AGTU – THE GLOBAL UNIVERSITY

ESTUDO DE CASO: IMPLEMENTAÇÃO ESTRATÉGICA DE INTELIGÊNCIA ARTIFICIAL NA STARTUP DE E-COMMERCE SHOPSMART

AUTOR: MARCIO LUCENA MAGALHAES

RESUMO

Este estudo de caso analisa a situação da startup de e-commerce ShopSmart, que enfrenta desafios relacionados à experiência do cliente e eficiência operacional, como alta taxa de abandono de carrinho, recomendações de produtos pouco eficazes e atendimento ao cliente limitado. Propõe-se a implementação de soluções baseadas em Inteligência Artificial (IA), especificamente sistemas de recomendação, chatbots para atendimento e análise preditiva para otimização de estoque. O estudo detalha um plano estratégico, aborda a fundamentação teórica, aspectos técnicos, análise de custo-benefício, considerações éticas e fornece recomendações para a implementação bem-sucedida da IA na ShopSmart, visando melhorar a personalização, a automação e, consequentemente, os resultados do negócio.

Palavras-chave: Inteligência Artificial; E-commerce; Sistemas de Recomendação; Chatbot; Otimização de Estoque; Transformação Digital.

1 INTRODUÇÃO

A startup ShopSmart opera em um mercado de e-commerce competitivo, buscando diferenciar-se pela experiência do cliente e eficiência operacional. No entanto, a empresa enfrenta desafios significativos que impactam seu crescimento e lucratividade: uma alta

taxa de abandono de carrinhos de compra, dificuldade em apresentar produtos relevantes aos usuários de forma personalizada, e um serviço de atendimento ao cliente com capacidade limitada para responder prontamente às demandas. Reconhecendo o potencial transformador da Inteligência Artificial (IA), a ShopSmart busca avaliar e implementar soluções tecnológicas para superar esses obstáculos.

O objetivo deste estudo de caso é propor e analisar a implementação de soluções baseadas em IA para resolver os problemas específicos da ShopSmart, considerando aspectos técnicos, econômicos e éticos. Busca-se estabelecer um roteiro prático de implementação que possa ser seguido pela empresa, com métricas claras para avaliação do sucesso.

2 REFERENCIAL TEÓRICO

2.1 Fundamentos da Inteligência Artificial

A Inteligência Artificial busca criar sistemas capazes de realizar tarefas que normalmente exigem inteligência humana. O Aprendizado de Máquina (Machine Learning - ML), um subcampo da IA, foca no desenvolvimento de algoritmos que permitem aos computadores aprenderem a partir de dados sem serem explicitamente programados (MITCHELL, 1997). Esta definição clássica se mantém relevante, embora o campo tenha evoluído significativamente, especialmente com o advento do Deep Learning.

Segundo GOODFELLOW et al. (2016), o Deep Learning representa uma evolução do Machine Learning tradicional, permitindo que redes neurais com múltiplas camadas aprendam representações de dados com níveis crescentes de abstração. Esta abordagem revolucionou várias aplicações de IA, incluindo visão computacional, processamento de linguagem natural e sistemas de recomendação.

Técnicas como aprendizado supervisionado (regressão, classificação), não supervisionado (clusterização) e por reforço são a base para muitas aplicações em e-commerce, cada uma com suas particularidades e casos de uso específicos (JORDAN & MITCHELL, 2015).

2.2 Sistemas de Recomendação

Os sistemas de recomendação representam uma das aplicações mais bem-sucedidas de IA no e-commerce. Conforme definido por RICCI et al. (2011), esses sistemas são ferramentas de software e técnicas que fornecem sugestões de itens potencialmente úteis para um usuário. No e-commerce, isso se traduz em produtos ou serviços recomendados com base no comportamento anterior do cliente, preferências declaradas ou comportamentos de usuários similares.

