

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E SISTEMAS
CURSO DE GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

Isadora Noetzold de Almeida

**A APLICAÇÃO DE TECNOLOGIAS DISRUPTIVAS NA CAPACIDADE
PREDITIVA DA CADEIA DE SUPRIMENTOS**

Santa Maria, RS
2021

Isadora Noetzold de Almeida

**A APLICAÇÃO DE TECNOLOGIAS DISRUPTIVAS NA CAPACIDADE
PREDITIVA DA CADEIA DE SUPRIMENTOS**

Projeto de pesquisa do Trabalho de Conclusão de Curso apresentado ao curso de Graduação em Engenharia de Produção da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Bacharel em Engenharia de Produção.**

Orientador: Prof. Dr. Alvaro Neuenfeldt Júnior

Santa Maria, RS
2021

A APLICAÇÃO DE TECNOLOGIAS DISRUPTIVAS NA CAPACIDADE PREDITIVA DA CADEIA DE SUPRIMENTOS

THE APPLICATION OF DISRUPTIVE TECHNOLOGIES IN THE PREDICTIVE CAPACITY OF THE SUPPLY CHAIN

Isadora Noetzold de Almeida¹, Alvaro Neuenfeldt Júnior²

RESUMO

Devido à necessidade de visibilidade, flexibilidade e assertividade, muitas empresas estão buscando formas de utilizar tecnologias de dados disruptivas como *big data*, inteligência artificial e *machine learning* para tornar a cadeia de suprimentos mais preditiva. No entanto, identificar quais tecnologias de dados podem ser implementadas é um desafio que deve fazer parte dos objetivos estratégicos das empresas. Dessa forma, o objetivo principal do estudo consiste na elaboração de um plano de implementação de tecnologias disruptivas, com foco na capacidade preditiva da cadeia de suprimentos, baseado na análise dos pontos críticos da cadeia de valor. Para isso, foram mapeados os processos de maior valor agregado de uma companhia, bem como, delimitou-se o processo para a cadeia de fornecimento de tecido. As soluções propostas englobam as áreas de Desenvolvimento de produto, MRP, Compras e Produção de matéria-prima. Os diferentes níveis de maturidade tecnológica de cada área foram analisados, de modo a propor soluções através de ferramentas digitais de dados para impactar diretamente na capacidade preditiva da cadeia de suprimentos. Com base no modelo de organização da companhia estudada, optou-se pela utilização do método ágil Scrum para o plano de implementação. As sugestões foram divididas em *sprints* e projetadas para o primeiro trimestre com o *product roadmap*.

Palavras-chave: Cadeia de suprimentos; Capacidade preditiva; Tecnologias disruptivas; Cadeia de fornecimento de tecido.

ABSTRACT

Due to the need for visibility, flexibility and assertiveness, many companies are looking for ways to use disruptive data technologies like big data, artificial intelligence and machine learning to make the supply chain more predictive. However, identifying which data technologies can be implemented is a challenge that must be part of the strategic objectives of companies. Thus, the main objective of the study is to develop a plan to implement disruptive technologies, focusing on the predictive capacity of the supply chain, based on the analysis of critical points in the value chain. For this, the processes with the highest added value of the company were mapped, as well as the process for the fabric supply chain was delimited. The proposed solutions include the areas of Product Development, MRP, Purchasing and Production of raw materials. The different levels of technological maturity in each area were analyzed, in order to propose solutions through digital data tools to directly impact the predictive capacity of the supply chain. Based on the organization model of the company studied, it was decided to use the agile Scrum method for the implementation plan. The suggestions were divided into sprints and projected for the first quarter with the product roadmap.

Keywords: Supply chain; Predictive capacity; Disruptive technologies; Fashion retail; Fabric supply chain.

¹ Aluna, autora: Graduanda do Curso de Engenharia de Produção pela Universidade Federal de Santa Maria

² Professor, orientador: Doutor em Engenharia e Gestão Industrial pela Universidade do Porto

SUMÁRIO

1 INTRODUÇÃO.....	3
1.1 OBJETIVO GERAL.....	5
1.2 OBJETIVO ESPECÍFICO.....	5
2 REFERENCIAL TEÓRICO.....	5
2.1 TECNOLOGIAS DISRUPTIVAS.....	5
2.1.1 <i>BIG DATA</i>	6
2.1.2 INTELIGÊNCIA ARTIFICIAL.....	6
2.1.3 <i>MACHINE LEARNING</i>	7
2.2 ANÁLISE PREDITIVA.....	7
2.3 IMPLEMENTAÇÃO DAS TECNOLOGIAS DISRUPTIVAS NA CADEIA DE SUPRIMENTOS.....	8
3 METODOLOGIA.....	8
3.1 CENÁRIO.....	8
3.2 ENQUADRAMENTO METODOLÓGICO.....	9
3.3 PROCESSO DE DESENVOLVIMENTO DO ESTUDO.....	10
4 ANÁLISE DO CENÁRIO ATUAL DA EMPRESA.....	12
4.1 DEFINIÇÃO DO CONTEXTO.....	12
4.2 REVISÃO DOS PROCESSOS ATUAIS.....	14
4.2.1 DELIMITAÇÃO DO PROCESSO DE FORNECIMENTO DE TECIDO.....	18
4.3 ANÁLISE DOS PONTOS DE MELHORIA.....	19
5 APLICAÇÃO DAS TECNOLOGIAS DIGITAIS.....	20
5.1 IDENTIFICAÇÃO DA APLICAÇÃO DAS ANÁLISES.....	20
5.2 IDENTIFICAÇÃO DAS TECNOLOGIAS APLICÁVEIS.....	24
5.3 DEFINIÇÃO DO MÉTODO DE IMPLEMENTAÇÃO.....	27
6 CONCLUSÕES SOBRE O ESTUDO.....	30
REFERÊNCIAS.....	32

1 INTRODUÇÃO

Nos últimos anos, a complexidade e os requisitos da indústria aumentaram constantemente. Fatores como o crescimento da concorrência, o aumento da volatilidade do mercado, a demanda por produtos altamente individualizados e os ciclos de vida mais curtos dos produtos apresentam sérios desafios para as empresas (HOFMANN; RÜSCH, 2017; DI GREGORIO; NUSTAD, 2017).

A gestão da cadeia de suprimentos (*Supply Chain Management* - SCM) é uma maneira de conectar os fornecedores, fábricas, armazéns e lojas para que os produtos cheguem na quantidade correta, no local certo e no momento certo, assegurando a integração estratégica da cadeia de suprimentos (ORENSTEIN; LADIK; RAINFORD, 2016). Para garantir essa integração estratégica, a SCM precisa relacionar o fluxo de informação e de materiais com os diferentes elos da cadeia (SIKILERO et al., 2015), que precisam ser gerenciadas de forma colaborativa e otimizadas globalmente (STEFANOVIC, 2014).

A fim de potencializar a agilidade e atingir a adaptabilidade da cadeia de suprimentos, é necessário o uso de tecnologias de dados e ferramentas inteligentes, que permitam monitorar e avaliar o desempenho da SCM (STEFANOVIC, 2014). Além disso, para a construção de uma cadeia de suprimentos mais ágil, proporcionando o monitoramento contínuo dos processos e a rápida adaptação à complexidade dos negócios, é indispensável a incorporação das tecnologias de dados disruptivas na SCM (KERSTEN et al., 2017).

Segundo Schoenherr e Speier-Peró (2015), gerenciar uma cadeia de suprimentos requer processar uma grande quantidade de dados para tomar decisões que minimizem custos e aumentem a disponibilidade de produtos para os clientes. O êxito da tomada de decisão na SCM depende, majoritariamente, da qualidade dos dados processados através da infraestrutura organizacional, o que permite aos gerentes adquirir, processar e analisar os dados mais rapidamente. (HAZEN et al., 2014).

O *big data* e a análise preditiva podem ser definidos pelo gerenciamento, processamento e análise dos dados, com alto volume, variedade, velocidade e veracidade: seu objetivo é de criar *insights* relacionados à demanda, entrega, medição de desempenho e estabelecimento de competitividade (WAMBA et al., 2015; GUNASEKARAN et al., 2017). Dessa forma, verifica-se a importância do comportamento e o crescimento do gerenciamento de dados como o *big data*, e também sua aplicabilidade à análise preditiva.

Além da utilização de tecnologias de dados, podemos identificar como tecnologia complementar e de papel crucial na cadeia de suprimentos, a inteligência artificial. As

lideranças corporativas, de maneira geral, têm como expectativa, que os gerentes da cadeia de suprimentos se preparem para os negócios digitais. Buscam saber, também, como serão desenvolvidas as suas capacidades e como serão utilizadas as tecnologias avançadas, tais como *big data*, inteligência artificial, *machine learning*, para ter uma SCM mais digital, flexível, ágil e responsiva.

Os recursos de inteligência artificial usam o reconhecimento de padrões do *machine learning* e o processamento de linguagem neural para ler e analisar o *big data*, com o intuito de reconhecer padrões complexos e fornecer informações. O *machine learning* oferece ferramentas eficazes para modelar e gerenciar operações no ambiente complexo da cadeia de suprimentos, grande parte devido às técnicas de associação de dados, as quais são capazes de lidar com interdependências complexas. Como resultado, as tecnologias de dados podem formar a base para o desenvolvimento de métodos e sistemas de otimização, que aperfeiçoam efetivamente os diversos objetivos da cadeia de suprimentos (MINIS; AMPAZIS, 2006).

De acordo com um recente modelo de economia digital da *International Data Corporation* (IDC), até 2023, mais de 50% de todo o produto interno bruto nominal mundial será impulsionado por empresas transformadas digitalmente e, até 2025, pelo menos 90% dos novos aplicativos corporativos terão recursos de inteligência artificial incorporados. Além disso, segundo a pesquisa feita pela Gartner, em 2019, estima-se que, até 2021, o aumento do uso de inteligência artificial gerará US\$ 2,9 trilhões em valor comercial e recuperará 6,2 bilhões de horas de produtividade do trabalhador. Há evidências do crescente uso da inteligência artificial em todas as funções de negócios, incluindo o fornecimento da cadeia. Por fim, a IDC prevê também que os gastos com inteligência artificial e *machine learning* crescerão de US\$ 8 bilhões em 2016 para US \$ 47 bilhões em 2020.

Assim, o uso de ferramentas tecnológicas e métodos preditivos está se tornando mais popular e necessário para as indústrias (GREWAL; ROGGEVEEN; NORDFÄLT, 2017). Diversos setores, como o varejo, estão procurando soluções automatizadas de previsão e reposição de demanda que usam *big data* e tecnologias de análise preditiva (BRADLOW et al., 2017). Dessa forma, justifica-se a importância da análise de diferentes tecnologias de dados disruptivas, que utilizam sistemas inteligentes de coleta, compilação, raciocínio e aprendizado, por meio de padrões identificados em dados, como ferramentas de capacidade preditiva na tomada de decisão, na resolução de problemas e no gerenciamento de riscos iminentes.

1.1 OBJETIVO GERAL

Propor a aplicação de tecnologias de dados para otimização da capacidade preditiva da cadeia de suprimentos.

1.2 OBJETIVOS ESPECÍFICOS

- a) Identificar as tecnologias de dados disponíveis para a análise preditiva;
- b) Apresentar aplicabilidades das tecnologias de dados disponíveis na cadeia de suprimentos;
- c) Estudar formas de implementação das tecnologias de dados na cadeia de suprimentos;
- d) Desenvolver uma metodologia de implementação de tecnologias de dados para a análise preditiva.

2 REFERENCIAL TEÓRICO

Foram apresentados, nessa seção, os tópicos que são empregados como base de conhecimento para o problema de pesquisa em questão, que são: as tecnologias de dados disruptivas (tais como *big data*, inteligência artificial e *machine learning*), a análise preditiva e a implementação das tecnologias disruptivas.

