *roadmap* de implementação de ML para previsão de demanda de bens de consumo. É possível encontrar na literatura abordagens para *roadmaps* estratégicos de tecnologia que suportam os planos de negócios de uma organização, bem como *roadmaps* de implementação de sistemas que viabilizam a oferta de produtos e serviços utilizando as tecnologias previstas. Porém, nota-se grande foco nos sistemas de gestão empresarial (ERP), com menor destaque para sistemas analíticos envolvendo ML e IA.

## REFERÊNCIAS

AKABANE, G. **Gestão estratégica das tecnologias cognitivas: conceitos, metodologias e aplicações**. São Paulo: Saraiva, 2018.

ALTEXSOFT. **Demand Forecasting Methods: Using Machine Learning and Predictive Analytics to See the Future of Sales**. Disponível em: <https://www.altexsoft.com/blog/demand-forecasting-methods-using-machine-learning/>. 11 Nov, 2019. Acesso em 24/01/2020.

ARUNRAJ, N.S.; AHRENS, D. A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. **International Journal of Production Economics**, Vol.170, p.321-335, 2015.

ARVAN, M.; FAHIMNIA, B.; REISI, M.; SIEMSEN, E. Integrating Human Judgement into Quantitative Forecasting Methods: A Review. **Omega The International Journal of Management Science**, 2018.

BENDAVID, Y.; CASSIVI, L. A ‘living laboratory’ environment for exploring innovative RFID-enabled supply chain management models, *International Journal of Product Development*, 17:1-2, 94-118, 2012.

BERNARDI, L.; MAVRIDIS, T.; ESTEVEZ, P. **150 Successful Machine Learning Models: 6 Lessons Learned at Booking.com**. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining - KDD 2019.

BERTAGLIA, P.R. **Logística e gerenciamento da cadeia de abastecimento**. 3. ed. São Paulo: Saraiva, 2016.

CHEN, F.L.; OU, T.Y. **Sales forecasting system based on Gray extreme learning machine with Taguchi method in retail industry**. *Expert Systems with Applications*, 2011.

CHEN, I.F.; LU, C.J. Sales forecasting by combining clustering and machine-learning techniques for computer retailing. **The Natural Computing Applications Forum**, 2016.

CHOFREH, A.G.; GONIB, F.A.; SHAHAROUNC, A.M.; ISMAILC, S. Review on Enterprise Resource Planning Implementation Roadmap: Project Management Perspective. **Sains Humanika**, p. 135–138, Penerbit UTM Press. 2014.

CHOI, T.M.; HUI, C.L.; LIU, N.; NG, S.F.; YU, Y. Fast fashion sales forecasting with limited data and time. **Decision Support Systems**, 2014.

CHRISTOPHER, M.; LEE, H. Mitigating supply chain risk through improved confidence. **International Journal of Physical Distribution and Logistics Management**, Vol. 34 No. 5, p. 388-396, 2004.

COHEN, M.C.; LEUNG, N.H.Z.; PANCHAMGAM, K.; PERAKIS, G.; SMITH, A. The Impact of Linear Optimization on Promotion Planning. **Operations Research**, 2017.

CRESWELL, J.W. Research Design. **Qualitative, Quantitative, and Mixed Methods Approaches**. 4th ed. Sage, 2014.

CREWS, C. What Machine Learning Can Learn from Foresight: A Human-Centered Approach. **Research-Technology Management**, 62(1), 30–33. 2019.

DA SILVA, I.D.; MOURA, M.D.C.; DIDIER LINS, I.; LÓPEZ DROGUETT, E.; BRAGA, E. Non-Stationary Demand Forecasting Based on Empirical Mode Decomposition and Support Vector Machines. **IEEE Latin America Transactions**, 15 (9), art. no. 8015086, p. 1785-1792, 2017.

DE LAAT, B.; MCKIBBIN, S. The Effectiveness of Technology Road Mapping: Building a Strategic Vision. **Ministry of Economic Affairs**, 2003.

DOGANIS, P.; ALEXANDRIDIS, A.; PATRINOS, P.; SARIMVEIS, H. **Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing**, 2005.

