

Arquitetura de sistemas de recomendação para apoio ao vendedor no uso de sistemas de força de vendas em empresa com grande portfólio de produtos

Fabio Kazuo Ohashi¹, Marcos Antonio Gaspar¹, Ivanir Costa¹, Fellipe Silva Martins¹, Fábio Luís Falchi de Magalhães²

kazuo.ohashi@hotmail.com; marcos.antonio@uni9.pro.br; ivanirc@uni9.pro.br; fellipemartins@uni9.pro.br; fabiosimp@gmail.com

¹ Universidade Nove de Julho, Rua Vergueiro, 235/249, 01525-000, São Paulo (SP) - Brasil

² Universidade Federal de São Paulo, Avenida Cesare Mansueto Giulio Lattes, 1.201, 12247-014, São José dos Campos (SP) - Brasil

DOI: 10.17013/risti.42.46-61

Resumo: Empresas que fazem distribuição de produtos no atacado normalmente têm grande quantidade de itens comercializados de diversos fabricantes em seu portfólio de produtos. Assim, encontrar e recomendar produtos ao cliente entre milhares de possibilidades se caracteriza num desafio para a equipe de vendas. O objetivo deste artigo é mostrar uma arquitetura de sistema de recomendação para implantação em ferramentas de sistema de automação de força de vendas e suportado por Inteligência Artificial que possa recomendar produtos online a cada interação no processo de venda. Foram usados os seguintes os métodos e materiais: revisão sistemática da literatura, pesquisa exploratória quali-quantitativa, experimentos computacionais, estudo de caso, prova de conceito do sistema e pesquisa com o método Delphi junto a especialistas com aplicação de questionários. A arquitetura foi aplicada construindo-se uma prova de conceito numa empresa de distribuição de autopeças na qual o sistema foi capaz de fornecer recomendações de quatro algoritmos diferentes.

Palavras-chave: Sistemas de recomendação. Automação de força de vendas. Gestão do conhecimento. Disseminação do conhecimento.

Recommender System Architecture to support salesperson using Sales Force Automation Systems In large product portfolio companies

Abstract: Wholesale distribution companies usually have a large number of items sold by different manufacturers in their product portfolio. Finding and recommending products to the customer among thousands of possibilities is a challenge for the sales team. In addition, there are also new product releases and promotions that are added to the portfolio frequently. This paper proposes to develop an architecture to implement a Sales Force Automation system supported by Artificial Intelligence that can recommend products online to a sales professional when making a purchase order. To achieve this objective, the following methods and

experiments were used: systematic literature review, qualitative and quantitative exploratory research, experiments, case study, proof of concept, and survey with the Delphi method. The proposed architecture was applied by building a proof of concept in an auto parts distribution company in which the system was able to provide recommendations for four different algorithms.1cm.

Keywords: Recommender systems. Sales force automation. Knowledge management. Knowledge dissemination.

1. Introdução

Empresas com grande portfólio de produtos como distribuidoras de alimentos, produtos automotivos e farmacêuticos apresentam maior complexidade estrutural para disseminar o conhecimento por todos os profissionais e áreas envolvidos em seus processos internos (Vinita & Feisal, 2017). Encontrar e recomendar ao cliente uma lista de produtos dentre milhares de possibilidades se configura num desafio para a equipe de vendas. Em acréscimo à situação relatada, há ainda os lançamentos e promoções de produtos que são acrescentados às linhas continuamente (Mariadoss, Milewicz, Lee, & Sahaym, 2014).

Além disso, de acordo com Syam e Sharma (2018), o perfil do profissional de vendas atual mudou para um profissional com plataformas e soluções informatizadas que processa os pedidos em sistemas conectados à Internet. Em vários setores, os pedidos em papel foram substituídos pelos sistemas SFA (*Sales Force Automation*), que contribuíram para capacitar o vendedor com uma ferramenta mais eficiente para suportar o processo de venda. O mercado de sistemas SFA está em constante crescimento ao longo dos últimos anos, sendo que em 2018 chegou a US \$ 6,9 bilhões, de acordo o relatório Quadrante Mágico Gartner (2019).

Embora o perfil do vendedor tenha mudado, o relacionamento comprador-vendedor não desapareceu e se configura um importante requisito do processo de venda (Arli, Bauer, & Palmatier, 2017). Além disso, da mesma forma que os vendedores têm acesso às ferramentas informatizadas, os compradores têm acesso à soluções automatizadas que disponibilizam informações sobre produtos e serviços da empresa de forma instantânea e sem a assistência de um profissional de vendas durante a consulta. Portanto, o papel do vendedor precisa mudar para suprir as necessidades únicas de cada comprador, que cada vez mais exige maior valor agregado na prestação de suporte por parte do vendedor durante o processo de aquisição do produto ofertado (Rocco & Bush, 2016).

Nesse sentido, Sistemas de Recomendação (*RS – Recommender Systems*) são uma tecnologia que pode ajudar os profissionais de vendas, sendo compostas por sistemas baseados em IA (Inteligência Artificial), utilizados em transações de comércio eletrônico e aplicativos de música e vídeos, por exemplo (Barragán, Chanchí, & Campo, 2020). Estas soluções de RS sugerem itens ao comprador de forma personalizada, baseando-se para tanto na similaridade de seu perfil com outros usuários (Aggarwal, 2016). Tais soluções de RS são especialmente aplicáveis em processos de venda em transações entre empresas (*business to business – B2B*) dadas a diversidade e especificidades técnicas que envolvem os produtos nesse tipo de negociação.

O objetivo deste artigo é: Desenvolver uma arquitetura de Sistema de Recomendação para implantação em ferramentas de Sistema de Automação de Força de Vendas suportada por Inteligência Artificial que possa recomendar produtos ao profissional de vendas online a cada interação no processo de venda de empresa distribuidora com grande portfólio de produtos.