AGGARWAL (2016) classifica os sistemas de recomendação em três categorias principais:

- **Filtragem baseada em conteúdo:** Sugere itens similares aos que o usuário demonstrou interesse anteriormente.
- **Filtragem colaborativa:** Recomenda itens com base em padrões de preferências de usuários semelhantes.
- **Sistemas híbridos:** Combinam diferentes abordagens para superar limitações individuais de cada método.

Adicionalmente, ZHANG et al. (2019) destacam uma quarta categoria emergente:

- **Sistemas baseados em Deep Learning:** Utilizam redes neurais profundas para capturar padrões complexos e não-lineares nos dados de usuários e itens, superando limitações dos métodos tradicionais em termos de

personalização e acurácia.

2.3 Processamento de Linguagem Natural (PLN)

O Processamento de Linguagem Natural permite que computadores compreendam e processem a linguagem humana. Fundamentos de PLN, como tokenização, reconhecimento de entidades nomeadas (Named Entity Recognition - NER) e análise de sentimento, são essenciais (MANNING & SCHÜTZE, 1999).

Chatbots modernos utilizam PLN para entender a intenção do usuário (Intent Recognition) e gerenciar o diálogo (Dialogue Management), oferecendo atendimento automatizado, como explorado por JURAFSKY & MARTIN (2020) em sua atualização sobre processamento de fala e linguagem. Modelos transformers como BERT (DEVLIN et al., 2019) e GPT (BROWN et al., 2020) revolucionaram o campo do PLN, permitindo compreensão contextual muito mais rica e gerando respostas mais naturais e adequadas.

Para RODRIGUES et al. (2020) destacam os desafios linguísticos particulares, como a riqueza de expressões idiomáticas, variações regionais e ambiguidades semânticas que exigem tratamento especializado nos sistemas de PLN.

2.4 Análise Preditiva e Otimização de Estoque

A previsão de demanda utiliza dados históricos e modelos estatísticos/ML para estimar vendas futuras. Técnicas de séries temporais, como ARIMA, e modelos de ML mais avançados, como Redes Neurais Recorrentes (RNNs) e Long Short-Term Memory (LSTMs), são eficazes para capturar padrões sazonais e tendências.

FILDES et al. (2019) demonstram que modelos de ensemble e XGBoost frequentemente superam métodos tradicionais em previsões de séries temporais para e-

commerce, especialmente quando incorporam variáveis externas como sazonalidade, promoções e tendências de mercado.

A otimização de estoque aplica essas previsões para minimizar custos de armazenagem e evitar rupturas (stockouts), seguindo princípios estabelecidos por BALLOU (2006) e atualizados com técnicas de IA por HU et al. (2022).

2.5 Ética e Regulamentação em IA

A implementação de IA levanta questões éticas cruciais. Frameworks como FAT/FATE (Fairness, Accountability, Transparency, Ethics) são essenciais. Autores como O'NEIL (2016) alertam sobre os perigos do viés algorítmico em "Weapons of Math Destruction", enquanto FLORIDI (2019) discute a ética da informação em um mundo dataficado.

A OCDE (2019) estabeleceu princípios para IA responsável, enfatizando transparência, explicabilidade e respeito aos direitos humanos. O IEEE (2021) desenvolveu o framework "Ethically Aligned Design" para orientar o desenvolvimento de sistemas de IA centrados no ser humano.

A conformidade com regulamentações como a LGPD (Lei Geral de Proteção de Dados Pessoais - Lei nº 13.709/2018) no Brasil é mandatória, exigindo atenção à privacidade e ao consentimento do usuário, como detalhado por BIONI (2021) em seu estudo sobre proteção de dados no contexto brasileiro.