DOMINGOS, P. A few useful things to know about machine learning. **Communications of the ACM**, 55(10), 78, 2012.

ETAATI, L. Machine Learning with Microsoft Technologies: Selecting the Right Architecture and Tools for Your Project. **Auckland, Apress Media LLC**, 2019.

FERREIRA, K.J.; LEE, B.H.A.; SIMCHI-LEVI, D. Analytics for an online retailer: Demand forecasting and price optimization. **Institute for Operations Research and the Management Sciences**, v. 18, n. 1, p. 69-88, 2016.

FUJIMAKI, R.; MURAOKA, Y.; ITO, S.; YABE, A. From prediction to decision making - Predictive optimization technology. **NEC Technical Journal**, 2016.

GIEBEL, M.; ESSMANN, H.; PREEZ, N.D.; JOCHEM, R. Improved Innovation Through the Integration of Quality Gates into the Enterprise and Product Lifecycle Roadmaps. **CIRP Journal of Manufacturing Science and Technology**, 1, 199–205, 2009.

GIL, A.C. **Métodos e Técnicas de Pesquisa Social**. 6. ed. São Paulo: Atlas, 2008.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: The MIT Press, 2015.

GUALTIERI, M.; CARLSSON, K. Multimodal Predictive Analytics And Machine Learning Solutions. **Forrester Research**. Cambridge. 2018.

GUEDES, V; BORSCHIVER, S. Bibliometria: uma ferramenta estatística para a gestão da informação e do conhecimento, em sistemas de informação, de comunicação e de avaliação científica e tecnológica. **CINFORM–Encontro Nacional de Ciência da Informação**, v. 6, 2005.

GUO, Z.X.; WONG, W.K.; LI, M. A Multivariate Intelligent Decision-Making Model for Retail Sales Forecasting. **Decision Support Systems**, v. 55, n. 1, p. 247-255, 2013.



HEVNER, A.R. A Three Cycle View of Design Science Research. **Scandinavian Journal of Information Systems**: v. 19, n. 2, Article 4, 2007.

IBM. Analytics Solutions Unified Method Data Sheet. IBM Corporation, **New Orchard Road Armonk**, NY 10504. 2016.

ISLEK, I.; OGUDUCU, S.G. A Retail Demand Forecasting Model Based on Data Mining Techniques. **IEEE 24th International Symposium on Industrial Electronics (ISIE)**, 2015.

JOBIN, C.; LE MASSON, P., HOOGE S. What does the proof-of-concept (POC) really prove? A historical perspective and a cross-domain analytical study. XXIXème conférence de l'Association Internationale de Management Stratégique (AIMS), Online, France. 2020.

KANDANANOND, K. A comparison of various forecasting methods for autocorrelated time series, **International Journal of Engineering Business Management**, 2012.

KANEKO, Y; YADA, K. A Deep Learning Approach for the Prediction of Retail Store Sales. **IEEE 16th International Conference On Data Mining Workshops (ICDMW)**, 2016.

KOSTOFF, R.N.; BOYLAN R.; SIMONS, G.R. Disruptive technology roadmaps. **Technological Forecasting and Social Change** n. 71, p. 141-159, 2004.

LACERDA, D.P.; DRESCH, A.; PROENÇA, A.; ANTUNES JÚNIOR, J.A.V. Design Science Research: a research method to production engineering. **Gestão e Produção**, v. 20, n. 4, p. 741-761, 2013.

LEE, H.; KIM, S.G.; PARK, H.W.; KANG, P. Pre-launch new product demand forecasting using the Bass model: A statistical and machine learning-based approach. **Elsevier**, 2014.

LEE, T.S.; LU, C.J.; CHENG, T.F. Hotel sales forecasting based on variable selection techniques and extreme learning machine. **Journal of Quality**, 24 (6), p. 411, 2017.

LIU, N.; REN, S.Y.; CHOI, T.M.; HUI, C.L.; NG, S.F. Sales Forecasting for Fashion Retailing Service Industry: A Review. **Mathematical Problems in Engineering**, 2013.