2. Revisão da literatura

Nesta seção serão discutidos os pressupostos e conceitos de SFA e CRM suas principais diferenças e características dos elementos constituintes desses sistemas.

2.1. Sistemas de Automação de Força de Vendas

Sistemas de Automação de Força de Vendas (SFA) são ferramentas de *software* que fornecem aos gestores e aos membros da sua equipe muitas funcionalidades para aumentar a eficiência e eficácia da equipe de vendas (Gannage, 2018). Os sistemas SFA têm conjuntos de funcionalidades voltadas ao processo de vendas, apesar de cada fabricante disponibilizar um conjunto de ferramentas diferentes de acordo com a sua estratégia.

2.2. Comparação entre SFA e CRM

Como os sistemas SFA e CRM (*Customer Relationship Management*) têm muitos recursos em comum e buscam essencialmente objetivos similares, tais como aumento do desempenho de vendas e melhoria da eficiência operacional, o entendimento da diferenciação entre ambos pode levar a confusões sobre a utilidade e os requisitos básicos de cada um desses sistemas.

Segundo Rolus Tech (2020), os sistemas CRM aprimoram o relacionamento com o cliente e aumentam sua retenção à organização. Eles registram, analisam e centralizam as informações nos pontos de contato do cliente ao longo do seu ciclo de vida. Isso fornece informações importantes sobre o histórico de interações, o seu comportamento e os padrões de compra, oferecendo assim mais oportunidades de venda e *cross-selling* (vendas cruzadas de produtos). Já os sistemas SFA otimizam os fluxos de trabalho de vendas, se concentrando em conseguir mais clientes e fechar mais negócios por meio da otimização dos processos de vendas. Juntamente com recursos para rastrear o desempenho e gerar previsões de vendas, proporcionando maior visibilidade ao gerenciamento do processo de vendas de forma mais ampla.

Buttle e Maklan (2019) classificam os SFA em três categorias: sistemas SFA especialistas: aqueles sistemas que possuem somente as funções para automação de força de vendas; SFA como parte de sistemas CRM: SFA é um módulo de um sistema maior CRM; ou SFA como parte de sistemas ERP: SFA é um módulo de um sistema maior ERP.

2.3. Sistemas de Recomendação - Recommender Systems

Recommender Systems (RS) ou Sistemas de Recomendação são utilizados por várias empresas como Netflix, Amazon e Facebook (Banik, 2018) para, utilizando tecnologias

de ponta, ajudar os usuários a achar o que procuram mais facilmente. RS são uma das ferramentas muito utilizadas para aumentar o lucro das empresas e auxiliar os usuários (Aguiar, Araújo, & Costa, 2020).

Os três tipos básicos de recomendações são, segundo (Adomavicius & Tuzhilin, 2005) (Burke, 2007): Collaborative Filtering, Content-based Filtering e Sistemas Híbridos.

2.4. O problema de Cold Start

Para que o sistema comece a gerar recomendações, quando se usa a técnica de *Collaborative Filtering*, os usuários devem ter avaliado um número suficiente de itens. Somente então, o Sistema de Recomendação conseguirá aprender as preferências do usuário e conseguir recomendar itens mais apropriados ao seu perfil (Kale, Petrie, Bikdash, & Topal, 2018). O *Cold Start* se manifesta também quando são adicionados novos itens ao sistema. Assim, até que o sistema seja avaliado por um expressivo número de usuários, os métodos *Collaborative Filtering* não conseguirão efetuar recomendações consistentes (Aharon et al., 2015).

2.5. Ineditismo do tema deste artigo

Nesta seção relata-se as pesquisas feitas a fim de se demonstrar o ineditismo da solução proposta neste artigo.

2.5.1. Pesquisa de artigos acadêmicos

Foi feita uma revisão sistemática da literatura (SLR) (Todeschini & Baccini, 2016) e (Kitchenham et al., 2009), a questão de pesquisa foi: Qual é o *framework*/arquitetura mais utilizado na implantação de um SFA com Sistema de Recomendação?

Os seguintes termos foram definidos para busca: “Sistemas recomendação”, “força vendas”, “Automação força vendas”, “Recommender system”, “sales force”, “Sales force”, “Sales force automation”.

Para as buscas de trabalhos optou-se pelas bases Proquest, Scielo, Google Scholar, Emerald, IEEE e Web of Science. As pesquisas foram feitas de setembro de 2019 a maio de 2020. No total foram encontrados 671 artigos, então passou-se à próxima etapa da SLR que foi a leitura dos Abstracts dos artigos.

Foram encontrados apenas artigos sobre Recomendações de Previsão de Vendas usados em sistemas SFA, porém a Previsão de Vendas se difere de Recomendação de Vendas, no sentido de que a primeira é uma necessidade dos níveis gerenciais da empresa de se ter uma estimativa do volume de faturamento futuro, enquanto a segunda é a ferramenta utilizada pelo profissional de vendas para efetivar a venda. Portanto, como resultado, não foi encontrado nenhum trabalho que satisfizesse aos critérios estabelecidos.

2.5.2. Pesquisa de soluções comerciais

De acordo com os relatórios “Magic Quadrant for Sales Force Automation” de 2008 até 2019, a tecnologia IA aparece pela primeira vez somente no relatório de 2017 (Gartner Inc., 2008, 2013, 2014a, 2014b, 2016, 2017, 2019). Num relatório similar chamado

“*Forrester Wave: Sales Force Automation Solutions*”, que foi publicado apenas em 2008 (Forrester, 2008) e outro em 2017 (Forrester, 2017). Também neste caso, apenas em 2017 surge a tecnologia IA. Em ambos os tipos de relatórios, somente dois fornecedores oferecem soluções de IA: a Microsoft, com seu produto *Dynamics 365* e a empresa Salesforce, com seu produto *Sales Cloud*.