2.1 TECNOLOGIAS DE DADOS DISRUPTIVAS NA CADEIA DE SUPRIMENTOS

Na era da tecnologia da informação e da complexidade dos processos técnicos e industriais, os processos logísticos ágeis e eficientes desempenham um papel central. Altos requisitos de logística (como confiabilidade, transparência e flexibilidade), combinados com condições econômicas ideais, formam a base para uma cadeia de suprimentos bem-sucedida. Os processos de mudança dinâmica exigem tecnologias de dados disruptivas com potencial para administrar a crescente complexidade das cadeias de suprimentos. (WENZEL; SMIT; SARDESAI, 2019)

Segundo Kersten et al. (2017), a digitalização e a transformação digital associada dos processos afetam quase todas as áreas da economia e da indústria. Para que elas sejam

implementadas são necessários novos conceitos tecnológicos, principalmente relacionados ao gerenciamento e análise de dados, - incluindo o uso de tecnologias de dados disruptivas, que servem como fonte de dados para monitoramento e aprimoramento, bem como análises preditivas e inteligência artificial, que formam a base para a otimização dos processos logísticos (KERSTEN et al., 2017).

2.1.1 *BIG DATA*

O termo *Big data* pode ser definido como uma forma genérica de denominar qualquer coleção de conjuntos de dados grandes e complexos que apresentam dificuldade em armazenar, processar e analisar com métodos anteriores (HUANG; CHAOVALITWONGSE, 2015). Dessa forma, requerem tecnologias avançadas e exclusivas de armazenamento, gerenciamento, análise e visualização, pois trabalham com altos volumes e multiplicidade de dados (CHEN et al., 2012). *Big data* define-se também pela alta velocidade, diversa variedade, escopo exaustivo e natureza relacional (KITCHIN, 2014). Com a supervalorização da economia digital, o *big data* pode ser descrito como um dos disruptores mais significativos da tecnologia (AGARWAL; DHAR, 2014).

Para Sanders (2016), a análise *big data* oferece vantagens para a tomada de decisão, pois é vista como ferramenta de previsões de demanda, direcionamento de campanhas de marketing e avaliações de riscos de fornecedores por meio da análise de dados. Além disso, internet das coisas e computação na nuvem são elementos da indústria 4.0 que estão relacionados com a análise *big data* na cadeia de suprimentos. (ZHONG et al., 2016).

2.1.2 INTELIGÊNCIA ARTIFICIAL

Desde a sua introdução, na década de 1950, o campo da inteligência artificial testemunhou períodos alternados de intenso crescimento e declínio significativo. Nos últimos anos, fatores como o aumento do poder computacional e a disponibilidade de *big data*, entre outros, levaram a um interesse renovado no campo. Devido a essa constante evolução na pesquisa de inteligência artificial, a definição do que é considerado inteligência artificial também está em constante evolução (BARYANNIS et al., 2019).

Segundo Pereira (2018), na inteligência artificial, a máquina é capaz de aprender padrões ou características fornecidas pela análise de dados gerados no *big data*, transformados em informações. O aprendizado adquirido cria conhecimento, o que gera ações

inteligentes, as quais se tornam mais precisas ao longo do tempo. Além disso, na inteligência artificial, a máquina possui uma capacidade de executar processos sem nenhuma intervenção.

2.1.3 MACHINE LEARNING

O *machine learning* é um método de análise de dados que automatiza a modelagem e implementação de fenômenos de aprendizado. É um ramo da inteligência artificial que tem como abordagem identificar padrões com base em dados de treinamento e derivar regras que podem ser transferidas para novos conjuntos de dados (MARSLAND, 2011; MELLO; PONTI, 2018). A máquina pode, então, executar a mesma tarefa, mas com novos dados que nunca foram vistos ou manipulados antes (LOURIDAS; EBERT, 2016).

O objetivo do *machine learning* é desenvolver algoritmos com capacidade de aprender associações automaticamente, em grandes quantidades de dados, em tempo real e melhorar a experiência sem serem explicitamente programados (DOGRU; KESKIN, 2020). O aprendizado de máquina pode combinar métodos quantitativos e qualitativos, para que seja possível integrar dados históricos e conhecimento especializado no processo de tomada de decisão (SHALEV-SHWARTZ; BEN-DAVID, 2014). Há uma grande tendência do uso de *machine learning* ou redes neurais para aprimorar a previsão de uma expressiva quantidade de dados internos e externos (MERTENS; RÄSSLER, 2012).

2.2 ANÁLISE PREDITIVA

A análise preditiva é definida como o processo de descoberta de padrões significativos de dados usando técnicas de reconhecimento de padrões, estatísticas, *machine learning*, inteligência artificial e mineração de dados (ABBOTT, 2014). Para Siegel (2013), a análise preditiva intervém na recuperação de informações para prever um evento desconhecido de interesse, geralmente um evento futuro. Dessa forma, é reunida a tecnologia da informação, o processo de modelagem de negócios e o gerenciamento para fazer uma previsão sobre o futuro. Usar a modelagem preditiva, com ferramentas de *machine learning* e *big data*, pode ajudar as organizações a se tornarem proativas, prospectivas e anteciparem tendências ou comportamentos com base nos dados (SIEGEL, 2016). Por fim, o objetivo da análise preditiva é aprimorar o comportamento humano na tomada de decisões, em vez de confiar no conhecimento humano, experiência pessoal ou intuição subjetiva, somente (CHURCH; FAIRCHILD, 2017).

2.3 IMPLEMENTAÇÃO DAS TECNOLOGIAS DISRUPTIVAS NA CADEIA DE SUPRIMENTOS

A construção e implementação de modelos preditivos através das tecnologias de dados disruptivas, segundo Nogare e Zavaschi (2016), possui um processo cíclico. A primeira etapa consiste na identificação do problema da área ou processo em questão. O objetivo dessa etapa é garantir que a raiz do problema seja tratada, para evitar que o modelo resolva somente uma parte do que é necessário. Na segunda etapa, é feita a análise dos dados de amostra existentes e a verificação da necessidade de coleta de novos dados. Assim que se obtêm os dados necessários, são realizadas a filtragem e a limpeza dos dados para que se obtenham informações corretas e úteis para a construção do modelo. Com os dados preparados, é possível dar início ao desenvolvimento do modelo preditivo, com o desafio de encontrar o algoritmo correto para resolver o problema apresentado.

O processo, de maneira geral, é iterativo, permitindo analisar as diferentes possibilidades existentes dentro dos algoritmos e fazer a comparação do desempenho de cada uma delas, em relação aos dados que já estão sobre o parâmetro de saída. Após realizar a comparação dos resultados e fazer ajustes, encontra-se o modelo mais apropriado para aquela amostra de dados. A seguir, o modelo é implementado, sendo ajustado para ser utilizado com dados reais, onde é esperado que os dados reais encontrem retornos como foram encontrados no *feedback*, mostrando o quanto o algoritmo foi bem desenvolvido e ajustado para resolver os problemas reais.

Por fim, é feito o monitoramento da performance do modelo preditivo criado, isso permite que o modelo obtenha um *feedback* sobre a qualidade do parâmetro de saída e, em seguida, ajuste suas próprias regras de decisão para melhorar o resultado (MOROFF; SARDESAI, 2019). Um sistema de autoaprendizagem é criado por meio do *loop* de *feedback*, à medida que os algoritmos de *machine learning* continuam a melhorar, junto à duração do uso e a quantidade de dados (GOTTSCHLICH et al., 2018).

3 METODOLOGIA

3.1 CENÁRIO DE ESTUDO

O varejo é, em relação aos demais setores, o que mais investe em inovação, segundo a pesquisa mundial feita pela Bain & Company. Os varejistas estão reconhecendo que as

dimensões competitivas, *omni channels* e o *customer experience* exigem a adoção da transformação digital, obrigando-os a adaptar uma abordagem de inovação contínua e aproveitar as melhores práticas de inovação e tecnologias digitais, para oferecer a experiência excepcional do consumidor que os clientes esperam.

De acordo com uma pesquisa feita pela PwC (2017), somente 54% dos executivos fazem investimentos significativos em tecnologias de inteligência artificial e apenas 20% disseram que suas organizações tinham as habilidades necessárias para obter sucesso com essa tecnologia. Fatores como a *internet* das coisas, robótica e *machine learning* estão promovendo discussões dentro da tomada de decisão para novas oportunidades de negócio. Além disso, o *machine learning*, quando aplicado no varejo, amplia a capacidade de uma loja de oferecer novos produtos, serviços e ofertas personalizadas. Além disso, operacionalmente, é capaz de reduzir custos e aumentar a produtividade.

Um estudo realizado com mais de 70 empresas presentes na *Retail Trends* (convenção que discute tecnologias aplicadas ao setor de varejo), identificou e mapeou os usos e qual o rumo da aplicabilidade de recursos tecnológicos no futuro. Nos próximos três anos, o varejo deve investir prioritariamente em inteligência artificial e novos meios de pagamento, seguidos de soluções em logística. Ademais, cerca de 35% dos varejistas entrevistados ainda não possuem um canal de vendas online, 20% não contam com sistema de inteligência artificial e cerca de 42% não apresentam soluções de *customer relationship management* (CRM). Ao mesmo tempo que o setor do varejo no Brasil reconhece a importância e as tendências relacionadas às tecnologias digitais - mais especificamente à inteligência artificial -, há uma grande dificuldade na implantação dessas tecnologias e adaptação ao modelo de negócio da empresa.

3.2 ENQUADRAMENTO METODOLÓGICO

A presente pesquisa está classificada teoricamente em diferentes pressupostos, caracterizados quanto à natureza, abordagem, objetivos e procedimentos técnicos. Com a finalidade de atingir o objetivo proposto de apresentar ao leitor os elementos necessários para construção da pesquisa.

Quanto à natureza, a pesquisa pode ser considerada aplicada, devido ao direcionamento dos conhecimentos adquiridos para uma análise exploratória, que proporciona a revisão dos processos atuais da empresa e a análise dos pontos de melhoria, podendo identificar, de forma prática, a aplicabilidade das novas tecnologias de dados.

Em relação à abordagem, no presente estudo, o tema será analisado tanto sob o viés qualitativo quanto quantitativo. O objetivo é identificar e evidenciar a aplicabilidade das tecnologias de dados e análises à capacidade preditiva da cadeia de suprimentos, para assim apresentar o plano de implementação e a metodologia de aplicação. O estudo será feito, de forma qualitativa, a revisão ou coleta e análise exploratória de dados, posteriormente a análise do cenário atual da empresa em relação às tecnologias de dados e a análise do impacto das tecnologias digitais à capacidade preditiva. Por fim, as informações numéricas obtidas serão convertidas para uma base qualitativa, de forma a possibilitar a mensuração do desempenho das análises das tecnologias de dados à capacidade preditiva na cadeia de suprimentos.

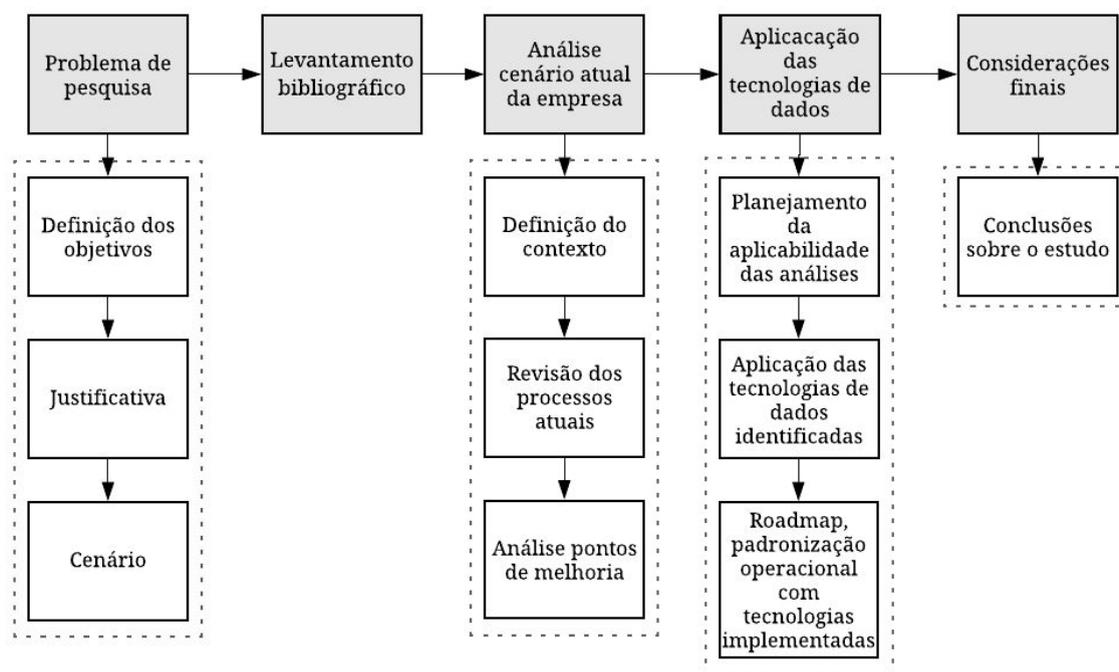
No que tange aos objetivos, a pesquisa é de caráter exploratório, devido à necessidade de maior compreensão do impacto das tecnologias de dados e inteligência artificial e como forma de construir análises sobre a temática de capacidade preditiva relacionadas a estas tecnologias.