LLAMASOFT. Demand Modeling and Forecasting - Understand how external factors influence your demand to increase forecast accuracy. Disponível em: <https://llamasoft.com/demand-modeling-and-forecasting/>. Acesso em 02/02/2020.

LU, C.J. Sales forecasting of computer products based on variable selection scheme and support vector regression. **Neurocomputing**, n. 128, p. 491-499, 2014.

LU, C.J.; CHANG, C.C. A Hybrid Sales Forecasting Scheme by Combining Independent Component Analysis with K-Means Clustering and Support Vector Regression. **Scientific World Journal**, 2014.

LU, C.J.; SHAO, Y.E. Forecasting computer products sales by integrating ensemble empirical mode decomposition and extreme learning machine. **Mathematical Problems in Engineering**, art. n. 83101, 2012.

MAAß, D.; SPRUIT, M.; DE WAAL, P. Improving short-term demand forecasting for short-lifecycle consumer products with data mining techniques. **Decision Analytics**, Vol.1(1), pp.1-17, 2014.

MARTÍNEZ, A.; SCHMUCK, C.; PEREVERZYEV, S.; PIRKER, C.; HALTMEIER, M. A machine learning framework for customer purchase prediction in the non-contractual setting. **European Journal of Operational Research**, 2018.

MICHALSKI, C.M. **Palo Alto**: Tioga publishing company, 1983.

MICROSOFT. **Team Data Science Process (TDSP)**. Disponível em: <https://docs.microsoft.com/en-us/azure/machine-learning/team-data-science-process/overview>. Microsoft, 10/01/2020. Acesso em 03/04/2020.

MIKHAILOUSKAYA, I. How to Make Big Data Implementation a Success: Roadmap and Best Practices to Follow. **Science Soft**. Disponível em: <https://www.scnsoft.com/blog/big-data-implementation>. Acesso em 17/04/2020.

MOEHRLE, M.G.; ISENMANN, R.; PHAAL, R. **Technology Roadmapping for Strategy and Innovation**. Springer Heidelberg New York Dordrecht London. 2013.

MOHRI, M.R.A.; TALWALKAR, A. Foundations of Machine Learning. **MIT Press**, 2012.

NAGASHIMA, M.; WEHRLE, F.T.; KERBACHE, L.; LASSAGNE, M. Impacts of adaptive collaboration on demand forecasting accuracy of different product categories throughout the product life cycle. **Supply Chain Management**, Vol.20(4), pp.415-433, 2015.

OCHIAI, K. Predictive analytics solution for fresh food demand using heterogeneous mixture learning technology. **NEC Technical Journal**, v.10, n.1, p. 83-86, 2015.

OPEX. Disponível em: <https://opexanalytics.com/enframe> **Opex Analytics Enframe**. Acesso em 02/02/2020.

PAYNE, T. Current Use Cases for Machine Learning in Supply Chain Planning Solutions. **Gartner**. ID G00349854. 2018.

PEFFERS, K.; TUUNANEN, T.; ROTHENBERGER, M.A.; CHATTERJEE, S. A. Design Science Research Methodology for Information Systems. **Research, Journal of Management Information Systems**, 24:3, 45-77, 2007.

PERRY, N.; UYS, W. Knowledge integration based on roadmapping and conceptual framework approach to ease innovation management. **Int. J. Computer Applications in Technology**, Vol. 37, Nos. 3/4, pp.165–181. 2010.

PHAAL, R.; MULLER, G. An Architectural Framework for Roadmapping. Towards Visual Strategy. **Technological Forecasting and Social Change**, 76, 39-49, 2009.

PINHO, J.M.; OLIVEIRA, J.M.; RAMOS, P.S. Forecasting in Retail Industry Based on Dynamic Regression Models. **Advances In Manufacturing Technology**, IOS Press, 2016.

PONCE, H.; MIRALLES-PECHUAN, L.; MARTINEZ-VILLASENOR, M.D. Artificial Hydrocarbon Networks for Online Sales Prediction. **Advances In Artificial Intelligence And Its Applications**, MICAI 2015, PT II, 2015.