Consultando-se a documentação das duas soluções citadas nos relatórios (Salesforce, 2020) (Microsoft, 2020), verifica-se o uso da IA nesses sistemas são aplicados em módulos diferente do SFA proposto neste artigo. O item 2.5.3 discute sobre as diferenças entre o sistema proposto neste artigo e as soluções comerciais existentes.

2.5.3. Diferenças entre um sistema de recomendação B2C para o sistema proposto

Normalmente, os Sistemas de Recomendação são usados fazendo recomendação de itens para o próprio usuário que vai consumir o produto. Por exemplo, no e-commerce Amazon.com há um RS que sugere produtos ao usuário, conforme este busca por produtos. Neste caso, o sistema de e-commerce com RS é o Vendedor e o usuário que navega no website é o Comprador.

No sistema proposto neste artigo, o usuário final é o Comprador (que não tem acesso direto ao sistema SFA, e o Vendedor é o representante de vendas que opera o SFA. Isso significa que, apesar de o Sistema de Recomendação recomendar produtos ao usuário, quem vê as recomendações é o Vendedor técnico da empresa. Nessa configuração, o usuário final não consegue saber se a recomendação veio do sistema SFA ou do Vendedor.

2.5.4. Conclusão sobre o ineditismo deste artigo

Pelas razões expostas nos itens 2.5.1, 2.5.2 e 2.5.3 verifica-se que não há trabalhos relacionados com o tema explorado isso revela o ineditismo do trabalho em relação às abordagens de Sistemas de Força de Vendas do estado da arte.

2.6. Arquitetura de recomendação para implantação proposta

Nesta seção é exposta a Arquitetura de Recomendação desenvolvido neste artigo, de modo a facilitar a compreensão de sua futura implantação em ferramentas de Sistema de Automação de Força de Vendas e suportado por Inteligência Artificial. A Figura 1 representa o constructo onde é exposto uma matriz tridimensional relacionando as três principais etapas da arquitetura. O constructo exposto na figura representa a forte ligação entre as três etapas, que juntas formam a estrutura de recomendação que será aplicada a um SFA suportado por IA.

Na etapa ‘1 - Definir Recomendações’, nesta fase são aplicadas técnicas de KDD (Knowledge Discovery in Databases) para a análise da estrutura de dados (atividade 1a), de modo a especificar que tipos de recomendação um RS pode produzir. A equipe responsável deve ser capaz de analisar como extrair conhecimento útil das bases de dados da empresa para uso nas atividades de vendas. Em complemento, a utilidade das recomendações (atividade 1b) deve ser mensurada pelos usuários da solução e pelos compradores que tomam a decisão final num processo de compra assistida.

Na etapa ‘2 – Construir a POC’ (Proof Of Concept) faz-se importante ressaltar que a principal função de um SFA é realizar o pedido de venda. Por essa razão, o sistema de recomendação não pode impedir o profissional de realizar a venda caso o módulo de recomendação apresente alguma falha. Assim, a arquitetura a ser desenvolvida para o sistema (2a) deve prever e evitar esse tipo de ocorrência no processo. Além disso, a performance do sistema deverá ser suficientemente rápida para ser capaz de recomendar produtos à medida que o usuário procura os itens que o comprador solicita. Em adição, a interface gráfica (UX – *User Experience*) do sistema de recomendação (2b) deve ser minimalista o suficiente para não comprometer a visualização dos conteúdos exibidos ao vendedor na área do pedido de vendas.

E finalmente, a etapa ‘3 - Diminuir *Cold Start*’ trata do problema do *Cold Start*, (item 2.4) Existem vários métodos para se mitigar esse problema, na atividade 3a deve-se definir qual método será utilizado e na etapa 3b implementá-lo para que essas informações possam ser utilizadas como base de dados inicial do sistema a ser implementado na empresa.

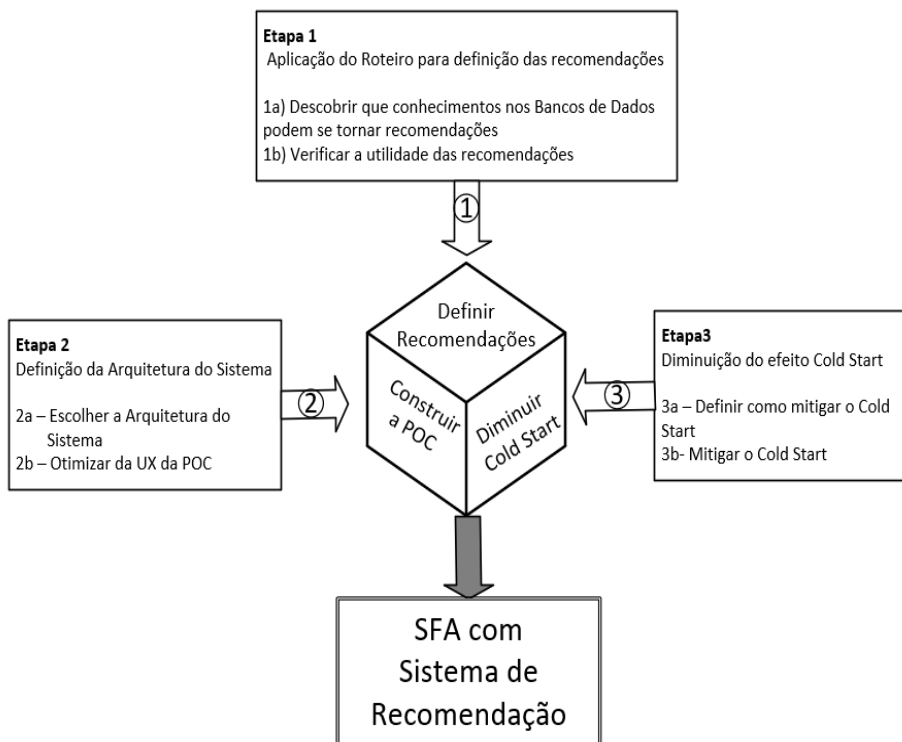


Figura 1 – Constructo da arquitetura para implantação desenvolvido
Fonte: autor.