Quanto aos procedimentos técnicos, o estudo pode ser enquadrado como um estudo de caso, com objetivo de analisar e compreender a relação das tecnologias de dados digitais à cadeia de suprimentos, bem como sintetizar o conhecimento adquirido através da construção do plano de implementação e sua metodologia, a fim de apresentar as soluções tecnológicas dentro de uma cadeia de suprimentos mais integrada.

3.3 PROCESSO DE DESENVOLVIMENTO DO ESTUDO

Para identificar visualmente as etapas da pesquisa, elaborou-se um fluxo metodológico, com cinco macro etapas: definição do problema da pesquisa, levantamento bibliográfico, análise do cenário atual da companhia, aplicação das tecnologias de dados digitais e considerações finais.

Figura 1 - Processo de desenvolvimento do estudo



Fonte: Autora (2020).

Primeiramente, o problema de pesquisa foi definido através de uma análise geral das tendências relacionadas à cadeia de suprimentos e o impacto que as tecnologias de dados aplicadas às tendências podem gerar. O enfoque na temática foi delimitado pelo objetivo geral e objetivos específicos, além da apresentação da importância do estudo e o cenário de pesquisa. Sucessivamente, teorias e conceitos são analisados, por meio de estudos sobre a aplicação das análises das tecnologias de transformação digital, com utilização de livros, relatórios técnicos e artigos científicos para o entendimento geral do contexto abordado.

O desdobramento da pesquisa iniciou com a análise do cenário atual da companhia, pois cada empresa possui diferentes níveis de inovação tecnológica em cada um dos seus setores internos. Em complemento, a definição do contexto e a revisão dos processos atuais para entender a maturidade da companhia e o impacto nas diferentes áreas da cadeia de suprimentos é realizado e após análises, são propostos os pontos em que as melhorias tecnológicas serão aplicadas.

O estudo de aplicação das tecnologias de dados foi desenvolvido através da identificação das análises, algoritmos ou ferramentas que cada tecnologia pode executar, apresentando o impacto na capacidade preditiva da cadeia de suprimentos. Após identificar as

tecnologias de dados, um método de implementação do plano foi desenvolvido, adaptado à realidade da companhia, considerando a dificuldade das empresas em mudanças de sistemas e processos, bem como a capacitação de seus colaboradores para a execução dos mesmos. O plano de implementação foi elaborado, levando em consideração a complexidade e conectividade das áreas da cadeia de suprimentos, apresentado no horizonte de tempo e implicações gerais na companhia.

Nas considerações finais são apresentadas as conclusões sobre o estudo, as soluções propostas e retratado o desenvolvimento do projeto.

4 ANÁLISE DO CENÁRIO ATUAL DA COMPANHIA

Para a análise e entendimento sobre o cenário atual da companhia, foi realizado um levantamento qualitativo semi-estruturado de dados com gerentes, coordenadores, *product owner*, analistas, assistentes e estagiários, feito por meio de entrevistas com os 20 profissionais das áreas de estilo, planejamento, cadastro, matéria-prima e compras. Além disso, foram utilizados materiais e relatórios internos fornecidos pela companhia.

4.1 DEFINIÇÃO DO CONTEXTO

O Grupo Soma é a maior plataforma de marcas de moda *premium* do Brasil, destinadas aos públicos "A" e "B", em termos de receita líquida. Estando está entre as 50 maiores companhias do *e-commerce* brasileiro, é a líder do *e-commerce* no setor de varejo de moda brasileiro, - de acordo com o estudo feito em 2018 pela Sociedade Brasileira de Varejo e Consumo.

Atualmente, oito marcas compõem o seu portfólio: *Animale, Farm, Maria Filó, Cris Barros, Fábula, Foxton, A.brand, NV* e uma loja outlet chamada *Off Premium* (com foco no segmento de luxo). A companhia destaca-se como o quinto maior *player*, no quesito roupas femininas, com uma participação de mercado de 3,5%, segmento no qual atualmente tem a maior presença. Dentre as marcas apresentadas, os destaques são para a *Animale* e a *Farm*: juntas representam 75% da receita bruta do Grupo Soma.

Quanto à estrutura de operações, o Grupo Soma possui uma rede de lojas físicas que cobre 23 Estados e o Distrito Federal no Brasil. A operação inclui 282 lojas físicas, com uma área de vendas total de aproximadamente 37.800 metros quadrados, sendo 244 lojas localizadas em shopping centers consolidados e 38 lojas de rua. Além das lojas físicas,

comercializa-se produtos através de nove *websites* proprietários de *e-commerce*, em complemento de um aplicativo móvel da marca *Off Premium*.

Além de atuar no mercado varejista, o Grupo Soma conta com uma participação relevante dos seus negócios oriunda do mercado de atacado, comercializando seus produtos por meio de aproximadamente 2.800 revendedores multimarcas, o que a permite atingir uma alta capilaridade no país, distribuindo suas marcas em mais de 1.063 cidades brasileiras.

No Brasil, a operação possui nove centros de distribuição, com área total superior a 13 mil metros quadrados. Esses centros de distribuição atendem a operação da seguinte forma: um centro de distribuição de matéria-prima (localizado no Rio de Janeiro e responsável pelo recebimento, armazenamento, corte e expedição dos insumos das roupas, que são posteriormente enviados às confecções); três centros de distribuição de produto acabado localizados no Rio de Janeiro, em São Paulo e no Espírito Santo, os quais garantem um tempo de entrega e abastecimento de lojas, multimarcas e clientes de *e-commerce*, com máxima eficiência em todo o país; um centro de distribuição que suporta exclusivamente a operação da *Cris Barros*, localizado em São Paulo; dois centros de distribuição que suportam exclusivamente a operação da *Maria Filó*, localizados no Rio de Janeiro; e dois centros de distribuição internacionais, responsáveis pela distribuição dos produtos nos Estados Unidos (Nova Jersey) e na Europa (Helmond, Holanda). A companhia conta também, com um ateliê de desenvolvimento localizado no Rio de Janeiro, onde são realizadas as modelagens e prototipagem das coleções futuras das marcas.

Por fim, as operações contam com três fábricas, estando duas fábricas localizadas no Rio de Janeiro e uma fábrica localizada em São Paulo.

Quanto à cultura do uso de tecnologias de dados disruptivas, estipulou-se para 2021, como um dos pilares dos objetivos estratégicos, ser referência no setor em tecnologia e aumentar a penetração digital. Isso porque o mercado de vestuário brasileiro ainda é pouco penetrado, enquanto o Brasil é o segundo país com maior tempo diário gasto em mídia social no mundo, totalizando 225 minutos.

Diferentemente da maioria das varejistas, o Grupo Soma já possuía um canal digital relevante antes da pandemia da COVID-19, respondendo por 22% das vendas em 2019. As estratégias multicanais estão presentes há mais de cinco anos, havendo sido implementado a multicanalidade completa em 2019 - entrega da loja, clique e retire e prateleira infinita. Como resultado, as vendas multicanais representaram 30% das vendas online naquele ano. Assim como para o restante do setor, a pandemia acelerou sua penetração online, levando o

e-commerce a representar 64% das vendas no 3º trimestre de 2020, com o multicanal representando um terço delas.

Como uma das companhias mais promissoras em tecnologia do setor, o Grupo Soma possui, desde 2017, o "Soma Labs", laboratório de inovação, como um meio para acelerar soluções digitais para todas as suas marcas e processos corporativos, empregando tecnologias como *big data*, inteligência artificial e *machine learning*.

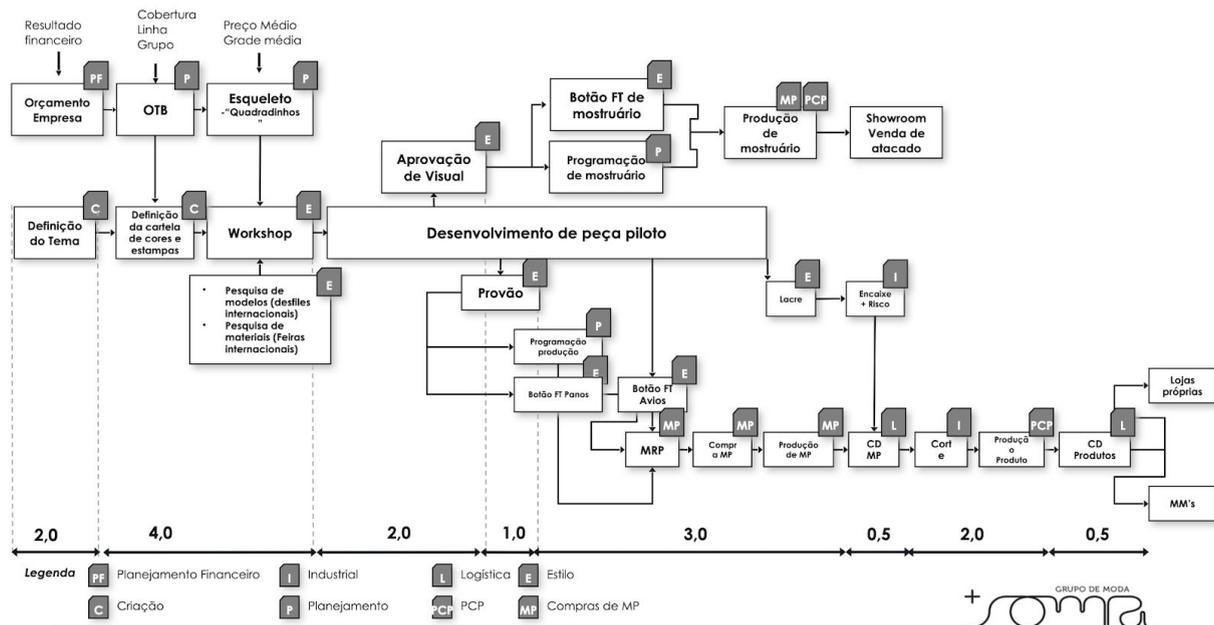
O Soma Labs desenvolve ferramentas e aplicações para diversas áreas (como estilo, criação, operações e gestão de estoque), com o objetivo de eliminar as fricções no processo do varejo, melhorando a rentabilidade, os prazos de entrega e a experiência do cliente. Reconhecido como o pulmão de inovação, o laboratório é responsável por contribuir para um posicionamento cada vez maior do Grupo Soma como companhia digital. Além disso, foi o grande responsável por colocar a companhia na posição de protagonista no canal digital do mercado brasileiro. Entre as principais entregas estão: (1) Iniciativas Multicanais; (2) Plataforma digital, com nuvem e dados em tempo real e *cross-docking* no atacado; (3) Pesquisas de mercado e *benchmarking*, simulação de loja e testes de coleções; (4) Redução de fricção com fornecedores.

O principal foco, em 2021, é conectar o atacado à plataforma multicanal, revisar a estratégia de distribuição para estruturar "lojas hub", melhorar a experiência em sua loja, desenvolver produtos digitais *Farm* e *Animale* e melhorar algoritmos de alocação para otimizar custos e tempo de envio/*fulfilment*.