3 PLANEJAMENTO ESTRATÉGICO: BASES PARA A IMPLEMENTAÇÃO DE IA

A implementação bem-sucedida de IA na ShopSmart deve começar com uma base

sólida, focando em:

3.1 Governança de Dados

- **Avaliação da infraestrutura existente:** Mapear sistemas atuais, fluxos de dados e capacidade de armazenamento/processamento.
- **Identificação de fontes de dados:** Listar todas as fontes relevantes (histórico de compras, navegação, logs de atendimento, dados de produtos, estoque).
- **Qualidade e preparação dos dados:** Estabelecer processos para limpeza, validação e enriquecimento dos dados.
- **Políticas de governança:** Definir claramente regras para coleta, armazenamento, acesso e uso dos dados, em conformidade com a LGPD.
- **Ciclo de vida dos dados:** Implementar políticas de retenção e descarte de dados em conformidade com requisitos legais e de negócio.

3.2 Identificação e Priorização de Problemas

- **Análise quantitativa:** Mensurar o impacto financeiro de cada problema (taxa de abandono de carrinho, ineficiência nas recomendações, tempo de espera no atendimento, custos de estoque).
- **Mapeamento solução-problema:** Estabelecer como cada solução de IA proposta endereçará problemas específicos.
- **Matriz de impacto-esforço:** Priorizar iniciativas considerando potencial de retorno e complexidade de implementação.
- **Definição de KPIs:** Estabelecer métricas claras para avaliar o sucesso

de cada iniciativa.

3.3 Capacitação Interna

- **Avaliação de competências:** Mapear habilidades existentes e identificar lacunas.
- **Programa de treinamento:** Desenvolver capacitação específica para diferentes perfis (técnicos, gestores, operacionais).
- **Gestão da mudança:** Preparar a organização para novos processos e ferramentas, garantindo adoção e minimizando resistências.
- **Parcerias estratégicas:** Identificar possíveis parceiros tecnológicos para complementar competências internas.

3.4 Redução do Abandono de Carrinho com IA

A IA pode ser utilizada para melhorar a retenção de clientes e reduzir a taxa de abandono de carrinho:

- **Análise Comportamental:** Utilizar Machine Learning para analisar em tempo real o comportamento do usuário (páginas visitadas, tempo no site, produtos no carrinho, histórico de compras) para identificar padrões que precedem o abandono (JORDAN & MITCHELL, 2015).
- **Personalização Dinâmica:** Com base nessa análise, acionar intervenções personalizadas: oferecer um desconto específico para um item no carrinho, exibir um pop-up com um benefício (frete grátis), ou enviar notificações (e-mail, push no app) com lembretes e incentivos.

HAMILTON et al. (2021) demonstram que implementações bem-sucedidas de

personalização dinâmica podem reduzir o abandono de carrinho em até 25%, com retorno sobre investimento significativo.

4 SOLUÇÕES BASEADAS EM IA

Esta seção detalha as três soluções principais propostas, incluindo aspectos técnicos, exemplos de mercado, desafios de implementação e métricas de avaliação.

4.1 Sistema de Recomendação Inteligente

Um sistema de recomendação combina ciência de dados e aprendizado de máquina. Para ser treinado com sugestões mais precisas, necessita de:

- **Coleta de dados dos usuários:** comentários, curtidas, histórico de navegação, carrinho de compras, cliques, histórico de pesquisa, etc.
- **Armazenamento e processamento:** Data warehouse e/ou data lake com capacidade para processar grandes volumes de dados.
- **Análise e modelagem:** Aplicação de algoritmos de ML para identificar padrões e correlações.
- **Filtragem e refinamento:** Otimização contínua do modelo para aumentar precisão e qualidade das recomendações.

Um exemplo bem documentado é o sistema de recomendação da Netflix, descrito por GOMEZ-URIBE & HUNT (2016). A plataforma utiliza uma combinação de várias tecnologias e algoritmos como machine learning para analisar o comportamento dos usuários, collaborative filtering para identificar padrões entre os usuários, deep learning para personalizar as recomendações, big data e cloud computing para processar grandes volumes em tempo real e oferecer

sugestões precisas.