As etapas da arquitetura proposta no constructo elaborado nesta tese foram baseadas nos trabalhos dos autores listados no Quadro 1.

Etapa / Autores	Descrição da contribuição / Definição empregada / Aplicação neste trabalho
1A (Piateski & Frawley, 1991)	Autor seminal que descreve os princípios da técnica de KDD para extração do conhecimento. “KDD é um processo não trivial de extração de informações úteis de dados” (p.3). Nesta tese utiliza-se essa técnica para a definição de quais recomendações o sistema proposto pode fornecer.
1A (Portugal, Alencar, & Cowan, 2018)	Autores efetuaram uma revisão dos algoritmos de recomendação mais utilizados. Os autores estudaram 129 artigos sobre os principais algoritmos de recomendação. Juntamente com os resultados do KDD, pode-se definir quais tipos de Sistemas de Recomendação a empresa pode construir.
1B (Batterton & Hale, 2017)	Autores sugerem técnicas de desenho de pesquisa tipo <i>survey</i> . A escala do tipo Likert pode ser usada para se medir a opinião dos entrevistados. Na pesquisa feita nesta tese a escala do tipo Likert foi usada para validar a utilidade das recomendações.
2A (Falk, 2019)	Autor propõem uma arquitetura de um Sistema de Recomendação para e-commerce. “Em favor da performance e confiabilidade, o ideal é não adicionar o banco de dados de evidências (recomendação) junto da aplicação web” (p. 47). Nesta tese propõe-se o uso de APIs para conexão entre o sistema de recomendação e a aplicação SFA.
2B (Chajadi, Uddin, & Gutwin, 2020)	Autor propõe princípios de usabilidade de interfaces utilizando ícones. Entre as técnicas sugeridas o autor realça que “os ícones de imagens concretas aumentam grau de aprendizado” (p. 1). Neste trabalho os ícones foram utilizados para representar qual tipo de recomendação é apresentada não reduz muito a área de resultados de busca do sistema já existente.
3A (Aharon et al., 2015)	Autor descreve o problema do Cold Start e sugere algumas alternativas para mitigar a ocorrência do problema. “Entre elas, cita que “se faça uma entrevista com usuários e solicite que eles classifiquem itens” (p. 83). Neste trabalho foi escolhida essa alternativa para aplicação de entrevistas estruturadas com especialistas.
3B (Skulmoski, Hartman, & Krahn, 2007)	Autor propõe uma estrutura de aplicação do método Delphi para ser utilizada em trabalhos de <i>Stricto Sensu</i> . Nesta tese o método Delphi foi utilizado para se alcançar consenso a respeito de qual seria o resultado esperado de cada recomendação.

Quadro 1 – Principais autores utilizados na arquitetura proposto

Fonte: autores.

3. Apresentação dos resultados

Neste capítulo é exposto o protocolo da implantação da pesquisa-ação feita numa empresa que atua no ramo de distribuição de autopeças de reposição fundada em 1989. A sede de 12.000 m² está situada na Zona Oeste do município de São Paulo (Brasil).

Sua linha de produtos abrange mais especificamente o segmento acessórios automotivos, totalizando mais de 35.000 itens no portfólio. Tem aproximadamente 200 vendedores, com uma carteira de 4.500 clientes em todo Brasil.

Uma das principais dificuldades do vendedor neste tipo de empresa é conhecer toda a linha de produtos da empresa, e este problema é ainda maior quando o vendedor não tem muita experiência neste mercado ou sobre a linha de produtos da empresa. Nesta situação, encontrar um produto entre milhares pode ser um desafio para o vendedor. A arquitetura proposta no item 2.6 foi implementada na empresa citada a fim de testar a aplicabilidade da arquitetura proposta.

3.1. Aplicação da Etapa 1

Utilizando as técnicas de KDD (Descoberta de Conhecimento em Bancos de Dados) (Piateski & Frawley, 1991) (Fayyad, Piatesky-Shapiro, & Smyth, 1996). e serviços de Consultoria especializada em Sistemas de Recomendação (Guillet et al., 2016) (Dalkir, 2005). A equipe fez uma análise completa dos repositórios de dados estruturados e não estruturados da empresa, a equipe propôs que o sistema SFA poderia prover quatro tipos de recomendações inteligentes: (1) Quem comprou isso, também comprou. (2) Seu concorrente comprou isso. (3) É um novo produto. (4) O produto tem um preço mais baixo em comparação com outros distribuidores.

Após definir quais são as recomendações que o sistema pode oferecer é necessário medir o quanto os stakeholders do SFA (neste caso, vendedores e compradores) percebem os benefícios das recomendações fornecidas pelo sistema.

Para atingir tal intento, um questionário de pesquisa proposto neste artigo segue as características indicadas por (BATTERTON; HALE, 2017), as perguntas devem ser formuladas para medir como o entrevistado (vendedores e compradores) concorda com a afirmação proposta, empregando-se para tanto uma escala do tipo Likert.

O questionário final foi enviado a 185 vendedores. Foram recebidas 52 respostas válidas. Outro questionário foi enviado para 3.500 compradores. Foram recebidas 56 respostas válidas.

Sabe-se que existem regiões brasileiras com realidades econômicas diferentes (Amado, 2018), por isso as respostas foram agrupadas por regiões: Norte, Nordeste, Centro-Oeste, Sudeste e Sul. Com isso, procura-se verificar se as respostas são consistentes e independentes do cenário econômico onde o vendedor/comprador atua.