4.2 REVISÃO DOS PROCESSOS ATUAIS

A revisão dos processos da cadeia de fornecimento da companhia encaminhou-se de forma macro até a análise micro das áreas-chave. Para o entendimento sobre a atual situação da companhia, foi analisado primeiramente o mapeamento da cadeia de valor fornecido - da criação até o ponto de venda. O processo da cadeia de fornecimento tem início no Workshop e vai até a Produção de matéria-prima, envolvendo as áreas de estilo, planejamento e compras de matéria-prima. Sob o aspecto macro, o processo é dividido em Desenvolvimento de Produto (Workshop e Desenvolvimento de peça piloto), MRP, Compra de matéria-prima e Produção de matéria-prima, conforme mostra a Figura 2, exposta a seguir.

Figura 2 - Mapeamento da Cadeia de Valor do Produto



Fonte: Grupo Soma, 2020

A cadeia de valor repete-se em coleções sazonais, com dois grandes lançamentos ao longo do ano: o primeiro relativo à coleção de inverno (com duração de janeiro a maio) e o segundo relativo à coleção de verão (com duração de julho a dezembro). Além disso, há o lançamento de coleções menores como a de Alto Inverno, com duração de março a maio, e a de Alto Verão, com duração de outubro a dezembro, totalizando quatro coleções por ano e uma produção anual de 6.101.378,00 peças de roupa.

A distribuição do volume de produção ao longo das coleções segue uma proporção distinta em cada mês, sendo os meses de lançamento (janeiro para o inverno e julho para o verão), aqueles que possuem a maior quantidade de produtos programados, evidenciando a estratégia em mostrar a maior quantidade disponível de novos produtos e o tema da coleção logo nas datas de lançamento.

A área de Desenvolvimento de Produto (Workshop e Desenvolvimento de peça piloto), primeira área da cadeia de fornecimento, é responsável por gerar as informações necessárias para a compra de matéria-prima. Essa informação é coletada pela área de estilo por meio da ficha técnica de cada produto (cadastrada no sistema *Linx* pela área de cadastro). A cada etapa chave do processo, essa informação é enviada para a área de compras pela área

de planejamento. O processo de desenvolvimento de produto da *Farm* foi mapeado (Anexo A), através da ferramenta BPMN (*Business Process Model and Notation*), com o objetivo de registrá-lo e entendê-lo, sendo um dos processos mais complexos, mas de maior valor agregado na cadeia de valor da marca.

Durante o processo do desenvolvimento de produto, primeiramente se desenvolvem as estampas da coleção, um processo artístico, artesanal e demorado. Assim que as estampas forem desenhadas e aprovadas, começa o Workshop, processo em que as estilistas desenham diferentes peças para cada estampa. Nessa etapa surge a ficha técnica, na qual a estilista desenha a roupa, preenche as informações na parte da frente da ficha e entrega para a assistente de estilo, este agente é o responsável por preencher a ficha costas e todas as alterações, inclusões e exclusões que surgirem durante todo o processo de desenvolvimento de produto.

Além da criação e do aprimoramento do produto, é no desenvolvimento de produto que a demanda das peças é definida. O "provão" é um evento simultaneamente presencial e online em que são apresentadas, através de uma plataforma digital desenvolvida pelo Soma Labs, as peças para que os vendedores das marcas votem numa escala *likert* com 5 opções de votos. Com o *input* das notas obtidas no provão, a área de planejamento das marcas aposta na grade de cada uma das peças, assinalando a quantidade de peças que serão produzidas.

A função do MRP no processo é transformar a demanda dos produtos de cada coleção em necessidade de compra de matéria-prima, definindo a quantidade e as datas necessárias para atender a programação de vendas, levando em consideração os *lead times* de produção das etapas da cadeia e o pulmão, visando à data loja - data em que o produto chegará nos consumidores finais.

O pulmão, mecanismo de antecipação do MRP usado para proteger as atividades da fábrica que são vulneráveis aos problemas associados com as flutuações estatísticas, é utilizado em dois momentos, na data de chegada da matéria-prima ao centro de distribuição e na data de utilização dessa matéria prima na produção. No primeiro momento, é estipulado um pulmão de 14 dias para a seda, 7 dias para tecido plano, casual, alfaiataria e artesanal e 0 dias para as demais linhas. No segundo momento, é determinado um período de 21 dias para os produtos faccionados e um de 14 dias para os produtos acabados. Além disso, programa-se que a chegada dos materiais seja parcelada, os produtos chegam pouco a pouco a cada semana, para que o processo se adeque ao gargalo da facção e passe pelo tempo de atravessamento dos materiais no centro de distribuição de matéria- prima.

O MRP recebe o *input* através da programação, feita por parte da área de planejamento, que, durante o processo de desenvolvimento de produto, programa duas vezes (para mostruário e para produção). Essa programação é feita importando as referências do *Linx* e preenchendo os dados de código de cor, quantidade, tipo de programação e data. A programação de mostruário acontece depois da aprovação de visual. O *output* desta etapa no MRP é a necessidade de compra de peças específicas para o atacado. Já a programação de panos e aviamentos, que acontece posteriormente ao provão, é a programação final para liberar o produto para produção do varejo.

O processo de compras começa a partir do recebimento da informação de necessidade de compra do MRP pelas compradoras. O pedido começa a ser efetuado passando pelas ferramentas de priorização e de qualidade até o pedido estar pronto para faturamento. Se a matéria-prima for internacional, é feita a importação pela *Logimex*. Obtém-se a licença de importação, a cotação do frete e o pagamento pela *fourtrade* para o pedido ser faturado.

Assim que o pedido é embarcado, é enviado o ETD (*Estimated Time of Departure*): data estimada ou prevista da saída do navio no porto ou da aeronave no aeroporto e o ETA (*Estimated Time of Arrival*): data estimada ou prevista da chegada do navio no porto ou da aeronave no aeroporto. A chegada ao Brasil conta com o processo de pagamento da logística, nacionalização, frete e impostos, além do desembaraço aduaneiro. Por fim, atualizam-se os custos de matéria-prima e ocorre o agendamento da entrega no centro de distribuição. Já se a matéria-prima for nacional, a compradora fatura o pedido com o fornecedor apresentado pelo MRP e faz o acompanhamento da entrega.

A Produção de matéria-prima é o processo em que o produto está sendo produzido pelo fornecedor. Em média, as matérias-primas internacionais possuem um *lead time* de 60 dias e as matérias-primas nacionais chegam ao centro de distribuição em 35 dias - sendo que cerca de 70% dos tecidos utilizados são nacionais e 30% internacionais. Vale ressaltar que há três tipos de processos de produção de tecidos: (1) Materiais finais: beneficiados que podem ser utilizados diretamente no produto comercializado; (2) Materiais bases: produzidos por um fornecedor e que precisam ser beneficiados por outro fornecedor antes de serem utilizados no produto final e (3) Triangulação: bases produzidos por um fornecedor que são enviados diretamente para o outro fornecedor estampar antes de chegar ao centro de distribuição da companhia.

Quando a matéria-prima chega ao centro de distribuição, há um tempo de 10 dias de atravessamento dos materiais, o tempo necessário entre a chegada da matéria-prima no estoque e a expedição. Durante esse tempo, ocorrem os seguintes fatores: (1) Revisão dos

materiais (3 dias): todo material recebido no centro de distribuição passa pelo controle de qualidade que, por sua vez, realiza de forma amostral (de 20% a 30% do lote recebido) a conferência do material, baseada em normas e nas fichas técnicas do material entregues pelo fornecedor na negociação, realizando testes de laboratórios e emissão de laudos técnicos.

Além disso, a área de Controle de Qualidade realiza testes visuais de aprovação de cores e estampas junto à equipe do estilo, pois um material pode estar aprovado quanto às normas técnicas, mas ainda pode ser reprovado caso não consiga atingir a estampa ou coloração adequadas. (2) Consumo da ordem de serviço (4 dias): ao ser informada de que os materiais estão disponíveis em estoque, a área do PCP (Planejamento e Controle da Produção) envia ordens de separação desses materiais para serem enviados para a facção ou fornecedores de produtos acabados, que recebem somente aviamentos. Além dos materiais, é necessário o envio do risco do produto, molde no qual o tecido deverá ser cortado para melhor aproveitamento do mesmo e (3) Transporte (3 dias): o envio da matéria-prima do centro de distribuição para a facção ou para os fornecedores de produtos acabados, que englobam o transporte e a confirmação de recebimento, com a qualidade esperada, por parte da facção ou do fornecedor.

4.2.1 DELIMITAÇÃO DO PROCESSO

A cadeia de fornecimento da companhia, além de complexa, possui inúmeras variantes. Dessa forma, os principais insumos utilizados na composição dos produtos foram analisados. Os produtos comercializados, na totalidade, são formados pela combinação de cerca de 10 materiais diferentes, divididos em três categorias principais: (1) Panos: tecidos de diversas composições e com largura superior a 1 metro, classificados em panos principais e panos secundários, sendo o pano principal o material que tem a maior relação custo por metragem em cada produto, enquanto os demais são classificados como panos secundários; (2) Aviamentos entretela: tecidos utilizados como forros dos produtos e que possuem largura inferior a 1 metro; (3) Aviamentos: todos os materiais do produto que não são do tipo de panos ou entretelas, como: botões, zíperes e ganchos.

Por representarem 85% do custo dos materiais e fazerem parte de apenas 10% do custo dos produtos, o material de panos foi escolhido para a análise. Outro ponto relevante para a escolha é o valor agregado das estampas para o Grupo Soma. Marcas como *Farm*, *Animale* e *Fábula* possuem como um dos principais processos a criação das estampas e são reconhecidas internacionalmente por isso. Além disso, a capacidade de produção dos

fornecedores tecidos é um ponto crítico devido às flutuações da demanda e aos processos de repique, em períodos de grande utilização da capacidade do fornecedor como o mês de novembro, sabendo que lançamento da coleção é em janeiro, a capacidade dos fornecedores não atende ao programado.

Tal ausência de capacidade tende a se tornar maior com os atrasos realizados em etapas anteriores (apertos de botões), pois os produtos acabam sendo migrados de meses e até de coleções. Por exemplo, migração da produção de itens de dezembro para janeiro, aumentando o delta entre a capacidade e o planejado.

O repique é o processo que consiste em utilizar o desempenho da venda do atacado, que é realizada 3 meses antes da venda em loja, para aumentar a quantidade programada no varejo. É um processo estrategicamente inteligente, pois a relação entre produtos que vendem bem no atacado para as multimarcas e incrementos de quantidade dos produtos que vendem bem no varejo com sucesso apresenta até 87% de confiança. No entanto, o repique além de diminuir os níveis de serviço da cadeia de fornecimento, é um processo à parte do MRP, não sendo contabilizado no cálculo de capacidade produtiva dos fornecedores, o que sobrecarrega a rede de fornecedores, necessitando negociar ou utilizar outras fontes de fornecimento. O processo de repique só é feito se os tecidos que compõem a peça forem tecidos de fornecedores nacionais, devido ao tempo e risco demandado pela importação.

4.3 ANÁLISE DOS PONTOS DE MELHORIA

A fim de otimizar a capacidade preditiva da cadeia de fornecimento de tecidos, foram identificados pontos de melhoria relacionados à visibilidade, flexibilidade, rapidez e assertividade de cada uma das 4 macro-áreas.

Quanto à etapa de Desenvolvimento de produto, podemos identificar uma necessidade de melhoria na previsão de demanda e maior rapidez e assertividade no cadastro da ficha técnica no *Linx*, informação que serve como *input* para a programação.

No processo do MRP, é de grande importância a visibilidade das possíveis falhas na capacidade dos fornecedores ou nas falhas na própria programação da ferramenta, além do acesso à informação gerada pela ferramenta. A flexibilidade de programação, tanto para mostruário quanto para produção, também é um ponto relevante, pois a cadeia entre o *output* do MRP e a facção do pedido é cada vez mais estreita.