PROCTOR, C.; FOWLER, G. Digital Transformation in Supply Chain - On Pace or At Risk? **Supply & Demand Chain Executive Magazine**. [www.sdcexec.com](http://www.sdcexec.com). 2019.

PRODANOV, C.C. **Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico**. 2. ed. Novo Hamburgo-RS: Universidade Feevale, 2013.

QU, T.; ZHANG, J.H.; CHAN, F.T.S.; SRIVASTAVA, R.S.; TIWARI, M.K.; PARK, W.-Y. Demand prediction and price optimization for semi-luxury supermarket segment. *Computers and Industrial Engineering*. 2017.

REN, S.Y.; CHAN, H.L.; RAM, P.A. Comparative Study on Fashion Demand Forecasting Models with Multiple Sources of Uncertainty. **Annals of Operations Research**, Spring, 2017.

SALTZ, J.S.; DEWAR, N. Data science ethical considerations: a systematic literature review and proposed project framework. **Ethics and Information Technology**. 2019.

SAPP, C. Laying the Foundation for Artificial Intelligence and Machine Learning: A Gartner Trend Insight Report. **Gartner Group**, ID: G00373110, 2018.

SHEARER, C. The CRISP-DM Model: The New Blueprint for Data Mining. **Journal Of Data Warehousing**, vol. 5. 2000.

SOGUERO-RUIZ, C.; GIMENO-BLANES, F.J.; MORA-JIMÉNEZ, I.; MARTÍNEZ-RUIZ, M.P.; ROJO-ÁLVAREZ, J.L. On the differential benchmarking of promotional efficiency with machine learning modelling (II): Practical applications. **Expert Systems with Applications**, 2012.

SUN, X.; ZHOU, T.; LI, G.; HU, J.; YANG, H.; LI, B. An Empirical Study on Real Bugs for Machine Learning Programs. 24th **Asia-Pacific Software Engineering Conference (APSEC)**. doi:10.1109/apsec.2017.41, 2017.

TEHRANI, A.F.; AHRENS, D. Enhanced predictive models for purchasing in the fashion field by using kernel machine regression equipped with ordinal logistic regression. **Journal of Retailing and Consumer Services**, 2016.

TEUCKE, M.; AIT-ALLA, A.; EL-BERISHY, N.; BEHESHTI-KASHI, S.; LUTJEN, M. Forecasting of Seasonal Apparel Products. *Dynamics In Logistics*, LDIC, **Springer International Publishing AG**, 2016.

TOOLSGROUP. **Six Tips for Success Using Machine Learning for Demand Planning**. Disponível em: <https://www.toolsgroup.com/resources/ebooks/six-tips-for-success-using-machine-learning-for-demand-planning/>. Acesso em 31/01/2020.

TSOUMAKAS, G. A survey of machine learning techniques for food sales prediction. *Artificial Intelligence Review* - **Springer Netherlands**, 2018.

WANG, Y.; CHATTARAMAN, V.; KIM, H.; DESHPANDE, G. Predicting Purchase Decisions Based on Spatio-Temporal Functional MRI Features Using Machine Learning, **IEEE Transactions on Autonomous Mental Development**, 2015.

WILSON, E. IBF Future of Demand Planning and Forecasting Survey. IBF Institute of Business Forecasting & Planning. Disponível em: <https://demand-planning.com/2018/06/11/ibf-survey-results-ai-demand-planning/>, Acesso em 02/02/2020.

WU, J.; ZHENG, S. Forecasting for fast fashion products based on web search data by using OS-ELM algorithm. **Journal of Computational Information Systems** 11(14), pp. 5171-5180, 2015.

YU, Y.; CHOI, T.M.; HUI, C.L. An intelligent fast sales forecasting model for fashion products. **Expert Systems with Applications**, 2011.

YUE, L.; WANGWEI, J.; JIANGUO, Z.; JUNJUN, G.; JIAZHOU, Z.; AIPING, J. Product life cycle based demand forecasting by using artificial bee colony algorithm optimized two-stage polynomial fitting. **Journal of Intelligent & Fuzzy Systems**, Vol.31 (2), p.825-837, 2016.