Realizou-se um teste de hipóteses usando a técnica ANOVA para verificar em cada pergunta, se os valores médios da resposta para cada uma das grandes regiões estão dentro da média da amostra total. Definimos $\alpha = 0,05$ e a hipótese nula como: H_0 :

$$\mu_{north} = \mu_{northeast} = \mu_{central-west} = \mu_{southeast} = \mu_{south}$$

O F crítico para a Pesquisa do Vendedor é 2,5787 e o F crítico para a Pesquisa do Comprador é 2,5740. Portanto, não rejeitamos a hipótese nula, o que significa que não temos evidências estatisticamente significantes com $\alpha = 0,05$ para mostrar que há uma diferença nos valores médios de cada região brasileira.

A média das respostas para todas as perguntas foram acima de 3,00. Isso quer dizer que, comparando-se o valor médio que cada resposta com a escala Likert (que vai de 1 a 5), os respondentes concordam com as afirmativas das perguntas do questionário.

Após análise, conclui-se que as 4 recomendações propostas têm utilidade percebida pelos Vendedores e Compradores da empresa estudada.

3.2. Aplicação da Etapa 2

A arquitetura proposta neste artigo baseia-se no trabalho de Falk (2019). Ele propõe que o Sistema de Recomendação se conecte ao Sistema de Venda usando-se APIs (Application Programming Interface) pois segundo o autor usando essa técnica, qualquer lentidão ou falha na recomendação não prejudica o sistema de SFA.

Para que as telas desenvolvidas nesta POC não sejam muito genéricas a ponto de não se conseguir aferir um resultado prático da teoria aplicada neste trabalho, se faz necessário ter um caso prático de um SFA de uma empresa real para verificar se os objetivos dessa POC são alcançados. A funcionalidade principal do sistema está focada na geração de pedidos de venda (Figura 2), além disso o sistema possui módulos de busca de produtos, cálculo de frete e cálculo de impostos, análise das vendas, títulos emitidos, emissão de boletos, etiquetas, acesso as promoções e lançamentos e tutoriais em vídeo.

A POC do sistema proposto possui todas as funcionalidades do sistema anterior, com o acréscimo do módulo de ‘Recomendações’, este artigo irá focar apenas no módulo de Buscar Produtos porque é nele que o Sistema de Recomendação irá atuar.

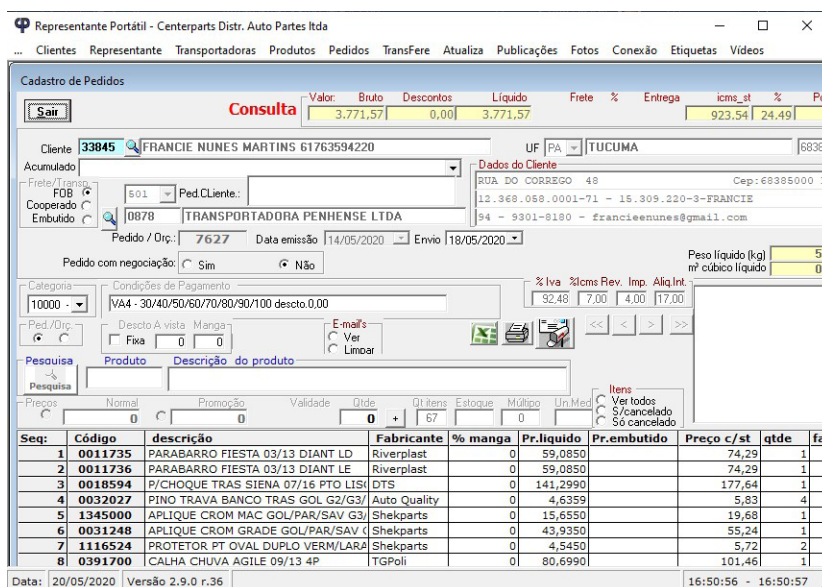


Figura 2 – Sistema Anterior - Tela de Criação de Pedidos
Fonte: autor.

Utilizando-se dos princípios de usabilidade 2 e 3 de Nielsen (1993), decidiu-se usar ícones ao invés de texto para representar as recomendações. Os ícones permitem uma melhor associação entre o mundo real e a interface de um software. Deve-se levar em consideração que é importante que o ícone represente uma metáfora coletiva da informação que se deseja passar ao usuário (Gittins, 1986).

Em pesquisas feitas no artigo “*Effects of Visual Distinctiveness on Learning and Retrieval in Icon Toolbars*” (Chajadi et al., 2020) verificou-se que o uso de traços minimalistas e ícones monocromáticos não prejudicam a usabilidade e a identificação do significado do ícone. O que ajuda na sua identificação é a familiaridade que o usuário tem com o desenho do ícone (Yan, 2011). (Quadro 2)

			
Quem comprou isso também comprou	Seu concorrente comprou isso	É um novo produto	Preço mais baixo

Quadro 2 – Ícones utilizados
Fonte: autores.

Para ilustrar o funcionamento do sistema proposto é exposto um exemplo na Figura 4 relativo à uma busca e das recomendações do produto ‘espelho retrovisor esquerdo’ com controle para a marca/modelo Fiat Fiorino 2014 em diante. Os seguintes passos (1 a 4) devem ser executados pelo usuário Vendedor:

1. – No campo de pesquisa digita-se o código de um Espelho Retrovisor (64628)
2. – O SFA retorna informações do produto buscado (Descrição, preço estoque etc.)
3. – Interface do RS. Nesta área são retornadas as recomendações. Elas aparecem em forma de lista, uma vez que é possível obter-se várias recomendações para um mesmo resultado de busca.
4. – Detalhe do resultado das recomendações. Neste exemplo, o sistema retorna três recomendações: Produto 7800834 por que tem um preço menor e 64639 e 7800836 – Pois são retrovisores para o mesmo veículo (marca, modelo), porém do tipo sem controle interno. Pois a loja que revende retrovisor com controle interno pode revender retrovisor sem controle interno.

