



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO DE CIÊNCIAS, TECNOLOGIAS E SAÚDE DO CAMPUS ARARANGUÁ
CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO

Otávio Luis Martins

**Um Método voltado à Recomendação de Itens no Contexto de Marketing de
Afiliações**

Araranguá
2022

Otávio Luis Martins

Um Método voltado à Recomendação de Itens no Contexto de Marketing de Afiliados

Trabalho de Conclusão de Curso do Curso de Graduação em Engenharia de Computação do Centro de Ciências, Tecnologias e Saúde do Campus Araranguá da Universidade Federal de Santa Catarina para a obtenção do título de Bacharel em Engenharia de Computação.

Orientador: Prof. Alexandre Leopoldo Gonçalves, Dr.

Araranguá

2022

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Martins, Otávio Luis

Um Método voltado à Recomendação de Itens no Contexto de
Marketing de Afiliados / Otávio Luis Martins ; orientador,
Alexandre Leopoldo Gonçalves , 2022.

39 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Campus Araranguá,
Graduação em Engenharia de Computação, Araranguá, 2022.

Inclui referências.

1. Engenharia de Computação. 2. Marketing Digital. 3.
Marketing de Afiliado. 4. Sistemas de Recomendação. 5.
Autoencoder. I. , Alexandre Leopoldo Gonçalves. II.
Universidade Federal de Santa Catarina. Graduação em
Engenharia de Computação. III. Título.

Otávio Luis Martins

Um Método voltado à Recomendação de Itens no Contexto de Marketing de Afiliados

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do Título de Bacharel em Engenharia de Computação e aprovado em sua forma final pelo Curso de Graduação em Engenharia de Computação.

Araranguá, 15 de março de 2022.

Profa. Analucia Schiaffino Morales, Dra.
Coordenadora do Curso

Banca Examinadora:

Prof. Alexandre Leopoldo Gonçalves, Dr.
Orientador
Universidade Federal de Santa Catarina

Profa. Analucia Schiaffino Morales, Dra.
Avaliadora
Universidade Federal de Santa Catarina

Prof. Fábio Rodrigues de la Rocha, Dr.
Avaliador
Universidade Federal de Santa Catarina

Um Método voltado à Recomendação de Itens no Contexto de Marketing de Afiliados

A Method aimed at Recommending Items in the Context of Affiliate Marketing

Otávio Luis Martins*

Alexandre Leopoldo Gonçalves †

2022, Março

Resumo

O progresso tecnológico tem proporcionado às empresas diversas ferramentas de *marketing* digital com o intuito de evidenciar a marca e aumentar o faturamento. O *marketing* de afiliados é uma delas, sendo entendido como um serviço de parceria que proporciona para as empresas uma nova forma de divulgar seus produtos de maneira mais rápida e precisa. Entretanto, a maioria das plataformas de *marketing* de afiliados sofrem pelo grande volume de afiliados (usuários) cadastrados que não promovem retorno, ou seja, não vendem. Neste sentido, o presente trabalho possui como objetivo o desenvolvimento de um método de recomendação de produtos no cenário de *marketing* de afiliados visando promover uma maior interconexão entre afiliados e produtos, com impacto no aumento da taxa de conversão, isto é, nas vendas. No intuito de avaliar o método, foram coletadas as interações dos afiliados em uma plataforma real, promovendo suporte para o treinamento e teste do modelo de recomendação baseado em aprendizado profundo do tipo *autoencoder*. Para avaliar o método proposto são apresentados alguns cenários com o intuito de demonstrar a utilização do sistema de recomendação. Além disso, foram realizados testes para verificar a efetividade das recomendações. Os resultados alcançados para as recomendações de produtos tiveram uma acurácia de 87,37%. Desta forma, conclui-se que o método proposto tem potencial para sugerir produtos aos afiliados que estes tenham interesse para a divulgação, elevando o potencial de faturamento das empresas parceiras da plataforma e o número de afiliados vendedores.

Palavras-chaves: Marketing Digital, Marketing de Afiliado, Sistemas de Recomendação, Autoencoder.

*otavio.l.martins@grad.ufsc.br

†a.l.goncalves@ufsc.br

Um Método voltado à Recomendação de Itens no Contexto de Marketing de Afiliados

A Method aimed at Recommending Items in the Context of Affiliate Marketing

Otávio Luis Martins*

Alexandre Leopoldo Gonçalves †

2022, Março

Abstract

Technological progress has provided companies with several digital marketing tools in order to highlight the brand and increase revenue. Affiliate marketing is one of them, being understood as a partnership service that provides companies with a new way to promote their products more quickly and accurately. However, most affiliate marketing platforms suffer from the large volume of registered affiliates (users) who do not promote returns, that is, do not sell. In this sense, the present work aims to develop a product recommendation method in the affiliate marketing scenario, aiming to promote a better link between affiliates and products, with an impact on increasing the conversion rate, that is, sales. In order to evaluate the method, affiliate interactions were collected on a real platform, providing support for training and testing the recommendation model based on deep learning of the autoencoder type. To evaluate the proposed method, some scenarios are presented in order to demonstrate the use of the recommender system. In addition, tests were carried out to verify the effectiveness of the recommendations. The results achieved for product recommendations had an accuracy of 87.37%. In this way, it is concluded that the proposed method has the potential to suggest products to affiliates that they are interested in promoting, increasing the revenue potential of the platform's partner companies and the number of affiliate sellers.

Key-words: Digital Marketing, Affiliate Marketing, Recommender System, Autoencoder.

*otavio.l.martins@grad.ufsc.br

†a.l.goncalves@ufsc.br

1 Introdução

Diante da era digital, os anunciantes (empresas) estão cada vez mais utilizando ferramentas de *marketing* digital para anunciar seus produtos ou serviços no mercado, com o objetivo de atrair novos clientes e aumentar a visibilidade da marca por meio da mídia digital (GHOSAL, 2021). De acordo com Pandey, Bhatia e Varshney (2021), as principais ferramentas de *marketing* digital são, publicidade *online*, *e-mail marketing*, mídia social, mensagens de texto, otimização de mecanismos de pesquisa e em especial o *marketing* de afiliados.

Segundo Patrick e Hee (2021), o *marketing* de afiliados é um acordo de *marketing* pelo qual ao promover produtos ou serviços de empresas ou pessoas, pode-se obter uma recompensa (resultante de um clique ou de uma venda real, por exemplo). A utilização deste serviço traz alguns benefícios importantes como, uma maior visibilidade do negócio, um aumento nas vendas e um maior alcance no volume de clientes. Empresas de referências no mercado como Amazon[®], eBay[®], LinkShare[®] e Flipkart[®] já fazem o uso do *marketing* de afiliados.

Para Suryanarayana, Sarne e Kraus (2021), a procura do serviço de *marketing* de afiliados tem aumentado nos últimos anos, pois geram benefícios aos anunciantes (empresas) principalmente com o aumento da receita e, aos afiliados (usuários) que divulgam os produtos ou serviços, proporciona um aumento da renda, maior conforto e liberdade. Renda pois os afiliados recebem comissão (resultante de um clique ou de uma venda real), conforto por trabalharem de qualquer lugar (inclusive de casa) e liberdade por fazer seu próprio horário de serviço e divulgarem somente o que lhes interessam.

De acordo com Rahal (2020), o *marketing* de afiliados está em expansão no mercado. Estima-se que até este ano de 2022, a indústria de *marketing* de afiliados deverá alcançar a marca de U\$8 bilhões, quase o dobro que valia em 2015. Um dos motivos para alcançar tal resultado reside no fato que desde abril de 2020, mais de 30% dos consumidores *online* fizeram compras de produtos através de *links* de afiliados (REPORT, 2021). Outro efeito, é que as pessoas estão cada vez mais propensas a comprarem produtos de interesse em dispositivos digitais ao invés de irem até lojas físicas. Entretanto, estes números poderiam ser ainda maiores, se todos os afiliados cadastrados em uma plataforma participassem das vendas, pois de acordo com Rolim, Simões e Figueiredo (2020b) a maioria dos afiliados, algo em torno de 99,5% dos afiliados, nunca efetuou uma venda.

Diante disso, o presente trabalho procura lidar com baixa taxa de conversão observada no contexto de *marketing* de afiliados. Sendo assim, como uma possível solução para este problema, propõem-se um método que combina serviços de *marketing* de afiliados e sistema de recomendação. Segundo Khan *et al.* (2021), os sistemas de recomendação aprendem, por meio de algoritmos, as preferências dos usuários a fim de melhorar o processo de tomada de decisão dos usuários, a usabilidade dos sistemas de vendas, a redução da sobrecarga de dados e também proporcionar um aumento efetivo nas vendas e consequentemente da receita. No contexto do método proposto, o sistema de recomendação desenvolvido neste artigo foi baseado no modelo de aprendizado profundo *autoencoder* (AE), por ser um modelo escalável e capaz de lidar com muitos itens e usuários (MU, 2018).