4.1.1 Abordagem de Implementação

Uma forma de implantar seria utilizando uma abordagem híbrida, combinando filtragem colaborativa (baseada no comportamento dos usuários) com análise baseada em conteúdo (utilizando características dos produtos). Esta combinação supera as limitações de cada método individual e melhora a qualidade das recomendações (RICCI et al., 2011).

4.1.2 Stack Tecnológico Recomendado

- **Linguagem:** Python.
- **Bibliotecas de ML:** pandas, numpy, scikit-learn, scipy, TensorFlow, PyTorch.
- **Armazenamento:** PostgreSQL para dados estruturados, Redis para cache de recomendações.
- **Processamento distribuído:** Apache Spark para processamento de grandes volumes de dados.
- **Deployment:** Docker containers orquestrados com Kubernetes para escalabilidade.

4.1.3 Desafios na Implementação

- **Cold Start:** Dificuldade inicial com novos usuários e produtos. Mitigação: utilizar popularidade, recomendações baseadas em conteúdo ou demográficas inicialmente.

- **Escalabilidade:** O sistema precisa lidar com um volume crescente de usuários, produtos e interações em tempo real. Exige infraestrutura robusta (preferencialmente cloud).
- **Diversidade:** Evitar "bolhas de filtro" recomendando apenas itens óbvios. Introduzir alguma aleatoriedade controlada ou focar em diversificar as recomendações (RICCI et al., 2011).
- **Avaliação:** Definir métricas corretas (precisão, recall, diversidade, cobertura, impacto em vendas) e realizar testes A/B sistemáticos.

4.1.4 Métricas de Avaliação

- **Taxa de conversão:** Percentual de recomendações que resultam em cliques/compras.
- **Lift de receita:** Aumento percentual nas vendas atribuível às recomendações.
- **Diversidade de recomendações:** Variação nos produtos recomendados.
- **Tempo de resposta:** Latência do sistema ao gerar recomendações em tempo real.

4.2 Atendimento Automatizado (Chatbot Inteligente)

A integração de um chatbot baseado em Processamento de Linguagem Natural (PLN) ao atendimento do cliente pode transformar a forma como as empresas interagem com seus consumidores, oferecendo uma experiência mais eficiente e personalizada.

Funcionalidades e Integrações

- **Base de conhecimento:** O chatbot pode ser conectado a uma base de conhecimento (FAQ, manuais, artigos) e extrair as informações relevantes para responder à pergunta do cliente.
- **Coleta de informações:** Conduzir conversas estruturadas para coletar dados relevantes sobre o cliente e seu problema.
- **Qualificação de leads:** Para equipes de vendas, o chatbot pode interagir com potenciais clientes, coletar informações de contato e entender suas necessidades iniciais.
- **Integração com CRM:** Reconhecer clientes recorrentes e acessar seu histórico de interações, oferecendo respostas personalizadas.
- **Escalonamento inteligente:** Identificar quando um atendente humano é necessário e transferir a conversa de forma fluida.

Um exemplo bem documentado é o da Magazine Luiza que investiu em IA para aprimorar a experiência do cliente com a assistente virtual Lu. RIBEIRO et al. (2021) detalham como a assistente virtual Lu interage com clientes por meio de chats e redes sociais, respondendo a dúvidas e oferecendo recomendações de produtos. Esta tecnologia é fornecida pelo Google, utilizando a plataforma Vertex AI para alimentar o "cérebro" da assistente virtual, permitindo interações mais naturais e personalizadas.

4.2.2 Vantagens e Limitações

- **Vantagens:** Disponibilidade 24/7, respostas instantâneas para FAQs, redução de custos operacionais, escalabilidade para picos de demanda, padronização das respostas.
- **Limitações:** Dificuldade em lidar com questões muito complexas,

ambíguas ou emocionais; necessidade de manutenção e atualização constantes da base de conhecimento; risco de frustração do usuário se o fluxo de escalonamento para humanos não for eficiente.