Quanto à área de Compras, a visibilidade do processo é essencial para o *follow-up* de entregas. Já a flexibilidade é imprescindível para identificar e solucionar cada uma das possíveis causas de rupturas de fornecimento.

Em relação ao processo de Produção de panos, o primeiro ponto diz respeito à flexibilidade, pois a cadeia de fornecimento de tecidos não consegue ter uma capacidade de produção flexível à demanda. Além disso, o trade-off de capacidade dos fornecedores não é muito flexível, devido à baixa margem de lucro do fornecedor na facção da matéria-prima. O segundo ponto diz respeito à visibilidade, como o processo de alocação ocorre em um momento anterior ao envio dos materiais para a produção, a fila de fornecedores e a taxa de utilização de capacidade dos mesmos não é visualizada nessa definição, o que aumenta a chance de atraso das produções. O terceiro ponto, por sua vez, refere-se à assertividade, quanto ao prazo de entrega, volume e também à qualidade do material entregue. Por fim, em relação à rapidez, o foco está na velocidade na entrega de produtos e agilidade nas respostas às possíveis mudanças na cadeia, mantendo o nível de serviço.

5 APLICAÇÃO DAS TECNOLOGIAS DISRUPTIVAS DE DADOS

5.1 PLANEJAMENTO DA APLICABILIDADE DAS ANÁLISES

Levando em consideração que a companhia possui diversas marcas as quais atuam em diferentes segmentos, com propostas de valor e níveis de maturidade do negócio distintos, a estratégia passa invariavelmente por objetivos específicos dentro da especificidade e necessidade de cada uma das marcas. Por isso, para a identificação da aplicabilidade das análises, optou-se pelas marcas que existem há mais tempo e possuem maior impacto nos resultados da companhia: *Animale* e *Farm*. Vale ressaltar que as operações da companhia são unificadas para todas as marcas já integradas.

Dentre os pontos de melhoria apresentados na seção anterior, pode-se dizer que as soluções se aplicam a três processos: o cadastro da ficha técnica, a demanda e o relacionamento com o fornecedor.

O processo do cadastro analisado é o da *Farm* (Anexo A), com interface em 3 áreas: estilo, cadastro e planejamento. Até o início de 2020, o processo do cadastro era feito de forma manual e presencial; o preenchimento da ficha técnica parte frente era feito a mão pela estilista e entregue para a assistente de estilo preencher a ficha costas, durante todo o desenvolvimento de produto; as alterações, inclusões e exclusões de informações sobre os

materiais que ficha eram feitos à mão e, para qualquer consulta em fichas anteriores, abria-se uma pasta pessoal com o histórico de fichas finalizadas.

Com o início da pandemia da COVID-19 em 2020, o processo migrou para o digital, mas ainda com ressalvas. A ficha é feita em um arquivo de *excel*, quando pronta, adicionada a uma pasta no *google drive* com o nome da assistente de estilo e se utiliza uma planilha também no *google drive* para controle do cadastro. Vale ressaltar que a ficha técnica é atualizada constantemente durante o processo de Desenvolvimento de produto. Melhorias feitas nas peças são baseadas nos *feedbacks* de outras estilistas, cadistas, assistentes de modelistas, que fazem o produto final performar melhor nas vendas e no desejo das clientes.

O processo do cadastro é um processo complexo, longo, que engloba as áreas de estilo, planejamento e cadastro, o que impacta diretamente em outras etapas da cadeia, pois toda a informação gerada na ficha técnica serve como insumo para o cálculo do MRP para o setor de compras. Além disso, a informação só chega até a área de compras na programação do aperto de botão de mostruário, deixando o intervalo de tempo para contatar os fornecedores e emitir a ordem de compra reduzido.

A solução proposta é digitalizar totalmente o processo de cadastro, reduzindo significativamente os erros, tornando as interfaces de comunicação e status entre as áreas fluidas e transparentes.

Apesar de a previsão de demanda da *Animale* já utilizar ferramentas de *machine learning* e possuir um sistema de provão com votos presencial e online por peça, é recente a utilização dessas ferramentas tecnológicas e ainda há espaço para o seu desenvolvimento. Prever melhor a demanda, no mercado da moda, também significa identificar melhor as tendências e olhar para os históricos de dados da companhia, tanto para produto quanto para estampa. Dessa forma, verificou-se a necessidade de tornar as áreas de estilo e criativo *data-informed*, para que a tomada de decisão sobre cores, modelos, cortes e estampas, seja além de um processo artístico e criativo, um processo mais assertivo.

A sugestão de dados externos que podem ser analisados é oriundo de redes sociais, de competidores, de tendências, da economia e do mercado. Nas redes sociais, consegue-se identificar, por meio de inteligência artificial, padrões de comportamento, de cores, de atitudes e identificar tendências do público-alvo. Analisar os dados dos competidores ou de marcas internacionais e nacionais que possuem um conceito parecido com o da marca. Utilizar plataformas de tendência que possuem diversos *inputs* e tecnologias que definem e entregam inspirações sobre o que o público vai buscar em um período de 2 ou 3 anos. Assim,

a análise da economia de forma geral, as problemáticas, as causas que estão sendo levantadas e também sobre o que o mercado espera do setor é viabilizada.

Em relação aos dados internos, podem ser explorados os dados de vendas, dos consumidores e dos fornecedores. Os dados de vendas já são analisados pela equipe em uma reunião semanal. A ideia é disponibilizar de forma atrativa e visual para que qualquer pessoa da equipe tenha acesso e interesse de olhar os dados. Os dados dos consumidores podem ser correlacionados aos dados de vendas para entender melhor o perfil de consumidor e os padrões de compra e comportamento. Por fim, os dados dos fornecedores são importantes para o acompanhamento da área de planejamento e a resolução de problemas referentes à ficha técnica.

As soluções para a demanda incluem tornar a criação de estampas e a criação de produtos *data-informed*, utilizando todas as opções de dados, tanto externos quanto internos, para a tomada de decisões. Além disso, o outro foco é a criação do acervo de inspirações e tendências, baseado no histórico da própria marca, nas inspirações que os próprios estilistas e designers encontram ou também nas possíveis tendências para os próximos anos. O objetivo é alimentar a criatividade das equipes de designers do criativo e estilo arte, e dos estilistas do estilo. No longo prazo, quando a base de dados do acervo estiver completa e a gestão de produtos e estampas já esteja sendo feita de forma digital, inicia-se a análise preditiva de performance de produtos e estampas, utilizando sistemas de inteligência artificial e sucessivamente *machine learning*.

Outro ponto é a melhoria do atual modelo de *machine learning* de apostas utilizado pela *Animale*. O foco do modelo é a definição de quais produtos serão os melhores de vendas, denominado pela marca como "*best-seller*" e sugerir a grade de produtos. O modelo de *machine learning* foi projetado inicialmente para diminuir o problema de *stockout*, aumentando a assertividade de produtos *best-sellers* de 40% para 60%. Para a empresa, a relação de custo-benefício de *stockout* e sobras é consideravelmente pior quando há *stockout* de uma peça do que quando há sobras.

Os *inputs* do modelo são as notas do provão e os históricos de venda, que definem de forma binária se o produto é *best-seller* e de forma quantitativa, o quão *best-seller*. Há, também, o *input* dos dados de esqueleto da coleção que tem como *output* a sugestão da grade de produtos. O modelo é um *machine learning* supervisionado, baseado em árvore de decisão, com dados categóricos e heterogêneos, com algoritmo baseado na relevância e foco no *recall*, pois o objetivo é descobrir quantas peças e a probabilidade de se classificarem

como *best-seller*, o cálculo do *recall* é feito na relação dos verdadeiros positivos (VP) e dos falsos negativos (FN), conforme mostrado a Equação (1).

$$Recall = \frac{TP}{TP+FN} \quad (1)$$

Para melhorar a assertividade do algoritmo, utilizou-se o *CatBoost*, uma biblioteca de *machine learning* que automatiza a categorização de dados. Uma das grandes vantagens do *CatBoost* é conseguir retornar bons resultados com um número menor de dados e também não é necessário haver um pré-processamento na conversão de categorias em números.

A solução proposta é utilizar outras fontes de dados para criar melhores estampas e melhores produtos, assim como identificar futuras tendências. A ideia é aumentar a porcentagem de *best-sellers* por coleção e conseguir identificá-los para ter a relação oferta e demanda equilibrada. Como consequência, diminuem os custos de cobertura de *stockout* e das sobras, impactando diretamente o problema de capacidade dos fornecedores, pois assim é possível planejar melhor e diminuir consideravelmente a necessidade do processo do repique.

No ano de 2020, nas marcas *Farm* e *Animale*, 80% dos tecidos foram produzidos por 20% dos fornecedores, contabilizando um total de 117 fornecedores, sendo 90% nacionais. Gerir uma ampla rede de fornecedores de tecidos gera complicações para a cadeia, não permitindo à equipe de compras focar em apenas alguns fornecedores. Isso dificulta o *follow-up* de entregas e exige uma maior atenção gerencial às rupturas de fornecimento, que podem ocorrer em vários fornecedores, obrigando a equipe a identificar e solucionar cada uma das causas de origens diferentes. Ademais, a dissolução de fornecimento impõe limites ao poder de barganha das marcas em negociações de preços e prazos. As negociações vêm se tornando cada vez mais complicadas. A prospecção de novos fornecedores de tecidos no mercado se torna cada vez mais custosa e com resultados de tempo/qualidade inferiores aos quais as marcas ambicionam.

Os produtos são alocados para os fornecedores no início de Desenvolvimento de produto, que acontece em média quatro meses antes de a produção iniciar. A alocação dos produtos não considera a capacidade de entrega do fornecedor no início da produção, onde, por vezes, a produção é enviada para fornecedores em estado de sobrecapacidade, resultando na falta de capacidade produtiva suficiente para entregar a demanda nos prazos previstos.

O processo de realocação ocorre quando um fornecedor está superalocado e existe um outro fornecedor subalocado - só que, para isso, o fornecedor subalocado tem que ser capaz de produzir o produto que estava alocado para o outro fornecedor.

Outro problema na alocação é que a capacidade cadastrada no sistema de cada fornecedor frequentemente não corresponde à capacidade real. Existem momentos em que os fornecedores informam propositalmente uma capacidade maior do que a real, de modo a garantir mais pedidos ou porque simplesmente não conhecem as ferramentas para uma medição de forma eficaz. A cadeia de fornecimento de tecidos não consegue ter uma capacidade de produção flexível à demanda, e isso se deve principalmente ao fato de que as marcas não informam aos fornecedores a previsão de demanda dos materiais ao longo da coleção, gerando picos e vales na demanda sem prazo suficiente para atendimento.

A solução proposta é a criação de uma plataforma inteligente de priorização e acompanhamento dos tecidos, que tenha uma interface de comunicação entre as áreas de compras e matéria-prima com os fornecedores. A plataforma recebe como *inputs* os dados dos fornecedores, os dados da ficha técnica e dados do recebimento. E recebe como *outputs*, um *checklist* diário de atividades priorizadas e um *dashboard* de acompanhamento dos fornecedores.

5.2 APLICAÇÃO DAS TECNOLOGIAS DE DADOS IDENTIFICADAS

Como proposta de solução de tecnologia de dados para o cadastro, desenhou-se uma ferramenta digital, baseada no mapeamento de processo desenvolvido (Anexo A), inserida no PLM (*Product Lifecycle Management*) - ferramenta de gestão de produto utilizada pelo Grupo Soma. Para o desenvolvimento da ferramenta, foi feito um protótipo que contém todos os campos da ficha técnica e as informações necessárias para o cadastro. O protótipo já foi validado pelas equipes de estilo, cadastro e planejamento.

A ferramenta digital proposta conta com um controle de preenchimento automático que facilitará o trabalho da assistente de estilo no *input* das informações da ficha para a ferramenta, tornando dispensável a busca pela informação em planilhas pessoais, além de padronizar e diminuir a probabilidade de erros de escrita. Também possui uma aba de histórico de alterações, inclusões e exclusões na ficha, que sinaliza qual o tipo de atualização, o campo que foi atualizado, o que foi modificado, o usuário que executou a modificação, quando modificou e se foi atualizado pelo cadastro e finalizado no *Linx*, utilizando um sistema visual de notificação por abas, mostrando está cada atualização.