O objetivo desta fusão é permitir que afiliados que já realizam vendas, tenham uma melhora em seu desempenho, e os afiliados que não vendem sejam impactados pelas recomendações das ofertas mais vendidas na plataforma, de modo a divulgarem e atingirem um consumidor. Ou seja, realizar recomendações com o intuito de aumentar a maior taxa

de conversão nas plataformas (lojas virtuais) voltadas ao *marketing* de afiliados. Além disso, uma vez que se alcancem tais propósitos, melhorias na experiência dos afiliados são esperadas, oferecendo uma experiência e uma plataforma mais personalizada.

Para além desta seção o trabalho é composto por outras cinco seções. A Seção 2 apresenta a fundamentação teórica detalhando os conceitos essenciais para elaboração do método proposto. Na Seção 3 são apresentados os trabalhos correlatos. Já na Seção 4, é apresentado o método proposto promovendo uma visão geral das três etapas que o constituem. Na Seção 5 são analisados e discutidos os resultados obtidos com a instanciação do método proposto. Por fim, a Seção 6 apresenta as considerações finais discutindo possíveis trabalhos futuros.

2 Fundamentação Teórica

Esta seção apresenta a fundamentação teórica detalhando cada um dos conceitos utilizados pelo método proposto neste trabalho, sendo eles o Marketing Digital, os Sistemas de Recomendação e a Inteligência Artificial.

2.1 Marketing Digital

De acordo com Cobra (2009), a palavra *marketing* deriva do latim “*mercare*”, termo que se referia ao ato de comercializar produtos na antiga Roma. Enquanto área surge nos EUA na década de 1940 em razão da necessidade de esforço adicional para incrementar as vendas, pois antes, tudo o que se produzia era vendido, portanto, o *marketing* era desnecessário. Desde o seu surgimento e, com o avanço no seu estudo, várias definições têm sido propostas. Para Gundlach (2007), o *marketing* é uma atividade de criatividade, comunicação, entrega e troca de ofertas que tenham valor para a sociedade. No trabalho de Kotler e Keller (2012), o *marketing* é definido sob as perspectivas social e gerencial. Do ponto de vista social, o *marketing* é um processo de desejo e necessidade devido as novidades de uma oferta e facilidade de troca de produtos. Já para perspectiva gerencial, *marketing* é frequentemente descrito como “a arte de vender produtos”. Porém, os autores ainda afirmam que muitos entendem o *marketing* somente como um processo de vender, e surpreendem-se ao ouvir o oposto.

Devido a isso, Drucker (1974), um dos principais teóricos da administração, esclarece e defende a afirmação de que o *marketing* não é simplesmente vender, e sim, conhecer e entender o cliente tão bem, que o produto ou serviço oferecido torne-se indispensável. Em outras palavras, que gere um sentimento de necessidade pelo produto ou serviço levando o cliente a aquisição. Dessa maneira, é entendido que a venda acaba sendo uma consequência do *marketing* e que a prioridade não é vender, e sim conhecer muito bem os seus clientes.

Cabe ressaltar que a definição precisa de *marketing* pode ser um pouco complexa, visto que cada autor possui um ângulo de observação diferente. Porém, os autores convergem em pensamento ao dizer que *marketing* é conhecer o público alvo, isto é, entender o que desejam e satisfazê-los por meio de um produto ou serviço.

Como já mencionado, o *marketing* surgiu há décadas atrás sendo bem diferente do que é conhecido atualmente. No passado, segundo Santos (2014), meios de comunicação tradicionais como TV, rádio, jornais, revistas, *outdoors*, placas, entre outros, eram utilizados para divulgar algum produto ou serviço. Todavia, no atual cenário, de acordo com Limeira (2012), por meio do advento da era da informação e com o crescimento exponencial da

tecnologia da informação originou-se o *marketing* digital. Esta abordagem mais recente se utiliza da *internet* como meio de comunicação. Por meio disso, o que antes era apenas conhecido como *marketing* tradicional, passou a ser reconhecido como uma nova categoria, ou seja, o *marketing* digital.

De acordo com Kotler, Kartajaya e Setiawan (2017), o *marketing* digital não se originou para substituir o *marketing* tradicional, mas para somar. Apesar de serem entendidas como duas categorias ou vertentes, nenhuma exclui a outra, uma vez que se complementam. Porém, existem diferenças entre elas, principalmente em seus meios de comunicação, em sua precificação e em suas audiências. De uma maneira mais específica, Faustino (2017) afirma que na utilização do *marketing* tradicional o anúncio acaba sendo em massa, não direcionado a um público-alvo, visto que o meio de comunicação principal são revistas ou a televisão, por exemplo. Por outro lado, o *marketing digital* é direcionado a um público-alvo. O mesmo autor enfatiza que através do *marketing* digital é possível obter transparência sobre a divulgação de um produto ou serviço, por meio do número de visualizações, pessoas alcançadas, ações, interações realizadas e conversões. Além disso, o valor de um anúncio é consideravelmente mais baixo do que o tradicional. Pode-se concluir que as categorias se complementam, visto que possuem funções específicas que se integram em uma estratégia de *marketing* global, podem apresentar resultados positivos para além de serem utilizadas separadamente.

De acordo com Oliveira Machado (2018), há várias estratégias de *marketing* digital, sendo elas: o *marketing* de busca, o *marketing* de conteúdo, a publicidade *online*, as parcerias *online*, o *e-mail marketing*, o *marketing* viral, a comunicação *offline* e, por fim, o *marketing* nas mídias sociais. Como foco deste trabalho, a parceria *online* é descrita pela geração de *links* que direcionam ao *website* de um varejista, visando melhorar a visibilidade de sua loja virtual. Sendo que nesta estratégia, ocorre um acordo entre o varejista e o parceiro. Assim, o funcionamento desta estratégia ocorre pela inclusão dos *links* de determinados produtos do varejista em *websites* de parceiros de negócios, como no *marketing* de afiliados.

2.1.1 Marketing de Afiliados

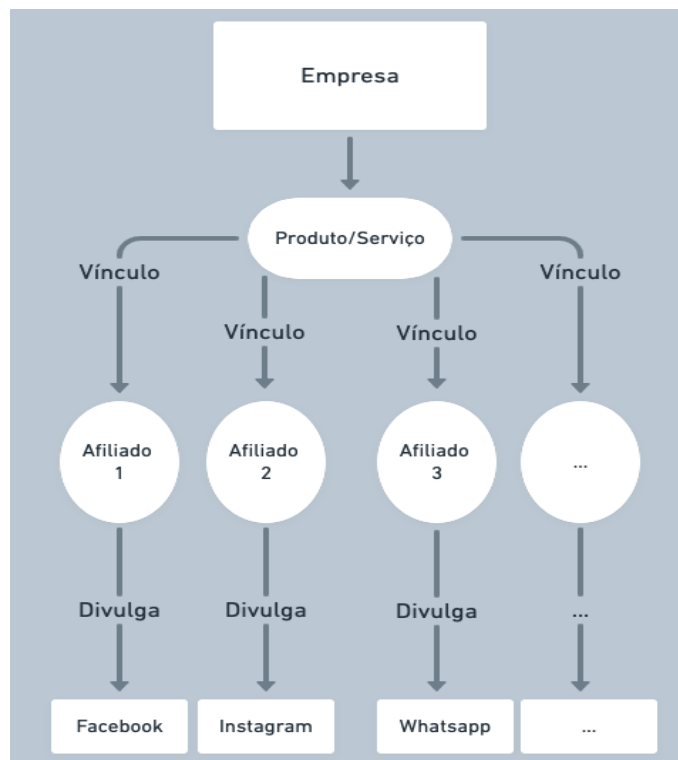
Para Iwashita e Tanimoto (2016), o *marketing* de afiliados é uma das técnicas mais comuns usadas para promover *sites*, produtos e serviços, em que os afiliados são recompensados por cada visitante ou cliente que veio por meio de seus esforços de *marketing*. Os afiliados são algumas vezes considerados como uma força de vendas estendida na promoção de determinado produto ou serviço. Além disso, como são recompensados pelo desempenho, o *marketing* de afiliados é frequentemente conhecido como *marketing* de “desempenho”.

De acordo com Rolim, Simões e Figueiredo (2020a), o *marketing* de afiliados é um programa público com o objetivo de proporcionar um novo canal de vendas para a empresa que o contrata, atraindo novos clientes, aumentando a visibilidade da marca e a receita a um custo de investimento relativamente baixo. Embora o *marketing* de afiliados seja uma tendência de rápido crescimento entre as empresas, é um dos serviços de parcerias *online* pouco explorado ainda no Brasil.