4.2.3 Abordagem de Implementação

Uma forma de implantar seria utilizando Processamento de Linguagem Natural (PLN) para compreender as intenções dos clientes, responder a perguntas frequentes, fornecer informações sobre produtos e pedidos, e escalonar para atendentes humanos quando necessário, com foco no idioma português brasileiro.

4.2.4 Stack Tecnológico Recomendado

- **Framework principal:** RASA (open-source para desenvolvimento de assistentes).
- **PLN:** spaCy para análise linguística em português com modelos específicos para português brasileiro.
- **Vetorização de texto:** Word2Vec/FastText pré-treinados para português brasileiro ou BERTimbau (SOUZA et al., 2020).
- **Database:** MongoDB para armazenamento de conversas e contexto.

4.2.5 Interface: API REST, WebSocket para integração com múltiplos canais.

Desafios Linguísticos do Português Brasileiro

Conforme RODRIGUES et al. (2020), o desenvolvimento de chatbots em português brasileiro enfrenta desafios específicos:

- **Variações regionais:** Diferentes termos e expressões entre regiões do Brasil.
- **Expressões idiomáticas:** Riqueza de expressões que não podem ser interpretadas literalmente.
- **Ambiguidade:** Palavras com múltiplos significados dependendo do contexto.
- **Informalidade:** Uso frequente de gírias e abreviações, especialmente em conversas online.

Para mitigar esses desafios, é recomendado utilizar modelos treinados especificamente com corpus de português brasileiro e implementar mecanismos de aprendizado contínuo para adaptar o sistema às particularidades da linguagem dos usuários da ShopSmart.

4.2.6 Métricas de Avaliação

- **Taxa de resolução no primeiro contato:** Percentual de questões resolvidas sem necessidade de escalonamento.
- **Tempo médio de resolução:** Comparação entre chatbot e atendimento humano.
- **Satisfação do cliente:** NPS específico para interações com o chatbot.
- **ROI de automação:** Economia de custos operacionais vs. investimento no sistema.

4.3 Análise Preditiva e Otimização de Estoque

Com a coleta de dados históricos e análise preditiva com algoritmos de machine learning, a IA pode automatizar os pedidos de reposição com base nas previsões e determinar a melhor alocação de estoque entre diferentes locais.

Um exemplo bem documentado é o do Mercado Livre, analisado por BASTOS et al. (2022). A empresa utiliza inteligência artificial para prever demanda e otimizar o gerenciamento de estoque de forma estratégica. Emprega algoritmos de aprendizado de máquina para analisar dados históricos de vendas, tendências de mercado e sazonalidade, permitindo prever a necessidade de reposição de produtos e identificar padrões de consumo em tempo real.

4.3.1 Técnicas de Aprendizado de Máquina para Previsão

- **Regressão Linear e Não Linear:** Para modelos mais simples envolvendo relações diretas.
- **Árvores de Decisão:** Como Random Forest e XGBoost, que capturam interações complexas entre variáveis e frequentemente superam métodos tradicionais (FILDES et al., 2019).
- **Modelos de Séries Temporais:** Como ARIMA, para capturar tendências e sazonalidade.
- **Redes Neurais Recorrentes (RNN, LSTM):** Para sequências temporais complexas, especialmente com múltiplos fatores influenciadores.
- **Modelos de Ensemble:** Combinando diferentes algoritmos para obter previsões mais robustas e precisas.

4.3.2 Aprendizado por Reforço: Aplicável para otimizar políticas de estoque dinamicamente, embora mais complexo de implementar.

4.3.3 Stack Tecnológico Recomendado

- **Linguagem:** Python/R para modelagem estatística.
- **Bibliotecas:** pandas, numpy, scikit-learn, statsmodels, TensorFlow/PyTorch, XGBoost.
- **Armazenamento:** Data Warehouse como Amazon Redshift ou Google BigQuery.
- **Visualização:** Tableau ou Power BI para dashboards operacionais.
- **Automatização:** Airflow para orquestração de pipelines de dados.