O sistema funcionará de modo similar para os outros tipos de recomendação, ou seja, dependendo do item buscado, até quatro tipos de recomendação poderão ser listados na área (3) e sinalizados com os devidos ícones, representando assim o motivo da recomendação complementar ao usuário vendedor.

A partir dos resultados apresentados nos passos anteriores, o Vendedor tem a opção de colocar a quantidade desejada no carrinho de compras. O sistema vai computar uma recomendação feita com sucesso se o vendedor colocar qualquer quantidade igual ou acima de 1 peça no carrinho de compras. Assim, se o vendedor fizer alguma busca e não colocar nenhum produto no carrinho de compras, o sistema não vai avaliar a recomendação feita.

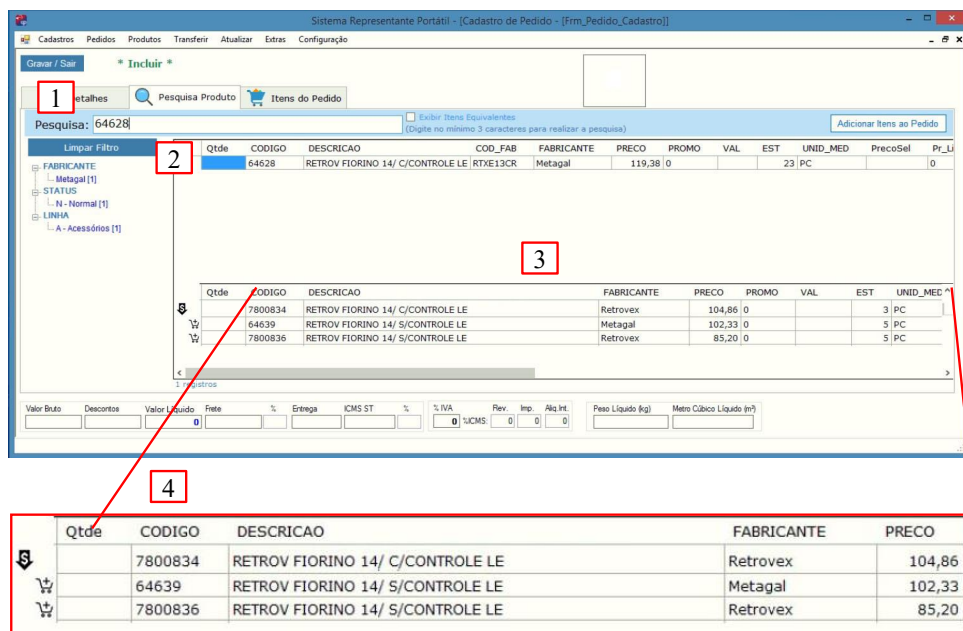


Figura 4 – Interface gráfica do RS
Fonte: autores.

3.3. Aplicação da Etapa 3

Todo novo RS apresenta como problema conhecido como *Cold Start* (conforme exposto no item 2.4). Para minimizar este problema, optou-se por montar um painel de especialistas na venda de autopeças para que eles determinem quais tipos de recomendações seriam mais úteis (Aharon et al., 2015). O resultado dessa pesquisa é especialmente proveitoso para o estabelecimento de um *baseline* inicial de resultados que o sistema final deveria fornecer.

Utilizando-se o método Delphi, as seguintes questões de pesquisa foram aplicadas aos vendedores técnicos da empresa analisada nesta pesquisa: (QP-D1) Quais categorias de produtos são os melhores para aparecer quando se tem a recomendação ‘Quem comprou isso também comprou...?’ (QP-D2) Determinar, para cada nicho de mercado atendido, quais categorias de produto são compradas. (QP-D3) Quais são as categorias de produtos que o comprador (cliente) mais solicita novidades? (QP-D4) Quais são as principais categorias de produtos que sofrem mais concorrência?

Em relação à escolha dos participantes dessa fase da pesquisa, ao se utilizar o método Delphi os especialistas participantes não são escolhidos aleatoriamente, mas sim são selecionados conforme sua experiência e conhecimento no assunto a ser explorado (Linstone & Turoff, 2002) (Hasson, Keeney, & McKenna, 2000), (Skulmoski, Hartman e Krahn (2007).

Na empresa analisada nesta pesquisa, o universo de profissionais de venda é composto de 185 pessoas. Neste grupo, os especialistas foram escolhidos utilizando-se os seguintes critérios de seleção: Experiência de mais de 5 anos na função de vendas na empresa; Mais de 10 anos de experiência de venda de autopeças; Domínio do atual sistema SFA; Alta performance de vendas.

Além dos critérios, procurou-se representar proporcionalmente as cinco regiões brasileiras, variedade em relação à idade e ao gênero dos profissionais. Dentro desses critérios foram escolhidos 10 profissionais de Vendas.

A técnica de coleta das informações utilizada foi a entrevista semiestruturada à distância, usando-se para tanto o recurso de vídeo conferência. Primeiramente foi realizada a apresentação de um documento com a proposição do novo SFA baseado nas telas elaboradas na POC, com o propósito de elucidar ao entrevistado como seria o funcionamento do sistema e como as recomendações seriam apresentadas. Após a apresentação, o pesquisador explicou a cada entrevistado como preencher do instrumento de coleta de dados.

O instrumento de coleta de dados foi feito em formato de Excel onde nas Linhas da planilha foram listadas todas as 325 categorias de produtos da empresa. As Colunas da planilha foram reservadas para a marcação das quatro respostas de pesquisa (QP-D1 a QP-D4).