O *marketing* de afiliado é caracterizado por uma pessoa, denominada de afiliado(a), que realiza uma parceria com determinada empresa para divulgar seus produtos e serviços em locais independentes dos da empresa, como *sites*, *blogs*, redes sociais e outros canais *online*. Em troca, a empresa paga uma comissão ao afiliado por diferentes tipos

de ações, como vender um produto diante da divulgação ou atrair clientes para o *site* da empresa (ROLIM; SIMÕES; FIGUEIREDO, 2020b). Na Figura 1 consta uma ilustração do funcionamento deste processo.

Figura 1 – Processo do funcionamento do *marketing* de afiliado



Fonte: Elaborado pelo autor (2022).

Como visto na Figura 1, o *marketing* de afiliados típico tem dois importantes participantes:

- **Empresa (anunciante):** uma loja virtual baseada na *web* e que utilize o *marketing* de afiliado para criar uma rede de afiliados que promoverá suas ofertas.
- **Afiliado (associado):** um usuário com acesso à *internet* e que possua algum canal de divulgação (redes sociais, blogs, *sites*) para divulgar algum item/produto de um anunciante, recebendo uma comissão por cada transação efetivada, seja ela por visitas no *site* ou compras de produtos. Porém, isto é um acordo realizado entre as partes envolvidas.

Assim sendo, para ocorrer uma transação, existem técnicas de rastreamento. Estas técnicas são utilizadas para monitorar todo o processo do afiliado diante da divulgação de algum item/produto do anunciante em seus canais de divulgação. Isto garante que o anunciante saiba o que o afiliado divulgou e tenha o controle de quanto precisará atribuir de comissão. Para isto ocorrer, o afiliado insere em seus canais de divulgação *links* e *banners*, sendo que nestes *links* existem parâmetros de identificação para cada afiliado.

Segundo Rolim, Simões e Figueiredo (2020a), o *marketing* de afiliados é um serviço muito positivo, pois além de melhorar os negócios do varejista, acaba sendo um serviço de custo benefício acessível em relação a outras formas de divulgação de item/produtos na *web*. De modo geral, a maioria das plataformas de *marketing* de afiliados trabalha com o modelo de pagamento de custo por ação (do inglês *Cost per Action - CPA*). É um modelo em que o pagamento somente será realizado quando ocorrer uma ação. Neste contexto, a ação é a venda de um item/produto do anunciante. Em outras palavras, o anunciante só irá realizar um pagamento à plataforma se houver vendas de seus produtos.

2.2 Sistemas de Recomendação

Com o crescente volume de informações *online*, cada vez mais se torna difícil encontrar conteúdo relevante, envolvente, atrativo e útil para os usuários, devido à sobrecarga de informações. Com isso, no início dos anos 90 foram iniciados estudos sobre uma possível solução para este problema, através do conceito de Sistema de Recomendação (do inglês *Recommender System - RS*).

Segundo Ricci *et al.* (2011), RSs são ferramentas de *software* que fornecem sugestões de itens que possam ser úteis para os usuários. Por item, se entende como tudo aquilo que pode ser sugerido, por exemplo, um livro, um artigo científico, um automóvel. Schafer, Konstan e Riedl (2001) afirmam que os RSs são aplicações que podem filtrar informações de forma personalizada.

De forma geral, os SRs são utilizados para identificar usuários, armazenar suas preferências e recomendar itens que podem ser produtos, serviços e/ou conteúdos, de acordo com suas necessidades e interesses. Além disso, objetivam ainda a redução da sobrecarga de informação, extraindo itens relevantes para determinada recomendação a partir de grandes quantidades de dados.

De acordo com Goldberg *et al.* (1992), um dos primeiros artigos publicados no assunto foi desenvolvido no centro de pesquisa da Xerox®, em Palo Alto, em 1992. O estudo analisava os problemas decorrentes do uso crescente de comunicações eletrônicas, que sobrecarregavam os usuários com documentos desnecessários ou de pouco interesse. Por meio disso, foi desenvolvido um sistema, chamado *Tapestry*, onde os usuários podiam listar critérios de filtragem de conteúdos, como palavras-chave e outros usuários com os quais compartilhavam interesses.

A partir de 1996, a popularidade dos sistemas de recomendação começou a ganhar forma, impactando tanto em pesquisas acadêmicas como comercialmente e, devido a isso, várias empresas se especializaram em construir seus próprios sistemas (KONSTAN; RIEDL, 2012)

Atualmente, os RSs são indispensáveis para várias empresas reconhecidas mundialmente, como Amazon® e Netflix®. Segundo MacKenzie, Meyer e Noble (2013), 35% do que os consumidores compram na Amazon® são influenciados por recomendações e 75% do que os assinantes assistem na Netflix® vêm de recomendações. A Amazon®, em 2011, registrou um aumento de vendas de 29% durante seu segundo trimestre fiscal devido a inserção de um sistema de recomendação em seu *website*, em relação ao mesmo período do ano anterior de \$9,9 bilhões para \$12,83 bilhões (MANGALINDAN, 2012)

Agregar um sistema de recomendação tende a ser positivo para uma ampla gama de negócios, visto que tem potencial para elevar a margem de lucro e aumentar a taxa de

conversão¹. De modo geral, os RSs objetivam melhorar a experiência do usuário, de modo que este se identifique com determinada plataforma. Todavia, o desenvolvimento de um RS não é uma tarefa trivial. Sendo assim, nas próximas seções, serão demonstrados vários aspectos importantes que devem ser considerados durante o projeto de um RS.

2.2.1 Tipos de Recomendação

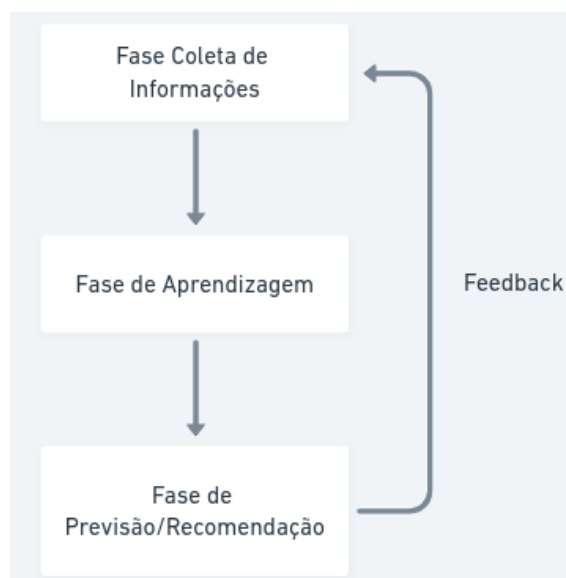
De acordo com Anusha e Biradar (2016), existem dois tipos de recomendação, a não personalizada e a personalizada. Na recomendação não personalizada todos os usuários recebem a mesma recomendação. A plataforma não sabe quem é o usuário, e com isso, não obtêm informações necessárias para recomendar itens/produtos personalizados. Por exemplo, ao acessar o *site* Amazon[®] como um usuário anônimo, serão exibidos os itens que estão sendo visualizados pelo membro que fez o acesso anterior.

Por outro lado, a recomendação personalizada não se baseia em uma suposição ou palpite. São baseadas diretamente no comportamento do usuário, como *clicks* em um botão, avaliação de um item, histórico de compras ou navegação. Sendo assim, a recomendação personalizada ocorre quando a plataforma sabe quem é o usuário, reconhecendo as preferências e recomendando itens de interesse.

2.2.2 Fases de um Sistema de Recomendação

Segundo Isinkaye, Folaajimi e Ojokoh (2015) e Kumar e Kumar (2019), para desenvolver qualquer RS, deve-se seguir três fases principais para o processo de recomendação, sendo a primeira a fase coleta de informações, a segunda a fase de aprendizado e, a terceira e última fase, a previsão/recomendação. A Figura 2 demonstra as fases de um RS.

Figura 2 – Fases de um sistema de recomendação



Fonte: Adaptado de Kumar e Kumar (2019).

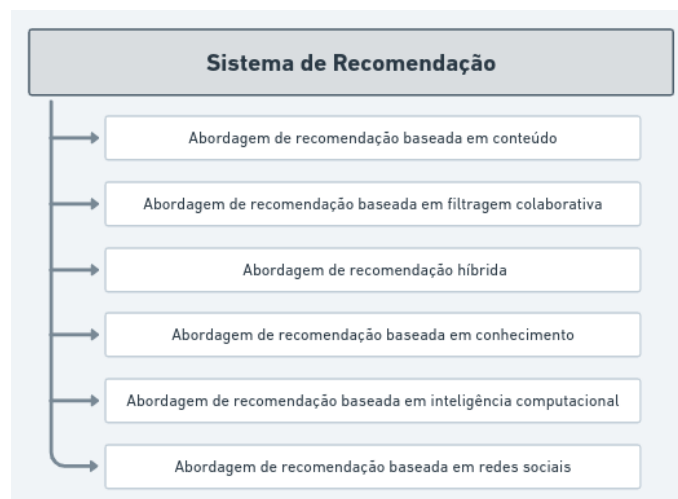
¹ A taxa de conversão consiste em uma métrica que avalia a audiência e a converte em resultados para o ofertante, isto é, a relação entre o total de pessoas que acessam a plataforma e se interessam pelo produto e efetivam a compra.