Por último, a ferramenta digital dispõe de um sistema de controle visual sobre quais os produtos que estão com informações divergentes do *Linx*, quais são as informações divergentes, qual foi o último usuário, em qual data e qual o tipo de atualização, se é alteração, inclusão ou exclusão. A sistemática possui um sistema de gestão por cores e em uma única tela, facilitando o trabalho de verificação da informação do cadastro e do planejamento.

A solução de tornar a criação de estampas e produtos *data-informed* é uma estratégia a ser aplicada nos produtos digitais "+estampas" e "+produtos" que a companhia já possui. O acervo de estampas e produtos digitais já está sendo feito. O próximo passo proposto para o "+estampas" é o cadastro de estampas da *Animale* na plataforma e para o "+produtos" é a digitalização dos produtos do acervo físico da *Farm* e transferir os arquivos compartilhados no grupo do *WhatsApp* de inspirações para a plataforma. Em relação às inspirações e tendências, é importante que seja simples, de fácil acesso na plataforma e visualmente agradável, para que os designers ou os estilistas consigam manipular os dados e infográficos inteligentes, realizando pesquisas e se informando sobre as últimas tendências. Quanto aos dados externos, sugere-se a utilização de dados de redes sociais como *twitter*, *instagram*, *pinterest*, *facebook* e dados de pesquisas que podem ser obtidos através do *google trends*.

Uma plataforma externa que utiliza inteligência artificial na obtenção de dados de redes sociais para moda é a *Heuritech*. Os dados das coleções de competidores ou de outras marcas nacionais e internacionais podem ser obtidos pelos canais de comunicação dessas empresas, armazenados e disponibilizados na plataforma por meio de imagens tagueadas ou de dados sobre o mix, cores, grade e padrões. A companhia já utiliza plataformas de tendência como o WGSN (*Worth Global Style Network*). No entanto, o acesso à informação é restrito, visto que são poucas pessoas que possuem conta na plataforma. A solução não é só buscar democratizar o acesso à plataforma, mas também extrair dados de outras fontes de tendência, como: *Spate*, *Tagwalk*, *Fashion Ideas*, *Trender* e *Catchwalk*.

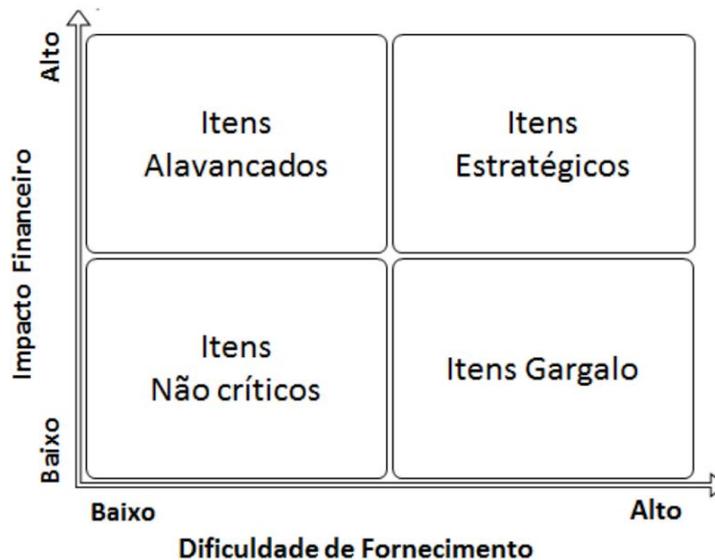
Por fim, a moda é cultura, história, arte e faz sentido olhar dados econômicos, políticos e buscar inspirações em outras culturas. Quanto aos dados internos, a solução inclui poder pesquisar sobre coleções, peças e estampas antigas, analisando também a performance das mesmas. Além disso, poder acompanhar as vendas e analisar a relação de cliente/vendas, identificando padrões de compras e desejos de cada tipo de cliente. Por fim, para a área de planejamento, poder acompanhar os lacres, apertos de botões e recebimento por parte do fornecedor.

O atual modelo de *machine learning* preditivo de apostas já possui grande influência na assertividade da análise preditiva atual da demanda, no entanto ainda está longe da performance ideal. A fim de aumentar a assertividade do modelo, foram analisados alguns pontos referentes à geração de valor das peças de roupas, entre eles: a classificação das estampas, dados de tendências, de redes sociais, de fornecedores e de consumidores. Além disso, identificar o que configura um produto *best-seller* e adicionar um peso ao modelo nos produtos que contém esses pontos. Devido ao alto volume de dados, identifica-se a necessidade de utilização de *big data*, que irá transformar e integrar os dados, e já é comportado pela biblioteca utilizada *Catboost*.

A proposta de solução dos problemas de gestão dos fornecedores de tecidos, *follow-up* de entregas, poder de barganha e capacidade dos fornecedores, é o desenho de uma ferramenta digital inteligente que comunica as interfaces de equipe de compras e matéria prima com os fornecedores. A solução anterior, do cadastro digital, fornece dados desde o primeiro cadastro da ficha técnica. Uma das soluções engloba a visualização da necessidade de tecidos e as alterações serem acessadas de forma automática, tornando as informações sobre as peças mais transparentes e, conseqüentemente, possibilitando maior poder de barganha por parte da equipe de compras.

Com o *input* de dados por parte da ficha técnica, pode-se também gerir, priorizar e analisar os fornecedores, com o intuito de administrar a sua capacidade produtiva. Para isso, é necessário um sistema que meça o impacto financeiro em relação à dificuldade de fornecimento, esse sistema pode ser classificado de acordo com a matriz de portfólio Kraljic (1983), como pode ser visto na Figura 3. A ideia é que essa análise seja feita automaticamente, para isso, é necessário classificar, categorizar e pontuar os fornecedores, de acordo com os parâmetros que configuram cada uma das quatro classificações abaixo: itens alavancados, itens estratégicos, itens não críticos e itens gargalo.

Figura 3 - Matriz de Portfólio Kraljic (1983)



Fonte: Adaptado Kraljic (1983).

Os itens não críticos são de baixo risco e têm baixo impacto na lucratividade organizacional. No caso da companhia seriam os materiais de escritório. Embora importantes para o desempenho de suas funções, não têm impacto significativo sobre os negócios, nem sua ausência representa uma ameaça séria. Já os itens alavancados são itens com alta rentabilidade, mas baixo fator de risco. Os compradores possuem o equilíbrio de poder no relacionamento e buscam obter maiores retornos. Os fornecedores podem ser facilmente substituídos, pois suas ofertas são praticamente as mesmas.

No processo, os itens alavancados são os tecidos recorrentes (aqueles utilizados em mais de 10 produtos). Nos itens gargalo, o risco é alto, mas a lucratividade é baixa. Nesse caso, a força está nas mãos do fornecedor, o mercado consiste de poucos fornecedores que podem formar oligopólios para forçar a alta dos preços. Esses fornecedores absorvem mais tempo dos compradores em comparação com qualquer outro segmento, o relacionamento com o fornecedor é exigente, embora tenha um impacto limitado na lucratividade da companhia. As bases de tecidos podem ser categorizadas como gargalo, pois apesar de ser a base do material, ela ainda precisa passar pelo processo de estamparia, então o seu valor agregado se torna baixo.

Por fim, os itens de alto risco do fornecedor e alto impacto no lucro cobrem fornecedores estratégicos. Eles são essenciais para os negócios, esses itens representam apenas alguns fornecedores, mas garantir um relacionamento eficaz e previsível com o fornecedor é fundamental para o futuro da companhia. Os tecidos já estampados estão classificados nessa categoria, pois são os itens de maior valor agregado e de maior *lead time*. Essa ferramenta digital também irá contar com um sistema MRP *Web*, já planejado para

implementação na companhia, que contará com a acessibilidade de um sistema em nuvem, com a transparência de dados da ferramenta.

5.3 ROADMAP, PADRONIZAÇÃO OPERACIONAL COM TECNOLOGIAS IMPLEMENTADAS

Para a implementação das tecnologias apresentadas anteriormente, foi selecionado o método ágil Scrum. O método Scrum, além de já ser utilizado pelo Grupo Soma, permite a utilização de processos adaptativos complexos simultaneamente com a entrega produtiva e criativa de produtos com o maior valor possível (SCHWABER; SUTHERLAND, 2016).

Para Lopes (2017), o método Scrum se aplica na prática dividindo o projeto em diversas interações e em pequenos intervalos de tempos. Cada um dos períodos, chamados de *sprints*, devem durar menos de um mês. A equipe do projeto começa cada período executando a *planning*, etapa de planejamento da *sprint*, analisando os OKRs (*Objectives and Key Results*) estipulados para o semestre e como podem priorizá-lo e executá-lo.

Durante a *sprint*, a equipe executa e testa o que foi feito e apresenta para os *stakeholders* para obter *feedback*. Não é esperado que o produto seja entregue completamente, mas sim que ele seja incrementado a cada *sprint* até que atinja sua maturidade. Todos os dias de trabalho, em um horário estipulado pela equipe, há uma reunião de *daily*, com em média 15 minutos de *time box*. Na *daily*, todos os membros da equipe apresentam o que foi feito no dia anterior e o que será feito no dia, apresentando os possíveis impedimentos. Ao final de cada *sprint* são feitas duas reuniões, uma de revisão e outra de retrospectiva.

A reunião de revisão é feita com a equipe Scrum e os *stakeholders* do projeto, sendo o objetivo da reunião conversar sobre as entregas da *sprint*, e alinhar as expectativas dos próximos entregáveis. A reunião de retrospectiva conta somente com a equipe Scrum, nela são levantados e discutidos os sucessos e fracassos da *sprint*, identificando os pontos de melhoria e levando o aprendizado para a próxima *sprint*. Dessa forma, o projeto se torna o resultado dessas múltiplas interações, o que minimiza o risco de a entrega final ser inadequada, já que é possível receber o *feedback* durante o desenvolvimento do produto.

Levando em consideração que há pontos de melhoria a serem executados nas quatro macro-áreas do processo, a ideia é montar equipes que consigam executar todo o projeto, do início até o fim, em cada área. Algumas das áreas, como o Desenvolvimento de produto, já possuem equipes Scrum. Outras áreas, como o MRP, em que não há uma pessoa responsável

pelo processo, deve-se definir uma equipe para a execução dos projetos. Para cada equipe é necessário ter um PO (*product owner*), responsável por guiar a equipe, dividir e priorizar as tarefas e remover todos os impedimentos que os membros da equipe possam ter ao tentar concluir uma tarefa ou uma *feature*. O período das *sprints* é de 15 dias, intervalo de tempo já utilizado pelo Grupo Soma, não necessitando de nova adaptação pelas equipes.

Inicialmente, analisa-se quais dessas soluções apresentadas contribuem para alcançar os objetivos atuais da companhia e assim, prioriza-se e dividem-se esses objetivos em forma de OKRs para cada trimestre. As seis sprints de cada OKR contribuem para atingir os objetivos estipulados para o trimestre.

Cada uma das soluções apresentadas se encontra em uma fase diferente. As soluções de tornar *data-informed* as áreas de criação de produto e estampas e de utilização de diferentes fontes de dados para o modelo preditivo de *machine learning*, são soluções incrementais. Já a construção da plataforma que utiliza a matriz Kraljic (1983) e da ficha técnica digital são novas soluções que devem passar pelo processo de *discovery*, design e validação com os *stakeholders*. Na Figura 4 consta o *product roadmap*, o plano de implementação que é utilizado pelas equipes e faz parte do método Scrum. Para o primeiro trimestre de implementação, o objetivo é que todas as soluções estejam implementadas e em fase de *feedbacks* com os *stakeholders*. O contato com as partes interessadas é constante. São feitos levantamentos e validações sobre as ferramentas ainda em desenvolvimento, para que as necessidades estejam sempre sendo alinhadas.