Foram necessárias 2 rodadas para o consenso entre os especializadas para as QP-D2, QP-D3 e QP-D3 e formam necessárias 3 rodadas para a QP-D1.

4. Conclusões

Este trabalho contribui primeiramente trazendo à luz da Academia a falta de estudos de ferramentas inteligentes baseadas em Inteligência Artificial que possam auxiliar os profissionais de vendas nas práticas executadas em vendas presenciais com interação entre o vendedor e o comprador. Esta pesquisa também apresenta uma arquitetura de desenvolvimento para implantação de sistema de recomendação que empreendeu esforços interdisciplinares em áreas de pesquisa academicamente distintas, tais como aprendizado de máquina, KDD, desenho de interfaces e administração de vendas.

Conclui-se que Sistemas de Recomendação podem ser usados em sistemas informatizados, mesmo que as recomendações não sejam dirigidas diretamente ao profissional que decide a compra do produto recomendado. Porém, a implementação desse tipo de sistema não é uma tarefa simples e envolve profissionais de várias áreas do conhecimento. Visando facilitar tais desafios, este artigo organiza os processos de implementação numa arquitetura modelo aplicável a diferentes tipos de empresa com grande portfólio de produtos. Na pesquisa ação do caso implementado verificou-se que a arquitetura proposta mostrou-se eficiente na organização dos trabalhos e cronograma de atividades dos diferentes profissionais envolvidos.

Além disso, a arquitetura apresentada poderá servir de base para aplicação em realidades de empresas de diferentes segmentos nos processos de venda em transações B2B, dada a diversidade e especificidades técnicas que envolvem os produtos nesse tipo de negociação.

Indicam-se sugestões para pesquisas futuras, a saber: a) Mensuração da qualidade da recomendação feita pelo sistema, considerando-se que quem recebe a recomendação não é o mesmo profissional que decide se coloca o item recomendado no carrinho de compras; b) Mensuração da performance da solução indicada ao rodar vários modelos de recomendação simultaneamente, uma vez que algoritmos de Sistemas de Recomendação precisam de hardware com muito poder de processamento.

Referências

- Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734–749. <https://doi.org/10.1109/TKDE.2005.99>
- Aggarwal, C. C. (2016). *Recommender Systems: The Textbook*. Springer. <https://doi.org/10.1145/245108.245121>
- Aguiar, J. J. B., Araújo, J. M. F. R. de, & Costa, E. de B. (2020). Estudo Comparativo de Abordagens para Sistemas de Recomendação baseados em Personalidade com uso do serviço IBM Watson Personality Insights. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (40), 73–88. <https://doi.org/10.17013/risti.40.73-88>
- Aharon, M., Anava, O., Avigdor-Elgrabli, N., Drachler-Cohen, D., Golan, S., & Somekh, O. (2015). ExcUseMe: Asking users to help in item cold-start recommendations. In *RecSys 2015 - Proceedings of the 9th ACM Conference on Recommender Systems* (p. 83–90). Association for Computing Machinery, Inc. <https://doi.org/10.1145/2792838.2800183>
- Amado, A. (2018). *Disparate Regional Development in Brazil: A Monetary Production Approach* (2nd ed). Taylor & Francis. <https://books.google.com.br/books?id=PoyADwAAQBAJ>
- Arli, D., Bauer, C., & Palmatier, R. W. (2017). Relational selling: Past, present and future. *Industrial Marketing Management*, (June). <https://doi.org/10.1016/j.indmarman.2017.07.018>
- Banik, R. (2018). *Hands-on recommendation systems with Python: start building powerful and personalized, recommendation engines with Python*. Packt Publishing.
- Barragán, M. S., Chanchí, G. E., & Campo, W. Y. (2020). Sistema de recomendación para contenidos musicales basado en el análisis afectivo del contexto social. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (39), 100–113. <https://doi.org/10.17013/risti.39.100-113>
- Batterton, K. A., & Hale, K. N. (2017). The Likert Scale What It Is and How To Use It. *Phalanx*, 50(2), 32–39. <http://www.jstor.org/stable/26296382>
- Burke, R. (2007). Hybrid Web Recommender Systems. In *The Adaptive Web* (p. 377–408). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-72079-9_12

- Buttle, F., & Maklan, S. (2019). *Customer Relationship Management: Concepts and Technologies* (4th ed). Taylor & Francis. <https://books.google.com.br/books?id=I5DUDwAAQBAJ>
- Chajadi, F., Uddin, M. S., & Gutwin, C. (2020). Effects of Visual Distinctiveness on Learning and Retrieval in Icon Toolbars. In *ACM Graphics Interface Conference GI20* (p. 11). Virtual.
- Dalkir, K. (2005). *Knowledge Management in Theory and Practice*. Elsevier (Vol. 4). Elsevier Butterworth–Heinemann. <https://doi.org/10.1002/asi.21613>
- Falk, K. (2019). *Practical Recommender Systems* (1st ed). Manning Publications.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). Knowledge discovery and data mining. In *KDD-96* (Vol. 87, p. 82–88). <https://doi.org/10.1511/1999.16.807>
- Forrester. (2008). *The Forrester Wave: Sales Force Management, Q4 2008*. <https://www.forrester.com/report/The+Forrester+Wave+Sales+Force+Management+Q4+2008/-/E-RES46169>
- Forrester. (2017). *The Forrester Wave: Sales Force Automation Solutions, Q2 2017*. <https://www.forrester.com/report/The+Forrester+Wave+Sales+Force+Automation+Solutions+Q2+2017/-/E-RES136162>
- Gannage, G. (2018). Sales Force Automation: CRM, Dashboards, and Empowering Mobile Technology Used by Millennial Salespeople. *Atlantic Marketing Association Proceedings*. Recuperado de https://digitalcommons.kennesaw.edu/ama_proceedings/2018/PROSALES-SALESMGMT_T17/3
- Gartner Inc. (2008). *Magic quadrant for sales force automation 2008*. <https://www.gartner.com/doc/722909/magic-quadrant-sales-force-automation>
- Gartner Inc. (2013). *Magic quadrant for sales force automation 2013*. <https://www.gartner.com/doc/2551416/magic-quadrant-sales-force-automation>
- Gartner Inc. (2014a). *Magic quadrant for sales force automation 2014*. <https://www.gartner.com/doc/2798021/magic-quadrant-sales-force-automation>
- Gartner Inc. (2014b). *Magic quadrant for sales force automation 2014*. *Gartner RAS Core Research Note G*. <http://www.gartner.com/technology/reprints.do?id=1-1XJHQ4X&ct=140716&st=sb>
- Gartner Inc. (2016). *Magic quadrant for sales force automation 2016*. <https://www.gartner.com/doc/3405124/magic-quadrant-sales-force-automation>
- Gartner Inc. (2017). *Magic quadrant for sales force automation 2017*. <https://www.gartner.com/doc/3760163/magic-quadrant-sales-force-automation>
- Gartner Inc. (2019). *Magic quadrant for sales force automation 2019*. <http://www.gartner.com/technology/reprints.do?id=1-1XJHQ4X&ct=140716&st=sb>
- Gittins, D. (1986). Icon-based human-computer interaction. *International Journal of Man-Machine Studies*, 24(6), 519–543. [https://doi.org/10.1016/S0020-7373\(86\)80007-4](https://doi.org/10.1016/S0020-7373(86)80007-4)