1. **Fase coleta de informações:** fase responsável por coletar todas as informações relevantes do usuário por meio de *feedbacks* implícitos, explícitos e híbridos. Além disso, é importante conseguir o máximo possível de informações do usuário para que o sistema esteja calibrado e consiga fornecer recomendações assertivas.
 - *Feedback* implícito: O sistema coleta as preferências do usuário através de monitoramento, por exemplo, analisando o histórico do usuário, compras, botões clicados, tempo gasto visualizando determinado item/produto, dentre outros. O método, entretanto, não requer esforço do usuário, mas é menos preciso.
 - *Feedback* explícito: Este sistema pede aos usuários que forneçam classificações ou avaliações sobre determinados itens/produtos, por exemplo. O método exige mais esforço dos usuários, em contrapartida, os dados coletados possuem em geral maior precisão.
 - *Feedback* híbrido: Os pontos fortes do *feedback* implícito e explícito podem ser combinados em um sistema híbrido para minimizar seus pontos fracos e obter um sistema de melhor desempenho.
2. **Fase de aprendizagem:** aplicação de um algoritmo de aprendizagem para conhecer as preferências do usuário com base nas interações coletadas na plataforma (*feedbacks*).
3. **Fase de previsão/recomendação:** nesta fase é recomendado ou previsto itens que o usuário possa se interessar considerando padrões fornecidos pela fase de aprendizado.

2.2.3 Abordagens de Sistema de Recomendação

De acordo com Anusha e Biradar (2016), existem diferentes abordagens para se projetar um sistema de recomendação. Algumas delas são demonstradas na Figura 3,

Figura 3 – Abordagens de sistema de recomendação



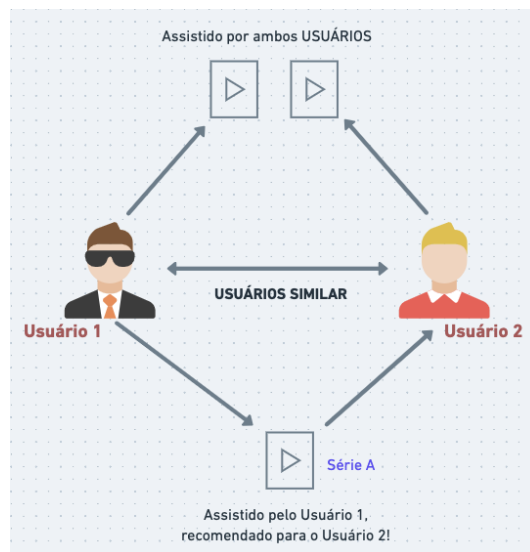
Fonte: Adaptado de Anusha e Biradar (2016).

sendo as principais a recomendação baseada em filtragem colaborativa, a recomendação baseada em conteúdo e a recomendação híbrida.

2.2.3.1 Recomendação Baseada em Filtragem Colaborativa

A abordagem baseada em filtragem colaborativa (do inglês *Collaborative Filtering* – CF) faz recomendações a um usuário de acordo com o comportamento de outros usuários com perfis semelhantes. Por exemplo, pensando em um ambiente de uma plataforma de *streaming*, onde há dois usuários, o primeiro identificado como Usuário 1 e o segundo como Usuário 2, ambos possuem interesses semelhantes por séries, o Usuário 1 assistiu recentemente a "Série A", porém o Usuário 2 ainda não assistiu. Logo o sistema poderia recomendar ao Usuário 2 a série "Série A", pois existe a possibilidade do Usuário 2 se interessar (Figura 4).

Figura 4 – Demonstração da recomendação baseada em filtragem colaborativa



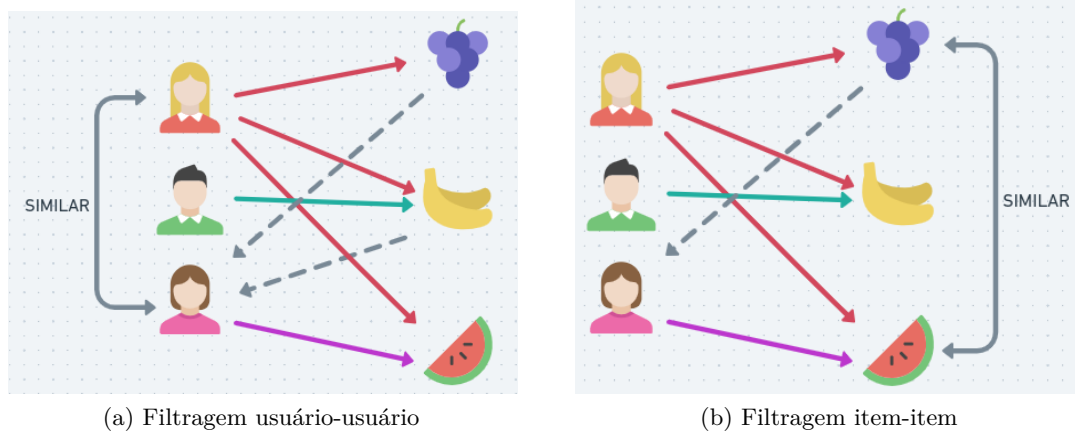
Fonte: Adaptado de Doshi (2019).

Além disso, essa abordagem é composta por dois tipos, sendo a filtragem colaborativa usuário-usuário e a filtragem colaborativa item-item.

- **Filtragem colaborativa usuário-usuário** é levado em conta a similaridade dos usuários, por exemplo, se um usuário possui um perfil de consumo similar a outro, tudo o que determinado usuário consumiu e o outro similar ainda não, o sistema poderá recomendar (Figura 5a).
- **Filtragem colaborativa item-item** é levado em conta a similaridade dos itens, por exemplo, se um determinado usuário gostou de uma fruta e essa fruta é similar a outra que ele ainda não consumiu, então o sistema poderia recomendar (Figura 5b).

Segundo Radisic e Lazarevic (2019), para encontrar a similaridade de um item ou usuário, um RS deve aplicar alguma métrica de similaridade, de modo que se possa avaliar o quão semelhante duas variáveis são entre si. Existem várias métricas que podem ser consideradas, como a distância euclidiana, o coeficiente de correlação de *Pearson*, o coeficiente de correlação de *Spearman*, a similaridade do cosseno, o coeficiente de correlação *tau* de *Kendall*, o índice de *Jaccard*, entre outros.

Figura 5 – Tipos de filtragem colaborativa

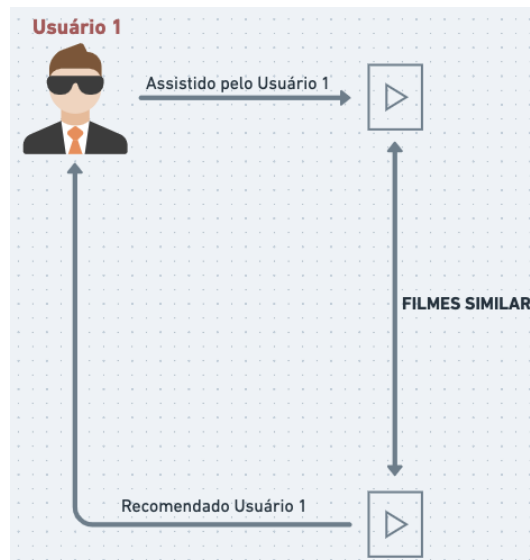


Fonte: Elaborado pelo autor (2022).

2.2.3.2 Recomendação Baseada em Conteúdo

De acordo com Anusha e Biradar (2016), a abordagem baseada em conteúdo (do inglês *Content-based Filtering - CBF*) faz recomendações a um usuário de acordo com os interesses demonstrados por este nos itens previamente selecionados. Utiliza metadados do objeto para encontrar a similaridade, por exemplo, em um filme poderiam ser utilizados alguns atributos como, título, autores, descrição e gênero. A ideia geral é que se o usuário teve interesse por algum item, possivelmente irá se interessar por um item similar que ainda não conhece. Na Figura 6 é possível visualizar o funcionamento desta abordagem.

Figura 6 – Demonstração da recomendação baseada em conteúdo



Fonte: Adaptado de Arora (2020).

Para realizar o cálculo da similaridade desta abordagem aplicam-se as mesmas métricas citadas na recomendação baseada em filtragem colaborativa.