Figura 4 - *Product Roadmap*

<p>+Produtos Design, validação e desenvolvimento da aba de acervos; Definição da estratégia de digitalização do acervo físico.</p> <p>+Estampas Cadastro estampas Animale; Tagueamento estampas da Animale; Discovery dados internos e performance: produtos, fornecedores e vendas.</p> <p>Ficha técnica digital MVP Ficha técnica digital.</p> <p>Modelo machine learning Definição de estratégia e escopo para estudos de utilização das novas fontes de dados.</p> <p>Matriz Kraljic Discovery: agendamento de entrevistas, design protótipo e definição de visão e estratégia.</p>	<p>+Produtos Discovery dados internos e performance: produtos, fornecedores e vendas; Desenvolvimento da estratégia de transferência do acervo de inspiração do <i>WhatsApp</i>; Desenvolvimento da estratégia de digitalização do acervo físico.</p> <p>+Estampas Cadastro e tagueamento estampas Animale; Desenvolvimento e validação da aba de dados internos e performance de estampas; Design e validação da aba de dados externos.</p> <p>Ficha técnica digital Utilização da ferramenta por 3 linhas diferentes da Farm; Levantamento e priorização de <i>fixes</i> e <i>features</i>.</p> <p>Modelo machine learning Análise histórica de <i>best-sellers</i> por dados priorizados.</p> <p>Matriz Kraljic Validação com <i>stakeholders</i>; Levantamento e priorização de <i>fixes</i> e <i>features</i>.</p>	<p>+Produtos Tagueamento do acervo físico e do <i>WhatsApp</i>; Desenvolvimento e validação da aba de dados internos e performance de produto; Design e validação da aba de dados externos.</p> <p>+Estampas Cadastro e tagueamento estampas Animale; Validação com <i>stakeholders</i>; Levantamento de <i>fixes</i> e <i>features</i> da aba de dados internos e externos.</p> <p>Ficha técnica digital Validação com <i>stakeholders</i>; Levantamento e priorização de <i>fixes</i> e <i>features</i>.</p> <p>Modelo machine learning Modelo em produção; <i>Testes naive</i>, por tipo de usuário, por fonte de dados e correlações.</p> <p>Matriz Kraljic Validação com <i>stakeholders</i>; Levantamento e priorização de <i>fixes</i> e <i>features</i>.</p>
○-----○-----○-----○-----○-----○-----○-----○-----○-----○		
<p>+Produtos Definição da estratégia de transferência do acervo de inspiração do <i>WhatsApp</i>; Desenvolvimento da estratégia de digitalização do acervo físico.</p> <p>+Estampas Cadastro e tagueamento estampas Animale; Design e validação da aba de dados internos e performance de estampas; Discovery dados externos: tendências, concorrentes, redes sociais, economia e mercado.</p> <p>Ficha técnica digital Validação com <i>stakeholders</i>; Levantamento e priorização de <i>fixes</i> e <i>features</i>.</p> <p>Modelo machine learning Visão de <i>best-sellers</i> por: estampa, dados de tendências, de redes sociais, de fornecedores e de consumidores; Priorização de aplicação da análise.</p> <p>Matriz Kraljic MVP Ferramenta Kraljic</p>	<p>+Produtos Tagueamento do acervo físico e do <i>WhatsApp</i>; Design e validação da aba de dados internos e performance de produto; Discovery dados externos: tendências, concorrentes, redes sociais, economia e mercado.</p> <p>+Estampas Cadastro e tagueamento estampas Animale; Validação com <i>stakeholders</i> e levantamento de <i>fixes</i> da aba de dados internos; Desenvolvimento e validação da aba de dados externos.</p> <p>Ficha técnica digital Validação com <i>stakeholders</i>; Levantamento e priorização de <i>fixes</i> e <i>features</i>.</p> <p>Modelo machine learning Construção das novas regras de modelagem; Validação de modelo com <i>stakeholders</i>.</p> <p>Matriz Kraljic Utilização da ferramenta em 30% dos fornecedores de tecidos; Levantamento e priorização de <i>fixes</i> e <i>features</i>.</p>	<p>+Produtos Tagueamento do acervo físico e do <i>WhatsApp</i>; Validação com <i>stakeholders</i> e levantamento de <i>fixes</i> da aba de dados internos; Desenvolvimento e validação da aba de dados externos.</p> <p>+Estampas Cadastro e tagueamento estampas Animale; Validação com <i>stakeholders</i>; Levantamento de <i>fixes</i> e <i>features</i> da aba de dados internos e externos.</p> <p>Ficha técnica digital Validação com <i>stakeholders</i>; Levantamento e priorização de <i>fixes</i> e <i>features</i>.</p> <p>Modelo machine learning Teste das novas regras com modelo de aposta; Elaboração de modelo de <i>machine learning</i>; Otimização e definição de sugestão de grade final.</p> <p>Matriz Kraljic Validação com <i>stakeholders</i>; Levantamento e priorização de <i>fixes</i> e <i>features</i>.</p>

Fonte: Autora (2020).

O *product roadmap*, é um caminho a ser seguido, mas o que dita o tempo e as entregas é o ritmo de trabalho da equipe, sendo que a cada *sprint* é analisado e discutido entre a equipe, bem como os motivos de sucesso ou fracasso nas entregas. Portanto, o *product roadmap* desenvolvido possibilita que as 5 soluções caminhem juntas, de maneira ágil, executando e melhorando em cada *sprint* as soluções em conjunto com os *stakeholders* das ferramentas e do processo.

Ao final do trimestre, o objetivo é que cada uma das soluções apresentadas se torne cada vez mais madura tecnologicamente. Processos que não existiam, como o da matriz Kraljic, agora existem, são digitais e geram dados. Processos que antes eram artesanais, como o da ficha técnica, agora são digitalizados, informam os *stakeholders* com maior transparência e servem como *input* de dados para outras aplicações. Ferramentas que trabalhavam somente com a gestão de produtos e estampas, passaram a utilizar tecnologias de dados e de inteligência artificial, para informar e inspirar a área de criação. O modelo preditivo de *machine learning* de apostas, que recebia *input* apenas dos dados de vendas e do

provão, possui agora uma gama de opções de dados, como os das soluções apresentadas anteriormente. São diferentes níveis de maturidades tecnológicas, que se preparam para utilizar ou utilizam tecnologias disruptivas para gerar dados e impactar diretamente na capacidade preditiva da cadeia.

6 CONCLUSÕES SOBRE O ESTUDO

O presente trabalho apresenta uma análise dos processos atuais da companhia, bem como um par de soluções que impactam, sobretudo, o que se acredita serem as causas raízes dos problemas. A proposta inicial do projeto foi entender os processos e identificar os pontos de aplicação de tecnologia de dados em toda cadeia de fornecimento de tecidos. No levantamento de dados, as dores apresentadas pelos diferentes profissionais nas diversas áreas baseavam-se em três pontos principais: problema na capacidade dos fornecedores, o tempo em que as informações de compra chegavam à área de compras e os erros contidos nesses dados.

Dessa forma, buscou-se entender o grau de maturidade tecnológica de cada etapa e verificar, de acordo com a cadeia de valor e com os objetivos estratégicos do Grupo Soma, quais são os pontos em que se poderia utilizar tecnologias de dados para que as informações possam ser analisadas de forma preditiva a fim de otimizar o processo de produção. As soluções relacionadas ao processo de desenvolvimento de produto são: alimentar as áreas de criação (estampas e produtos) com: tendências, inspirações de mercado e dados de performance sobre a própria companhia, impactando na assertividade da demanda e, conseqüentemente, tornando-a mais preditiva. As soluções também são responsáveis por gerar os dados necessários para que o modelo preditivo de *machine learning* de apostas, consiga prever melhor os *best-sellers* e as suas respectivas grades de coleção. Outro ponto é a digitalização do processo da ficha técnica, tornando a comunicação entre as áreas de estilo, cadastro e planejamento, mais assertiva e transparente, reduzindo significativamente os erros de cadastro e contribuindo para o *input* de dados da ferramenta da matriz de Kraljic (1983).

No que diz respeito à capacidade dos fornecedores, é através da ferramenta inteligente baseada na matriz de Kraljic (1983), que é possível prever os problemas, acompanhá-los e priorizá-los. A ferramenta automatiza a relação de prioridade dos fornecedores e informa a área de compras sobre o andamento das referências no processo de criação, informação que só era obtida após o processo de apertado de botão de mostruário.

Todas as soluções propostas apontaram para o mesmo objetivo, utilizar tecnologias para aumentar a capacidade preditiva da cadeia de suprimentos. Para isso, foram analisados quais os pontos de maior valor agregado e qual o seu impacto nos resultados da companhia. Por isso, optou-se por apresentar as soluções em áreas localizadas no início da cadeia de suprimentos. No setor analisado, tornar a demanda mais preditiva, ter a possibilidade de identificar tendências e utilizar dados de anos de marca para criar melhores estampas e melhores roupas, é de extrema importância. Por fim, além de ter uma cadeia de fornecimento mais preditiva e ágil, as soluções propiciam mudanças de *mindset* nas áreas de criação em relação à tecnologia de dados. Tornar *data-informed* uma das áreas mais artesanais, complexas e manuais, é um desafio diretamente proporcional aos ganhos adquiridos.

Tendo em vista, os resultados apresentados no *product roadmap* para o primeiro trimestre, bem como, os ganhos em flexibilidade, transparência e assertividade, que a aplicação das tecnologias disruptivas na cadeia de suprimentos pode oferecer, torna-se imprescindível a continuação das análises ao longo dos trimestres e conseqüentemente, a aplicação do estudo em outras áreas da cadeia de suprimentos da companhia.

Como limitações da pesquisa, apresenta-se a dificuldade na obtenção dos dados, bem como a qualidade dos mesmos. Para a coleta e limpeza de dados, utilizou-se da linguagem de banco de dados SQL (*Structured Query Language*), cada dado coletado era validado com os profissionais da área analisada, tornando o processo lento e mecânico. Outro ponto, foi a limitação geográfica, dificultando a análise presencial nas áreas de compras e matéria-prima, visto que o Grupo Soma se localiza na capital do estado do Rio de Janeiro.

REFERÊNCIAS

- ABBOTT, D. Applied predictive analytics: Principles and techniques for the professional data analyst. **John Wiley & Sons**, 2014.
- AGARWAL, R.; DHAR V. Big Data, Data Science, and Analytics: The Opportunity and Challenge for IS Research. **Information Systems Research**, v. 25, n. 3, p. 443-448, 2014.
- BAIN & COMPANY. The Future of Retail: Asia's Ecosystems. **Bain Report**, 2018.
Disponível em:
<https://www.bain.com/contentassets/334c41d7b65d41259e820a7c5761c4fb/bain_report-the_future_of_retail_asias_ecosystems.pdf>. Acesso em: 18 mai. 2020.
- BARYANNIS, G.; VALIDI, S.; DANI, S.; ANTONIOU, G. Supply chain risk management and artificial intelligence: state of the art and future research directions. **International Journal of Production Research**, v. 57, n. 7, p. 2179-2202, 2019.
- BRADLOW, E. T.; GANGWAR, M.; KOPALLE, P.; VOLETI, S. The role of big data and predictive analytics in retailing. **Journal of Retailing**, v. 93, n. 1, p. 79–95, 2017.
- CHEN, H.; CHIANG, R.; STOREY, V. Business intelligence and analytics: From big data to big impact. **MIS Quarterly: Management Information Systems**. v. 36, n. 4, p. 1165-1188, 2012.
- CHURCH, C. E.; FAIRCHILD, A. J. In Search of a Silver Bullet: Child Welfare's Embrace of Predictive Analytics. **Juvenile and Family Court Journal**. v. 68, n. 1, p. 67-81, 2017.
- DOGRU, A. K.; KESKIN, B. B. AI in operations management: applications, challenges and opportunities. **Journal of Data, Information and Management**. n. 2, p. 67–74, 2020.
- FAWCETT S. E.; WALLER M. A. Supply Chain Game Changers - Mega, Nano, and Virtual Trends - And Forces That Impede Supply Chain Design (i.e., Building a Winning Team). **Journal of Business Logistics**, v. 35, n. 3, p. 157–164, 2014.
- GARTNER, Inc. Leverage Augmented Intelligence to Win With AI. **Gartner report**, 2019.
Disponível em:
<<https://www.gartner.com/en/newsroom/press-releases/2019-08-05-gartner-says-ai-augmentation-will-create-2point9-trillion-of-business-value-in-2021>>. Acesso em: 28 abr. 2020.
- GOTTSCHLICH, J.; SOLAR-LEZAMA, A.; TATBUL, N.; CARBIN, M.; RINARD, M.; BARZILAY, R.; AMARASINGHE, S.; TENENBAUM, J. B.; MATTSON, T. The three pillars of machine programming. **The 2nd ACM SIGPLAN International Workshop**, p. 69–80, 2018.
- GREWAL, D.; ROGGEVEEN, A. L.; NORDFÄLT, J. The Future of Retailing. **Journal of Retailing**, v. 93, n. 1, p. 1–6, 2017.
- GS& GOUVEA DE SOUZA (GS&UP). Aplicação de tecnologias no varejo brasileiro. In: **RETAIL TRENDS PÓS NRF**, 2020, São Paulo. Disponível em:
<<https://revistapegn.globo.com/Banco-de-ideias/Varejo/noticia/2020/02/reforma-tributaria-te>>

cnologia-e-foco-em-pessoas-sao-pautas-do-varejo-para-2020.html>. Acesso em: 18 mai. 2020.