4.3.4 Métricas de Avaliação

- **Acurácia da previsão:** Métricas como MAPE (Mean Absolute Percentage Error), RMSE (Root Mean Square Error).
- **Redução do capital imobilizado:** Diminuição percentual no valor de estoque mantido.
- **Taxa de ruptura (stockout):** Frequência com que produtos ficam indisponíveis.
- **Taxa de rotatividade de estoque (inventory turnover):** Eficiência na gestão de estoque.

5 ANÁLISE COMPARATIVA DE CUSTOS E BENEFÍCIOS

A tabela abaixo apresenta uma análise detalhada dos custos, benefícios, ROI esperado e tempo de implementação para cada uma das soluções propostas.

Tabela 1 – Comparativo de Custos, Benefícios e Implementação das Soluções de IA

Solução	Estimativa de Custos (R$)	Benefícios	ROI Esperado
Sistema de Recomendação	200.000 - 350.000	Aumento médio de 15-30% nas vendas cruzadas; Melhoria de 20-40% na taxa de conversão; Aumento de 10-25% no valor médio do pedido	150-300% em 12 meses
Chatbot Inteligente	120.000 - 250.000	Redução de 40-60% nos custos de atendimento; Aumento de 15-30% na satisfação do cliente; Capacidade de atendimento 24/7 sem custos adicionais	100-200% em 18 meses
Otimização de Estoque	180.000 - 320.000	Redução de 20-30% nos custos de armazenagem; Diminuição de 30-50% nas rupturas de estoque; Redução de 15-25% em capital imobilizado	120-250% em 24 meses

5.1 Considerações sobre os Custos

Os custos estimados incluem:

- Desenvolvimento ou aquisição de software;
- Infraestrutura (servidores, cloud, etc.);
- Consultoria especializada;
- Treinamento da equipe;

5.2 Manutenção (custo anual pós-implementação).

Análise de ROI

A análise de ROI sugere que todas as soluções têm potencial para retorno positivo, com o sistema de recomendação mostrando o retorno mais rápido e maior potencial de impacto direto nas vendas. No entanto, a otimização de estoque pode representar o maior impacto positivo no fluxo de caixa a longo prazo, devido à redução significativa de capital

imobilizado.

6 DESAFIOS E CONSIDERAÇÕES ÉTICAS

A implementação responsável de IA exige atenção a múltiplos fatores, como desafios éticos e técnicos:

6.1 Privacidade e Conformidade Legal

- **Conformidade com a LGPD:** Garantir que toda coleta e processamento de dados esteja em estrita conformidade com a Lei Geral de Proteção de Dados (BIONI, 2021).
- **Consentimento:** Obter consentimento claro e informado dos usuários, oferecendo opções de opt-out.
- **Direitos do titular:** Garantir mecanismos para acesso, correção e exclusão dos dados pessoais.
- **Minimização de dados:** Coletar apenas os dados estritamente necessários para cada funcionalidade da IA.
- **Anonimização:** Aplicar técnicas para proteger a identidade dos usuários sempre que possível.

6.2 Transparência e Explicabilidade

- **Transparência algorítmica:** Informar aos usuários como os dados são coletados e utilizados.
- **Explicabilidade:** Garantir que as decisões tomadas pelos sistemas de IA sejam compreensíveis e explicáveis.
- **Comunicação clara:** Informar quando o cliente estiver

interagindo com um sistema automatizado.

6.3 Viés Algorítmico e Mitigação

Os dados históricos da ShopSmart podem conter vieses (sociais, econômicos) que os modelos de IA podem aprender e amplificar. O sistema de recomendação pode criar "bolhas de filtro" ou discriminar certos grupos de usuários (O'NEIL, 2016).