2.2.3.3 Recomendação Híbrida

É uma abordagem que une duas ou mais abordagens de recomendação com o objetivo de aumentar o desempenho e diminuir as desvantagens que cada uma possui individualmente. Segundo Anusha e Biradar (2016), a prática mais comum na abordagem híbrida é combinar a recomendação baseada em filtragem colaborativa com a recomendação baseada em conteúdo.

2.3 Inteligência Artificial

A Inteligência Artificial (do inglês *Artificial Intelligence* - AI) é uma área da ciência abrangente que vem cada vez provendo soluções para uma extensa variedade de problemas. Considerando a literatura da área percebem-se diferentes definições, sendo a definição de Demis Hasibis, cofundador e CEO do Google DeepMind[®], frequentemente referenciada apontando a AI como “a ciência de construir máquinas inteligentes” (ARSENIJEVIC; JOVIC, 2019). De acordo com Stuart e Peter (2009), a AI é definida como a arte de criar máquinas que executam funções que exigem inteligência quando realizadas por pessoas (Kurzweil, 1990).

Hoje em dia, devido aos avanços dos estudos em AI, diversas aplicações fazem uso desta área, como carros semi-autônomos, aspiradores robóticos, *chatbots*, sistemas de recomendação, detector de doenças, entre outros (LI *et al.*, 2018).

As aplicações supracitadas fazem parte de uma subárea da AI chamada Aprendizado de Máquina (do inglês *Machine Learning* - ML) oferecendo muitas soluções para problemas do dia a dia. O ML provê métodos e técnicas para que computadores tenham a capacidade de aprender de acordo com as respostas esperadas por meio de associações de diferentes dados, sejam estes estruturados (na forma de tabelas) ou não estruturados por meio de texto, imagem, áudio e vídeo (HOLZINGER, 2019).

De acordo com Rodrigues, Krois e Schwendicke (2021), existem diferentes formas de realizar a aprendizagem de máquina, sendo os mais comuns, o aprendizado supervisionado e o não supervisionado. O aprendizado supervisionado requer uma lista de variáveis independentes por meio de dados já rotulados. Por exemplo, ao realizar uma classificação de um cachorro, torna-se necessário indicar ao algoritmo instâncias de um cachorro, para que o algoritmo consiga prever de forma correta o que é um cachorro ou não, a partir da inserção das variáveis independentes (não conhecidas pelo algoritmo).

Por outro lado, para o aprendizado não supervisionado são providos dados para o algoritmo sem os rótulos. Por meio disso, o algoritmo possui o objetivo de encontrar padrões nos dados de entrada para conseguir realizar determinada tarefa, geralmente descrita como agrupamento, mas também pode ser adaptada para realizar recomendações. Um exemplo seria um sistema de recomendação de um *site* de comércio eletrônico. Quando um novo usuário acessa determinado *site*, o modelo previamente treinado não possui informações relevantes deste usuário. Todavia, a partir de algumas informações iniciais obtidas por meio da interação do usuário com o *site*, pode-se posicionar determinado usuário em determinado grupo de usuários e, a partir disso, realizar recomendações.

Outra subárea de Inteligência Artificial que vem sendo extensivamente pesquisada e aplicada em diferentes cenários é o Aprendizado Profundo (do inglês *Deep Learning* - DL). O objetivo do DL é imitar o mecanismo do cérebro humano para interpretar dados como imagens, sons e textos. Assim como no ML, o aprendizado profundo também se

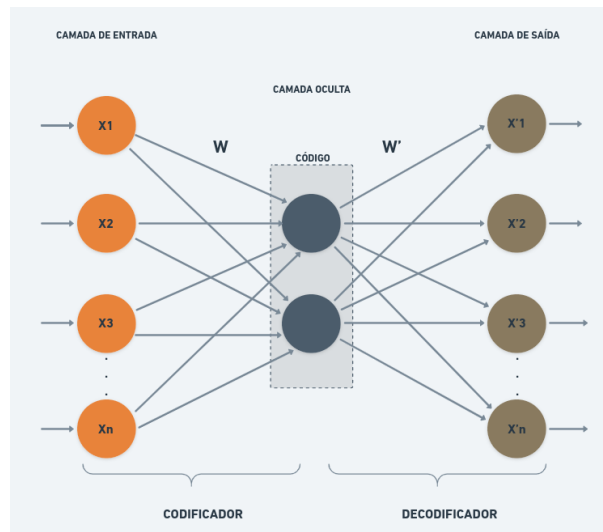
utiliza dos aprendizados supervisionado e não supervisionado. De maneira geral, o DL consegue abstrair e combinar recursos de baixo nível para formar categorias de atributos de representação de alto nível mais abstratas ou recursos para descobrir representações de dados distribuídos (MU, 2018).

Existem diversas arquiteturas de aprendizado de DL comumente usadas, como *autoencoder* (AE), máquina restrita de Boltzmann (do inglês *Boltzmann Machine* - RBM), rede neural recorrente (do inglês *Recurrent Neural Network* - RNN), rede neural convolucional (do inglês *Convolutional Neural Network* - CNN), entre outras. Neste trabalho o foco reside na arquitetura *autoencoder*.

2.3.1 Autoencoder

Autoencoder é caracterizado como um método de aprendizado profundo não supervisionado que aprende a compactar e codificar dados com eficiência e, em seguida, reconstruir os dados a partir de uma representação codificada reduzida, para uma representação idêntica à entrada original. Em outras palavras, é uma rede neural *feed-forward* não supervisionada treinada para transformar a entrada em uma representação que pode ser reconstruída novamente (MU, 2018). De modo geral, possui três camadas, conforme demonstrado na Figura 7.

Figura 7 – Estrutura típica de um *autoencoder*



Fonte: Adaptado de Mu (2018).

Segundo Tahmasebi, Ravanmehr e Mohamadrezai (2021), *autoencoder* é semelhante a uma rede *perceptron* multicamada (do inglês *Multilayer Perceptron* - MLP) tradicional. A diferença básica, é que o *autoencoder* reconstrói a entrada. Já na MLP o objetivo é prever valores alvo com entradas específicas. Como visto na Figura 7, as camadas que constituem um *autoencoder* básico são: camada de entrada, camada oculta e camada de saída. Sendo que as camadas de entrada e saída devem possuir o mesmo número de neurônios e, o número de neurônios na camada intermediária deve ser menor do que o da camada de entrada e saída.

A partir disso, a estrutura de um *autoencoder* obtém também um codificador e

um decodificador. A camada de entrada e a camada oculta constroem um codificador e, a camada oculta e a camada de saída constroem um decodificador. Entre esses dois, existe o que é chamado de código. A seguir são apresentados os elementos da estrutura:

- **O codificador** tem a função de compactar as informações de entrada em um espaço latente².
- **O código** é uma parte da rede que representa a entrada compactada que é enviada ao decodificador.
- **O decodificador** faz o trabalho inverso e reconstrói a informação original, movendo-se do espaço latente para o espaço próximo do original.

O codificador codifica os dados de entrada representado por $x = (x_1, x_2, x_3, x_4, \dots, x_n)$ em uma representação oculta de baixa dimensão $h = (h_1, h_2, \dots, h_m)$ por uma função f :

$$h = f(x) = S_f \cdot (W_x + b) \quad (1)$$

onde S_f é uma função de ativação não linear, por exemplo, a função tangente hiperbólica ou a função sigmóide, n é o número de neurônios na camada de entrada e m é o número de neurônios na camada oculta. O codificador é parametrizado por uma $m \times n$ matriz de peso W e um vetor de polarização $b \in R_m$.

Então, o decodificador mapeia a representação oculta h de volta para uma reconstrução $x' = (x'_1, x'_2, x'_3, x'_4, \dots, x'_n)$ por uma função g :

$$x' = g(h) = S_g \cdot (W'_h + b') \quad (2)$$

onde S_g representa a função de ativação não linear do decodificador. Os parâmetros do decodificador são compostos por um vetor de polarização $b' \in R_n$ e uma matriz $n \times m$ de peso W' .

De acordo com Zhang, Liu e Jin (2020), o objetivo do *autoencoder* é obter uma representação dimensional de dados, de tal forma que uma medida do erro de reconstrução entre a entrada original e a saída reconstruída seja minimizado. Existem duas maneiras de formular o erro de reconstrução, erro quadrático médio (Equação 3) e entropia cruzada (Equação 4).

$$E_{AE}(x, x') = \frac{1}{n} \sum_{i=1}^n (x_i - x'_i)^2 \quad (3)$$

$$E_{AE}(x, x') = - \sum_{i=1}^n (x_i \log x'_i + (1 - x_i) \log(1 - x'_i)) \quad (4)$$

Este modelo de aprendizado profundo é aplicado em diversas áreas, por exemplo, processamento de imagens, reconhecimento de fala, recuperação de informações, sistemas de recomendação, entre outros. Por fim, o *autoencoder* é considerado o modelo de aprendizado profundo mais adequado para analisar entradas ausentes em dados esparsos, sendo muito útil para sistemas de recomendação (BATHLA; AGGARWAL; RANI, 2020).