- Guillet, F., Ritschard, G., Zighed, D., Briand, H., Hamdi, F., Safar, B., ... Zargayouna, H. (2016). *Advances in Knowledge Discovery and Management* (Vol. 5). <https://doi.org/10.1007/978-3-642-00580-0>
- Hasson, F., Keeney, S., & McKenna, H. (2000). Research guidelines for the Delphi survey technique. *Journal of Advanced Nursing*, 32(4), 1008–1015. <https://doi.org/10.1046/j.1365-2648.2000.t01-1-01567.x>
- Kale, Y., Petrie, S. E., Bikdash, M., & Topal, M. D. (2018). Cold-Start User-Based Weighted Collaborative Filtering for an Implicit Recommender System for Research Facilities. In *2018 IEEE 4th International Conference on Collaboration and Internet Computing (CIC)* (p. 466–471). <https://doi.org/10.1109/CIC.2018.00070>
- Kitchenham, B., Pearl Brereton, O., Budgen, D., Turner, M., Bailey, J., & Linkman, S. (2009). Systematic literature reviews in software engineering – A systematic literature review. *Information and Software Technology*, 51, 7–15. <https://doi.org/10.1016/j.infsof.2008.09.009>
- Linstone, H. A., & Turoff, M. (2002). *The Delphi method: Techniques and Applications*. Addison-Wesley Educational Publishers Inc. <https://doi.org/10.1007/s00256-011-1145-z>
- Mariadoss, B. J., Milewicz, C., Lee, S., & Sahaym, A. (2014). Salesperson competitive intelligence and performance: The role of product knowledge and sales force automation usage. *Industrial Marketing Management*, 43(1), 136–145. <https://doi.org/10.1016/J.INDMARMAN.2013.08.005>
- Microsoft. (2020). Commerce, Microsoft Dynamics 365. <https://dynamics.microsoft.com/en-us/commerce/overview/>
- Nielsen, J. (1993). *Usability engineering*. Morgan Kaufmann.
- Piatetski, G., & Frawley, W. (1991). *Knowledge Discovery in Databases*. MIT Press.
- Portugal, I., Alencar, P., & Cowan, D. (2018). The use of machine learning algorithms in recommender systems: A systematic review. *Expert Systems with Applications*, 97, 205–227. <https://doi.org/10.1016/j.eswa.2017.12.020>
- Rocco, R. A., & Bush, A. J. (2016). Exploring buyer-seller dyadic perceptions of technology and relationships: Implications for Sales 2.0. *Journal of Research in Interactive Marketing*, 10(1), 17–32. <https://doi.org/10.1108/JRIM-04-2015-0027>
- Rolus Tech. (2020). Difference between CRM & Sales Force Automation. <https://www.rolustech.com/blog/crm-vs-sales-force-automation>
- Salesforce. (2020). Get to Know Commerce Cloud Einstein Unit, Salesforce Trailhead. <https://trailhead.salesforce.com/content/learn/modules/cc-einstein-plan-and-implement/cc-einstein-implementation-basics>
- Skulmoski, G. J., Hartman, F. T., & Krahn, J. (2007). The Delphi Method for Graduate Research The Delphi Method for Graduate Research. *Journal of Information Technology Education*, 6, 21. <http://www.jite.org/documents/Vol6/JITEv6p001-021Skulmoski212.pdf>

- Syam, N., & Sharma, A. (2018). Waiting for a sales renaissance in the fourth industrial revolution: Machine learning and artificial intelligence in sales research and practice. *Industrial Marketing Management*, 69, 135–146. <https://doi.org/10.1016/J.INDMARMAN.2017.12.019>
- Todeschini, R., & Baccini, A. (2016). *Handbook of Bibliometric Indicators: Quantitative Tools for Studying and Evaluating Research*. Wiley. <https://books.google.com.br/books?id=7BuACgAAQBAJ>
- Vinita, S., & Feisal, M. (2017). Product knowledge and salesperson performance: rethinking the role of optimism. *Marketing Intelligence & Planning*, 35(6), 724–739. <https://doi.org/10.1108/MIP-11-2016-0199>
- Yan, R. (2011). Icon design study in computer interface. *Procedia Engineering*, 15, 3134–3138. <https://doi.org/10.1016/j.proeng.2011.08.588>