Estratégias de mitigação de viés:

- Analisar os dados de treinamento em busca de vieses;
- Realizar auditorias regulares nos algoritmos e seus resultados;
- Promover diversidade na equipe de desenvolvimento;
- Utilizar métricas específicas durante o desenvolvimento para avaliar a equidade do modelo;

6.4 Aplicar técnicas de debiasing (redução de viés) aos algoritmos.

6.5 Considerações Sociais e Impacto no Trabalho

Conforme destacado por ACEMOGLU & RESTREPO (2020), a automação via IA pode ter impactos significativos no mercado de trabalho. No caso da ShopSmart, especialmente com a implementação do chatbot, é importante considerar:

- **Deslocamento de funções:** Possível redução na necessidade de atendentes humanos.
- **Requalificação:** Programas de capacitação para funções que exijam interação humana mais complexa.
- **Modelo híbrido:** Considerar uma abordagem em que IA e humanos trabalhem em conjunto, com sistemas automatizados lidando com questões rotineiras e funcionários focando em interações de maior valor.

6.6 Desafios Técnicos

- **Integração:** Os sistemas de IA devem ser integrados de forma fluida aos sistemas legados da ShopSmart.
- **Escalabilidade:** Preparar a infraestrutura para crescimento do volume de dados e usuários.
- **Manutenção contínua:** Estabelecer processos para monitoramento e refinamento constante dos modelos.
- **Segurança da informação:** Implementar medidas robustas para proteger os dados contra acessos não autorizados.

7 CONCLUSÃO

A startup ShopSmart tem uma oportunidade significativa de alavancar a Inteligência Artificial para superar seus desafios atuais e impulsionar seu crescimento. A implementação estratégica de um sistema de recomendação personalizada, um chatbot inteligente e análise preditiva para otimização de estoque pode resultar em melhorias substanciais na experiência do cliente, eficiência operacional e resultados financeiros.

O sucesso dessa implementação depende de uma abordagem faseada, começando com uma sólida governança de dados e capacitação interna. A análise de custo-benefício sugere priorizar o sistema de recomendação devido ao seu impacto direto nas vendas, seguido pelo chatbot para ganhos de eficiência no atendimento, e pela otimização de estoque, que oferece alto retorno financeiro, mas exige maior complexidade.

É crucial que a implementação seja guiada por princípios éticos robustos, com atenção especial à privacidade (conformidade com a LGPD), mitigação de vieses

algorítmicos e busca por transparência. Os desafios técnicos de integração, escalabilidade e manutenção contínua também devem ser cuidadosamente gerenciados.

Para maximizar as chances de sucesso, recomenda-se:

1. Iniciar com projetos piloto de escopo reduzido para cada solução ;
2. Estabelecer métricas claras de avaliação e realizar testes A/B rigorosos;
3. Adotar uma abordagem iterativa, com ciclos curtos de feedback e melhoria;
4. Investir na capacitação contínua da equipe interna;
5. Manter foco no equilíbrio entre inovação tecnológica e valor para o negócio.

Com um planejamento adequado e execução cuidadosa, a ShopSmart pode se posicionar como uma empresa data-driven, utilizando IA como diferencial competitivo sustentável no mercado de e-commerce.

8 REFERÊNCIAS BIBLIOGRÁFICAS

ACEMOGLU, D.; RESTREPO, P. The wrong kind of AI? Artificial intelligence and the future of labour demand. Cambridge Journal of Regions, Economy and Society, v. 13, n. 1, p. 25-35, 2020.

AGGARWAL, C. C. Recommender Systems: The Textbook. Springer, 2016.

BALLOU, R. H. Gerenciamento da Cadeia de Suprimentos/Logística Empresarial. 5. ed. Porto Alegre: Bookman, 2006.