² Um espaço latente pode ser entendido como uma representação das características mais relevantes do conjunto de dados utilizado.

3 Trabalhos Correlatos

Os trabalhos apresentados nesta seção foram selecionados após uma revisão bibliográfica nas bases de dados IEEE Xplore[®], Science Direct[®], Scopus[®] e SpringerLink[®] e representam trabalhos relacionados com foco em sistema de recomendação de produtos, com as seguintes palavras-chave: “recommender system”, “marketing”, “digital marketing”, “affiliates marketing”. Os trabalhos selecionados abrangem técnicas de ML, como os classificadores KNN, SVM, RF e sistemas de inferência *fuzzy*, além de filtragem colaborativa.

- Os autores Valois e Oliveira (2011) apresentam uma solução que avalia o sistema de recomendação em redes sociais com a redução da dimensionalidade da matriz usuário-item, utilizando técnicas de filtragem colaborativa baseadas em usuários e itens. O objetivo é verificar a influência desta estratégia quanto à esparsidade dos dados e também no desempenho da recomendação de itens para os usuários. Além disso, levou-se em consideração o conceito de que as pessoas mais conectadas têm mais influência nas opiniões entre elas. Dessa forma, é definido o critério de similaridade e traçado um gráfico de relações de interação entre os usuários da rede social.
- Segundo Xiao e Ezeife (2018), no comércio eletrônico, os dados das matrizes de classificação de itens para colaboração de sistemas de recomendação por filtragem são geralmente binários e esparsos. Isto não integra informações importantes de compras históricas e as consequentes informações de vínculo entre cliques e compras. Logo, os autores propõem um sistema de recomendação de compra histórica com *clickstream* (HPCRec), que normaliza a matriz histórica de frequência de compra para melhorar a qualidade da classificação. Resultados experimentais mostram que o HPCRec supera métodos tradicionais existentes.
- Liang e Wang (2019) apresentam um modelo integrado de suporte à decisão que pode ajudar clientes na identificação de produtos em ambientes *online* em que estes tenham interesse. O modelo proposto engloba três módulos, sendo, aquisição de informações, transformação de informações e modelo de integração. A coleta de informações é realizada via análise de sentimentos, levando em consideração uma máquina de suporte de decisões, enquanto a transformação de informações é realizada para converter dados *fuzzy* em nuvens normais intuicionistas linguísticas (do inglês *Linguistic Intuitionistic Normal Clouds* - LINCs). Um estudo de caso é realizado para ilustrar a eficácia e viabilidade da proposta, juntamente com análises de sensibilidade e comparação.
- No trabalho de Yu *et al.* (2018), os autores descrevem um sistema de recomendação para plataformas de pedidos de restaurante com base em algoritmos de filtragem colaborativa aprimorados. O sistema foi modelado sob a perspectiva de dois módulos: i) módulo de geração de regras para inferir a semelhança entre pratos; e ii) módulo de recomendação para representar o vetor de interesse dos usuários. Foram então utilizados dois algoritmos, FP-Growth e um baseado em CF para o treinamento do sistema. O algoritmo baseado em CF se sobressaiu quanto à sua alta taxa de cobertura atendendo aos requisitos de recomendações de pratos em aplicações reais quando comparado ao FP-Growth. Quanto à recomendação, foram adotadas duas métricas de similaridade, sendo elas a função cosseno e a função de aprendizado incremental/contínuo.

- A solução proposta por Mathew, Smith e Passarelli (2018) é um sistema de recomendação baseado em uma nova abordagem de recomendação sobre os metadados e experiência no domínio de vídeos utilizando técnicas de aprendizado de máquina (*Support Vector Machine* - SVM, Regressão Logística e *Random Forest* - RF). Além disso, é utilizado o serviço GovCloud para hospedar a aplicação, o sistema de recomendação e o banco de dados.
- Madani *et al.* (2019) propõem uma nova abordagem de recomendação de cursos para alunos. O método proposto é baseado em filtragem social e filtragem colaborativa visando recomendar cursos que melhor atendam ao perfil e conteúdo social do aluno. A coleta de informações é baseada em conteúdo dos alunos, como *tweets*, postagens no *Facebook*[®], curtidas e comentários. O estudo aborda o método de ML, K-vizinhos mais próximo (do inglês *k-nearest neighbors* - KNN) do aluno-alvo. Por fim, o autor sugere como próxima etapa a aplicação dessa abordagem em diferentes domínios, como em um *site* de comércio eletrônico ou na recomendação de filmes.
- O trabalho apresentado por Lee e Huang (2011) tem como objetivo propor o uso de sistemas de recomendação para auxiliar o processo de compra verde³(por exemplo, sabonetes puro-vegetal) e promover o consumo consciente, uma vez que aumenta o número de pessoas e governos preocupados com questões ambientais. No estudo é desenvolvida uma arquitetura de um sistema de recomendação para o consumo de eletroeletrônicos sustentáveis e o processo de tomada de decisão dos clientes é modelado com um sistema de inferência *fuzzy* adaptativo. As variáveis de entrada sugeridas são o preço e as características sustentáveis dos produtos, sendo as variáveis de saída os dados de classificação estimados. Foram modelados três tipos de recomendação, a filtragem de informações, a expansão de candidatos e a recomendação de multidão. A arquitetura proposta fornece uma plataforma de *marketing* sustentável personalizada, oferecendo aos clientes conselhos de compras adaptados às suas preferências, mesmo com a disponibilidade de poucas informações sobre determinado cliente.
- De acordo com os autores Jiang *et al.* (2019), algoritmos de previsão *Slope One* não possuem alta precisão, apesar de fácil implementação. Para resolver este problema, foi proposto no estudo uma abordagem aprimorada do algoritmo *Slope One*, baseado na fusão de dados confiáveis e similaridade de usuário, que pode ser implantado em vários sistemas de recomendação. O algoritmo sugerido compreende três procedimentos, a seleção de dados confiáveis; o cálculo de similaridade entre os usuários; e a adição de semelhança ao fator de peso do algoritmo de *Slope One* aprimorado. Segundo experimentos, foram realizados vários testes com o conjunto de dados da Amazon[®] e os resultados evidenciados mostraram que o algoritmo de recomendação *Slope One* aprimorado funciona com mais precisão do que o algoritmo tradicional.

Analisando o estado da arte em relação aos sistemas de recomendação, existem vários trabalhos que apresentaram análises de testes simulados, coletas de informações e recomendações com diferentes abordagens. A partir das pesquisas realizadas, constata-se que o estudo desenvolvido neste artigo é o primeiro que fornece uma avaliação experimental para *marketing* de afiliados utilizando o método de DL *autoencoder* para recomendação de produtos similares por filtragem colaborativa. Nenhum dos trabalhos analisados utilizou a coleta de comportamento dos usuários em relação aos afiliados de uma plataforma real.

³ Os produtos verdes são produtos que reduzem impactos e se preocupam com o processo de produção mais eficiente, diminuindo desperdícios de água e fontes de energia.

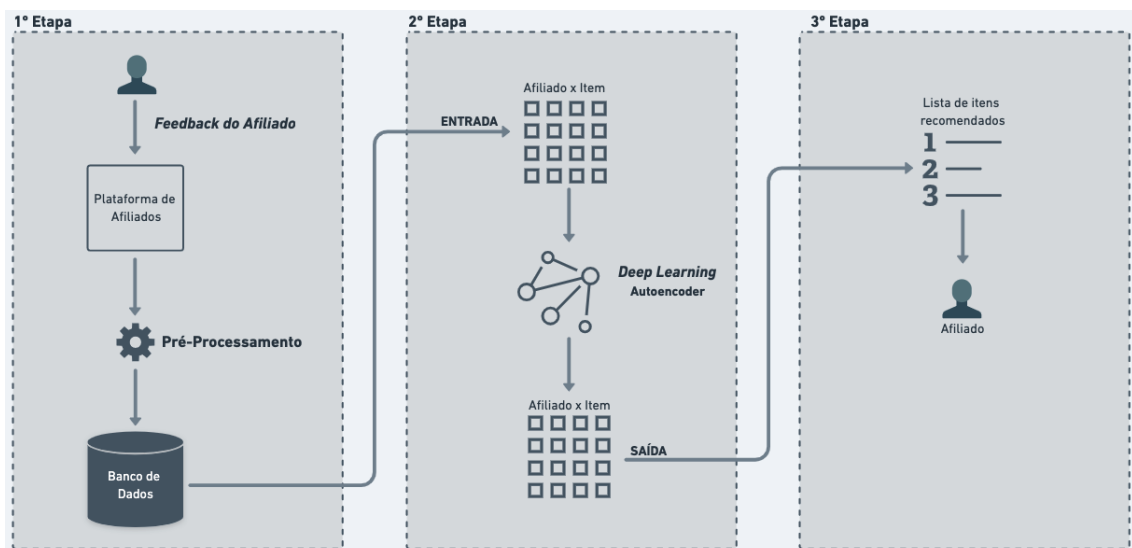
Portanto, este trabalho tem potencial para contribuir com o estado da arte ao preencher essa lacuna.