GUNASEKARAN A.; PAPADOPOULOS T.; DUBEY R.; WAMBA S. F.; CHILDE S. J.; HAZEN B.; AKTER S. Big data and predictive analytics for supply chain and organizational performance. **Journal of Business Research**, v. 70, p. 308-317, 2017.

HAZEN, B.; BOONE, C.; JONES-FARMER, L.A.; EZELL, J. Data Quality for Data Science, Predictive Analytics and Big Data in Supply Chain Management: An Introduction to the Problem and Suggestions for Research and Applications. **International Journal of Production Economics**, 2014.

HOFMANN, E; RÜSCH, M. Industry 4.0 and the current status as well as future prospects on logistics. **Computers in Industry**, v. 89, p. 23-34, 2017.

HUANG, S.; CHAOVALITWONGSE, W. Computational Optimization and Statistical Methods for Big Data Analytics: Applications in Neuroimaging. **The Operations Research Revolution**. p. 71-88, 2015.

INTERNATIONAL DATA CORPORATION (IDC). Outlines the Impact "Digital Supremacy" Will Have on Enterprise Transformation and the IT Industry. **IDC FutureScape**, 2019. Disponível em: <<https://www.idc.com/getdoc.jsp?containerId=prUS45613519>>. Acesso em: 28 abr. 2020.

KERSTEN, W.; SCHRÖDER, M.; INDORF, M. **Potenziale der Digitalisierung für das Supply Chain Risikomanagement: Eine empirische Analyse**. Schmalenbachs Zeitschrift für betriebswirtschaftliche Forschung, 2017.

KERSTEN, W.; SEITER, M.; VON SEE, B.; HACKIUS, N.; MAURER, T. Trends und Strategien in Logistik und Supply Chain Management. **Chancen der digitalen Transformation**, p. 8-12, 2017.

KITCHIN, R. Big Data, new epistemologies and paradigm shifts. **Big Data & Society**. v. 1, n. 1, 2014.

LOPES, L. **Aplicação da Metodologia Scrum em uma área de Engenharia de Processos de uma Empresa do Varejo**. Rio de Janeiro, 2017. Disponível em: <<http://periodicos.unifacef.com.br/index.php/creare/article/download/1634/1162>>. Acesso em: 20 jan. 2021.

LOURIDAS, P.; EBERT, C. Machine Learning. **IEEE Software**. v. 33, n. 5, p. 110-115, 2016.

MARSLAND, S. Machine learning: an algorithmic perspective: Chapman and Hall. **CRC press**, 2011.

MELLO, R. F.; PONTI, M. A. Machine learning: a practical approach on the statistical learning theory. **Springer**, 2018.

MERTENS, P.; RÄSSLER, S. Prognoserechnung-Einführung und Überblick. **Springer**, p. 3–10, 2012.

MINIS, I.; AMPAZIS, M. Applications of neural networks in supply chain management. **Nature Inspired Computing**, v. 2, p. 589 – 607, 2006.

MOROFF, N. U.; SARDESAI, S. Machine Learning in Demand Planning: Crossindustry Overview. **Proceedings of the Hamburg International Conference of Logistics (HICL)**. v. 27, p. 355-383, 2019.

NOGARE, D.; ZAVASCHI, T. Análise Preditiva com Azure Machine Learning e R. **B2U Editora**, 2016.

ORENSTEIN, P.; LADIK, D.; RAINFORD, S. What are the Key Drivers of Future Supply Chains? **Journal of Accounting – Business & Management**, v. 23, n. 1, p. 31–40, 2016.

PEREIRA, J. Utilización de Big Data y Machine Learning en la Industria 4.0. **Big Data Magazine**, 2018. Disponível em: <<https://bigdatamagazine.es/utilizacion-de-big-data-y-machine-learning-en-la-industria-4-0>>. Acesso em: 03 jul. 2020.

PRICEWATERHOUSE COOPERS (PWC). A decade of digital: Keeping pace with transformation. **Global Digital IQ® Survey: 10th anniversary edition**, 2017. Disponível em: <<https://www.pwc.com/sk/en/publikacie/assets/2017/pwc-digital-iq-report.pdf>>. Acesso em: 18 mai. 2020.

SCHOENHERR, T.; SPEIER-PERO, C. Data Science, Predictive Analytics, and Big Data in Supply Chain Management: Current State and Future Potential. **Journal of Business Logistics**, v. 36, n. 1, p. 120-132, 2015.

SCHWABER, K.; SUTHERLAND, J. **The Scrum Guide: The Definitive Guide To Scrum - The Rules Of The Game**. Disponível em: <<http://www.scrumguides.org/docs/scrumguide/v1/scrum-guide-us.pdf>>. Acesso em: 20 jan. 2021.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. Understanding machine learning: From theory to algorithms. **Cambridge university press**, 2014.

SIEGEL, E. Predictive Analytics: Harnessing The Power Of Big Data. **Analytics**, p. 38-42, 2013.

SIEGEL, E. Predictive Analytics: The Power to Predict Who Will Click, Buy, Lie, or Die. **John Wiley & Sons**, 2016.

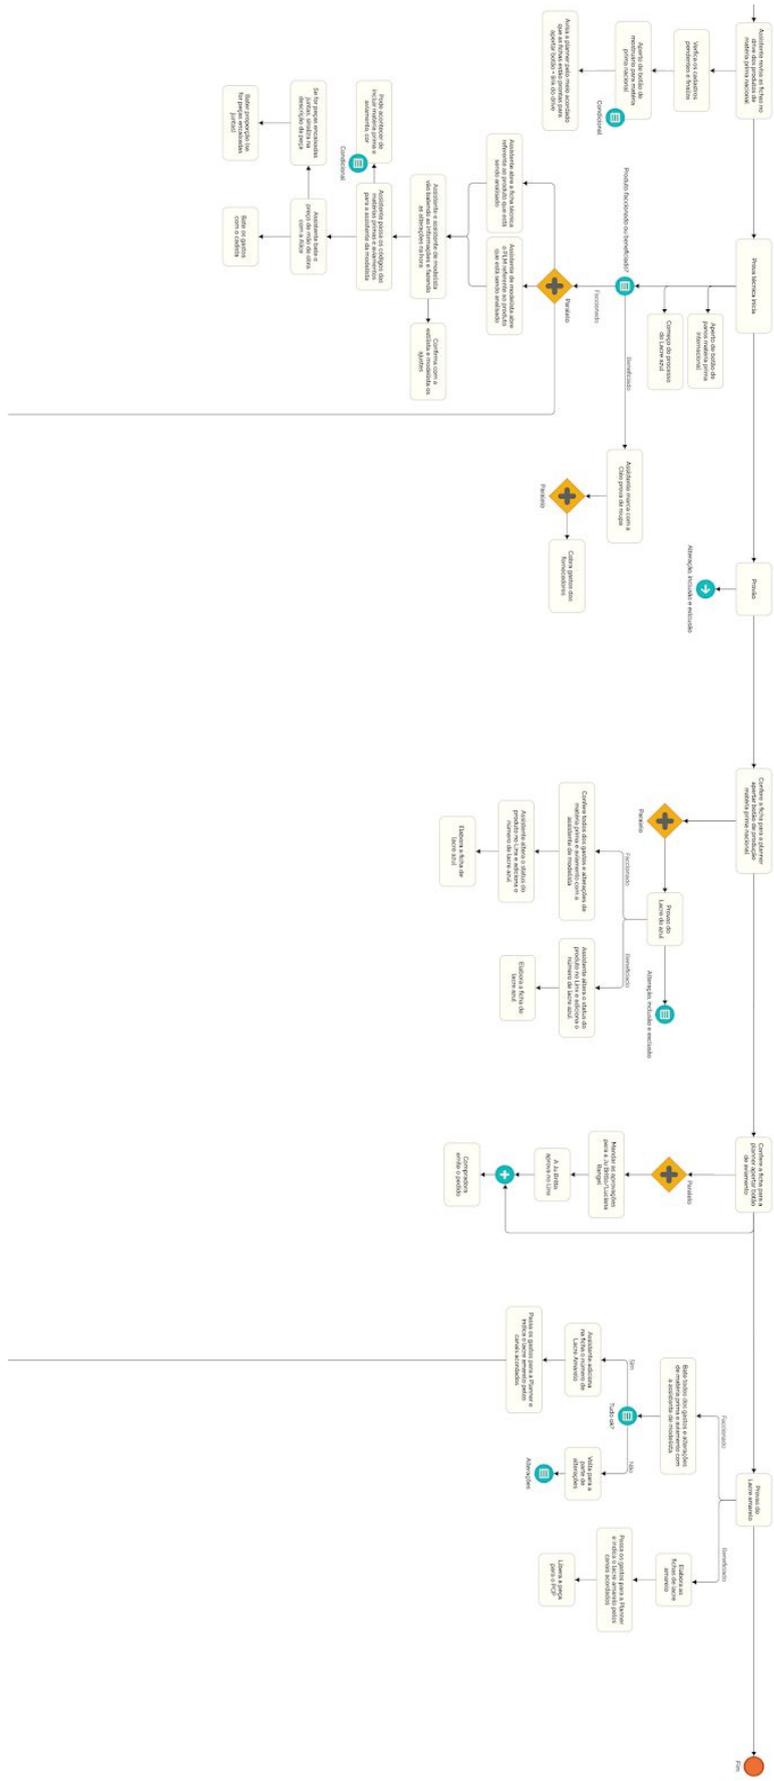
SIKILERO, C. et al. Gestão da Cadeia de Suprimentos: uma reflexão a partir da Teoria das Restrições. **Espacios**, v. 35, n. 4, p. 1–18, 2015.

STEFANOVIC, N. Proactive Supply Chain Performance Management with Predictive Analytics. **The Scientific World Journal**, v. 2014, 2014.

WAMBA, S. F.; AKTER, S. Big data analytics for supply chain management: A literature review and research agenda. **In Lecture Notes in Business Information Processing**, p. 61–72, 2015.

WENZEL, H.; SMIT, D.; SARDESAI, S. A Literature Review on Machine Learning in Supply Chain Management. **Fraunhofer Institute for Material Flow and Logistics IML**, p. 25-27, 2019.

ZHONG, R.; NEWMAN, S.; HUANG, G.; LAN, S. Big Data for Supply Chain Management in the Service and Manufacturing Sectors: Challenges, Opportunities, and Future Perspectives. **Computers & Industrial Engineering**. v. 101, p. 572-591, 2016.



Cedente digital
Cedente



Planejamento

Proposta de cronograma e envia-la planears

Planner recebe o prazo limite de prazo do cliente