BASTOS, M. R.; SILVA, T. C.; ALMEIDA, V. E. Market intelligence: Como o Mercado Livre utiliza IA para otimização de estoque. Journal of Operations and Supply

Chain Management, v. 15,

n. 2, p. 112-128, 2022.

BIONI, B. R. Proteção de dados pessoais: a função e os limites do consentimento. 2. ed. Rio de Janeiro: Forense, 2021.

BROWN, T. B. et al. Language models are few-shot learners. Advances in Neural Information Processing Systems, v. 33, p. 1877-1901, 2020.

DEVLIN, J. et al. BERT: Pre-training of deep bidirectional transformers for language understanding. Proceedings of NAACL-HLT 2019, p. 4171-4186, 2019.

FILDES, R.; MA, S.; KOLASSA, S. Retail forecasting: Research and practice. International Journal of Forecasting, v. 35, n. 1, p. 73-87, 2019.

FLORIDI, L. The Ethics of Information. 2. ed. Oxford: Oxford University Press, 2019. GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep Learning. Cambridge: MIT Press, 2016.

GOMEZ-URIBE, C. A.; HUNT, N. The Netflix recommender system: Algorithms, business value, and innovation. ACM Transactions on Management Information Systems, v. 6, n. 4, p. 13:1-13:19, 2016.

HAMILTON, R.; VOHS, K. D.; MCGILL, A. L. Dynamic personalization: Improving customer retention in online retail. Journal of Marketing Research, v. 58, n. 5, p. 857-877, 2021.

HU, Z.; LI, G.; YANG, J. Inventory optimization with deep reinforcement learning in e-commerce. International Journal of Production Economics, v. 233, 108009, 2022.

IEEE. Ethically Aligned Design: A Vision for Prioritizing Human Well-being with Autonomous and Intelligent Systems. IEEE Global Initiative on Ethics of Autonomous and

Intelligent Systems, 2021.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. Science, v. 349, n. 6245, p. 255-260, 2015.

JURAFSKY, D.; MARTIN, J. H. Speech and Language Processing. 3. ed. (Draft). Prentice Hall, 2020.

KOREN, Y.; BELL, R.; VOLINSKY, C. Matrix Factorization Techniques for Recommender Systems. Computer, v. 42, n. 8, p. 30–37, 2009.

MANNING, C. D.; SCHÜTZE, H. Foundations of Statistical Natural Language Processing. Cambridge: MIT Press, 1999.

MITCHELL, T. M. Machine Learning. New York: McGraw Hill, 1997.

OCDE. Recommendation of the Council on Artificial Intelligence. OECD Legal Instruments, 2019.

O'NEIL, C. Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy. New York: Crown Publishing Group, 2016.

PROVOST, F.; FAWCETT, T. Data Science for Business: What You Need to Know about Data Mining and Data-Analytic Thinking. Sebastopol: O'Reilly Media, 2013.

RIBEIRO, F. N.; COSTA, J. P.; MEIRA, W. Inteligência artificial no varejo brasileiro: o caso da Magazine Luiza. Revista de Administração de Empresas, v. 61, n. 4, p. 1-14, 2021.

RICCI, F.; ROKACH, L.; SHAPIRA, B. (Ed.). Recommender Systems Handbook. Springer, 2011.

RODRIGUES, M. V.; SANTOS, D. S.; DUARTE, A. S. Desafios linguísticos no

desenvolvimento de chatbots em português brasileiro. Revista Brasileira de Computação Aplicada, v. 12, n. 3, p. 31-44, 2020.

SOUZA, F.; NOGUEIRA, R.; LOTUFO, R. BERTimbau: Pretrained BERT models for Brazilian Portuguese. 9th Brazilian Conference on Intelligent Systems (BRACIS), p. 403-417, 2020.

ZHANG, S.; YAO, L.; SUN, A.; TAY, Y. Deep learning based recommender system: A survey and new perspectives. ACM Computing Surveys, v. 52, n. 1, p. 1-38, 2019.