4 Método Proposto

Este trabalho insere-se no contexto de uma plataforma de afiliados que possui desafios quanto à sobrecarga de itens cadastrados e também quanto a baixa taxa de conversão de usuários participantes. Neste sentido, o objetivo deste trabalho é apresentar um método voltado à recomendação de itens para usuários em uma plataforma de *marketing* de afiliados. Diante disso, o método está centrado na abordagem de recomendação baseada em filtragem colaborativa e no modelo de aprendizado profundo *autoencoder*. No contexto deste trabalho, usuários se referem aos afiliados e itens se referem aos produtos, promoções ou ofertas.

Este método está separado em três etapas, sendo coleta de informações e pré-processamento, aprendizagem e geração do modelo de recomendação, e previsão/recomendação de itens. A Figura 8 demonstra uma breve visão geral do método proposto.

Figura 8 – Etapas do método proposto



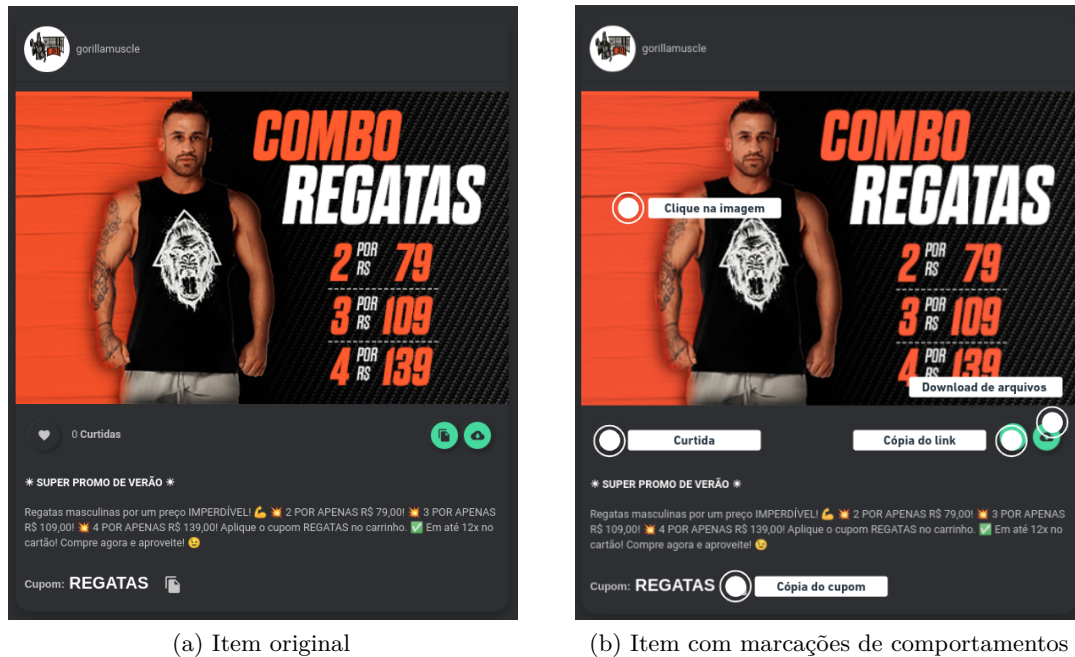
Fonte: Elaborado pelo autor (2022).

4.1 Etapa 1: Coleta de Informações e Pré-processamento

Na primeira etapa é efetuada a coleta de dados com base no comportamento do afiliado logado em uma plataforma de afiliados, por meio de *feedbacks* implícitos e explícitos. Deste modo, foi necessário desenvolver uma estratégia na plataforma para capturar as diferentes interações dos afiliados conectados à plataforma.

Primeiramente, foi realizada a identificação das principais características de comportamento que o afiliado pode obter na página principal da plataforma considerando os itens cadastrados. A Figura 9 apresenta as características identificadas na página dos itens cadastrados.

Figura 9 – Características de comportamento identificadas nos itens



Fonte: Elaborado pelo autor (2022).

sendo escolhidas cinco características em que o afiliado pode interagir com os itens cadastrados na plataforma, sendo elas:

- **Clique na imagem:** redireciona o item selecionado para o site da loja, neste caso, o combo de regatas da loja Gorilla Muscle®.
- **Download de arquivos:** utilizado para obter uma coleção de imagens do item para compartilhar nos canais de divulgação do afiliado, por exemplo, redes sociais.
- **Cópia do link:** utilizado o *link* para compartilhar em canais de divulgação junto com as imagens já obtidas. O *link* contém parâmetros que rastreiam o afiliado que divulga determinado item.
- **Cópia do cupom:** utilizado também na divulgação dos itens, porém, é inserido como forma de chamar a atenção dos consumidores, pois o cupom proporciona algum desconto, seja no frete ou no valor final da compra.
- **Curtida:** interação do afiliado que demonstra se o item cadastrado chama ou não a sua atenção.

A partir disso, cada característica de comportamento identificada obtém um peso, visando avaliar a preferência de cada afiliado sobre determinado item. Em outras palavras, a interação do afiliado com alguma característica do item cadastrado está associada diretamente a um peso que determinará a sua preferência, sendo que, quanto maior o peso, maior é a preferência do afiliado sobre o item. Pode-se visualizar cada característica associada a um peso no Quadro 1, sendo que estes valores foram definidos com base em um estudo sobre as preferências dos afiliados sobre os itens que constam na plataforma.

Quadro 1 – Relação de características de comportamento

Característica	Pesos	Feedback
Curtida	5	Explícito
Download de arquivos	3	Explícito
Cópia do link	2	Explícito
Cópia do cupom	2	Explícito
Clique na imagem	1	Implícito
Descurtir	0	Explícito

Fonte: Elaborado pelo autor (2022).

Após apresentada a estratégia em como capturar a preferência do afiliado sobre os itens cadastrados na plataforma, segue-se para a fase *feedback* do afiliado, conforme Figura 10. Nesta fase, a plataforma é responsável por analisar o comportamento do afiliado com os itens cadastrados e, no momento em que houver a interação com alguma característica, demonstrado no Quadro 1 e na Figura 9, ocorrerá a coleta dos dados necessários. Os dados consistem na identificação única do afiliado conectado, bem como o peso da característica de comportamento associado ao item selecionado na interface, servindo de entrada na fase de pré-processamento.

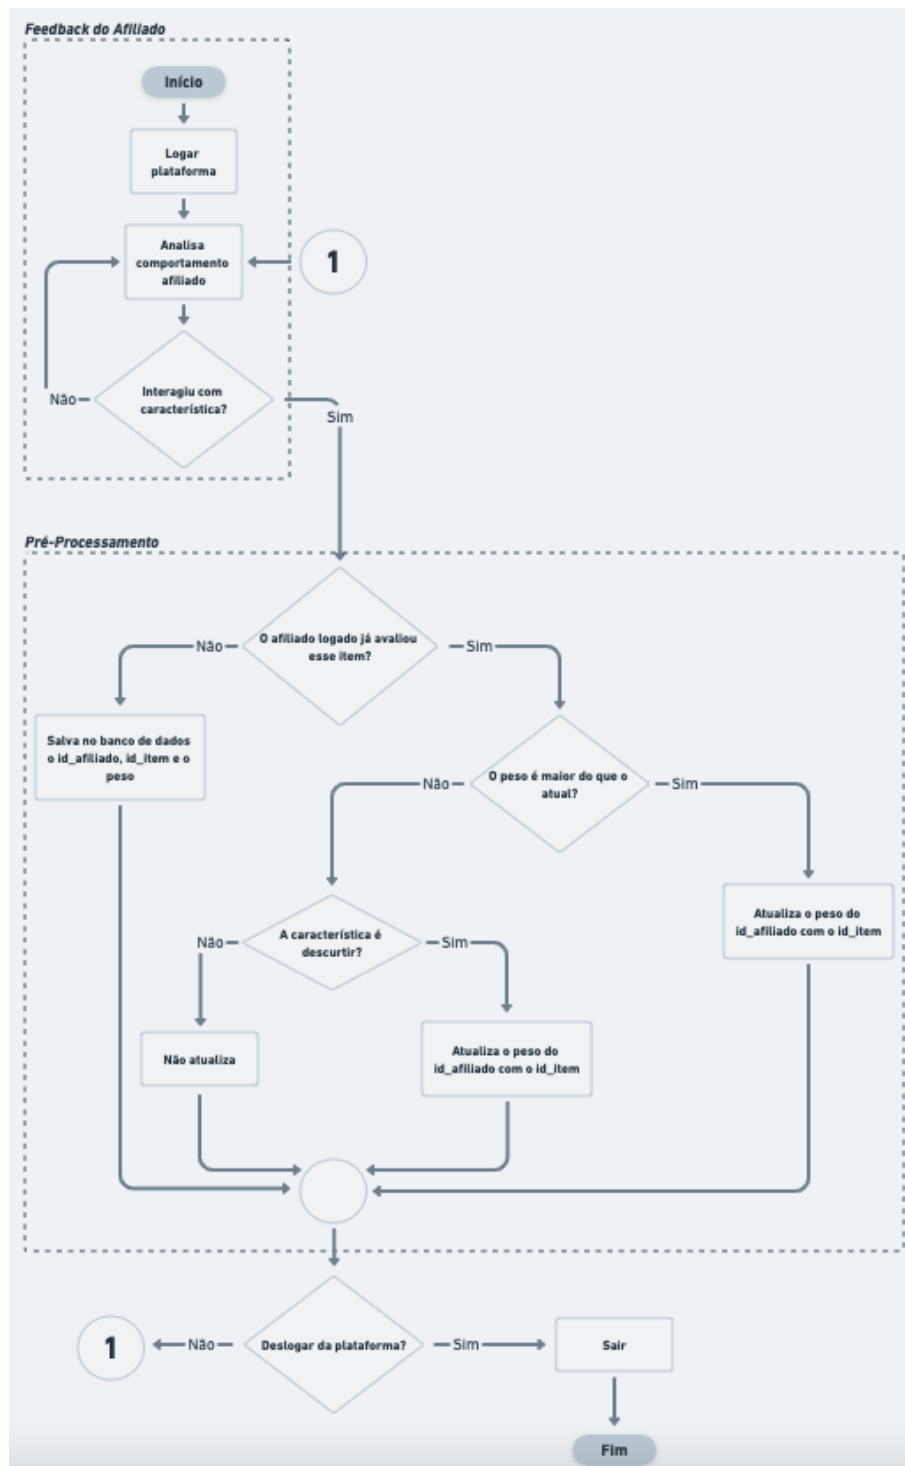
Deste modo, na fase de pré-processamento, os dados de entrada representam as coletas de dados da fase *feedback* do afiliado. Nesta fase, se faz necessário o processamento dos dados recebidos antes de serem inseridos no banco de dados da plataforma de afiliados. Sendo assim, foi desenvolvido um fluxograma (Figura 10) para ilustrar o funcionamento descrito pela estratégia de pré-processamento.

Na Figura 10 é possível observar que a fase *feedback* do afiliado representa todo o processo de análise de comportamento dos afiliados na plataforma. Já a fase de pré-processamento caracteriza, basicamente, o processo de inferência condicional do sistema de recomendação, antes de salvar os dados no banco de dados da plataforma de afiliados. Após passar pelas fases *feedback* do afiliado e pré-processamento, os dados são inseridos no banco de dados da plataforma como segue na Figura 11.

Como já mencionado, os dados obtidos a partir de *feedbacks* dos afiliados (identificação única do afiliado logado, o peso da característica de comportamento associado ao item de interação e a identificação única do item), passam pela fase de pré-processamento e, caso sigam as condições do fluxograma, são armazenados no banco de dados conforme mostrado na Figura 11. A estrutura da coleção de dados consiste de seis campos (descritos abaixo), sendo estes os campos responsáveis por referenciar no banco de dados da plataforma as preferências dos afiliados sobre os itens.

- **_id**: Identificação única para o elemento de dados inserido.
- **user_id**: Identificação única do afiliado na plataforma.
- **action_id**: Identificação única do item na plataforma.
- **rating**: Peso da característica de comportamento.
- **created_at**: Data de inserção da coleta de dados no banco de dados.
- **updated_at**: Data de atualização da coleta de dados no banco de dados.

Figura 10 – Fluxograma do pré-processamento



Fonte: Elaborado pelo autor (2022).

Figura 11 – Informações salvas no banco de dados

 <code>_id</code>	ObjectId("61a84aca9a0c0542ef901baa")
 <code>user_id</code>	ObjectId("5f721967365a654fb624ee78")
 <code>action_id</code>	ObjectId("619f76e51c032c4ecf38661a")
 <code>rating</code>	2
 <code>created_at</code>	2021-12-02 04:25:46.171Z
 <code>updated_at</code>	2021-12-02 04:25:58.374Z

Fonte: Elaborado pelo autor (2022).

Por fim, esta etapa de coleta de informações trabalha recursivamente para obter qualquer característica de comportamento dos afiliados logados. E, posteriormente, salva no banco de dados caso tenha um evento de interação sobre um determinado item na plataforma.

4.2 Etapa 2: Aprendizagem/Treinamento da rede

Nesta etapa, é aplicado um modelo de aprendizagem para filtrar e explorar recursos do afiliado a partir do *feedback* coletado na 1ª Etapa. Neste trabalho, utilizou-se o modelo de aprendizado profundo *autoencoder*, já citado na Seção 2. O modelo de aprendizado profundo implementado necessita de uma estrutura de dados específica para sua entrada. Esta estrutura de dados é uma matriz $N \times M$ onde N é o número de afiliados e M o número de itens. Cada linha $i \in N$ é um id do afiliado único e cada coluna $j \in M$ é um id de item único. Sendo que, para construir esta estrutura de dados, são utilizadas as informações coletadas e armazenadas no banco de dados da plataforma. Uma visualização da matriz pode ser visto no Quadro 2.


Quadro 2 – Matriz de interação *afiliado* \times *item*

	Item 1	Item 2	Item 3	Item 4	Item 5	Item N
Afiliado 1			5	3		
Afiliado 2	2		5			1
Afiliado 3			5		3	
Afiliado 4		0	5	3		
Afiliado 5	1		5			2
Afiliado N				1		

Fonte: Elaborado pelo autor (2022).

Observando a matriz de interação, cada registro nesta matriz é um valor de peso associado à interação do afiliado com o item. Por exemplo, na primeira linha da matriz, o Afiliado 1 curtiu o item 3, pois como já visto na 1ª etapa, a característica de comportamento curtida é referenciada pelo peso 5. Através dessa modelagem dos dados de entrada, a matriz de interação é primeiramente refatorada para uma matriz de interação esparsa, e posteriormente, submetida ao processo de aprendizagem/treinamento da rede *autoencoder*. O objetivo da saída da rede é a reconstrução da matriz de interação *afiliado* \times *item* contendo uma aproximação de todos os valores da matriz de interação de entrada. A Figura 12 demonstra o modelo.

Figura 12 – Modelo de aprendizagem/treinamento da rede *autoencoder*




Fonte: Elaborado pelo autor (2022).

A camada *autoencoder* realiza o processamento de aprendizagem sobre os afiliados com a intenção de recomendar os itens mais aderentes para determinado afiliado. Esta aprendizagem é baseada na abordagem de recomendação por filtragem colaborativa levando em consideração o conceito de similaridade. O conceito de similaridade pode ser visualizado, intuitivamente, no espaço latente, onde é possível observar de maneira gráfica alguns agrupamentos de dados que representam, por exemplo, os itens indicados para afiliados com preferências semelhantes. À medida que é realizado o treinamento do *autoencoder*, os itens se organizam em agrupamentos representando parcelas de afiliados que apresentam preferências (perfis) semelhantes sobre determinado item (Figura 13).

Como a rede *autoencoder* utiliza a abordagem de filtragem colaborativa, no momento do treinamento são inseridos os valores de avaliações dos afiliados sobre os itens (matriz interação de entrada) e, a partir disso, os dados passam pelo processo de codificação e são representados no espaço latente. Conforme a rede encontra afiliados com avaliações semelhantes sobre o mesmo item, o espaço latente é responsável por agrupar estes afiliados juntamente com o item. Assim sendo, estas informações podem ser utilizadas por sistemas de recomendação, reforçando a indicação de itens aos afiliados conforme a interação com a plataforma. Segue abaixo, uma representação deste cenário (Figura 13).

Figura 13 – Visualização da similaridade no espaço latente



Fonte: Elaborado pelo autor (2022).

Após o treinamento da rede e, sabendo que o objetivo do *autoencoder* é reproduzir a

entrada, a matriz de interação *afiliado* × *item* é então reconstruída (Figura 12), contendo uma aproximação de todos os valores de pesos da matriz de entrada.

4.3 Etapa 3: Previsão/Recomendação dos itens

Para esta etapa é realizado o processo de recomendação de itens com base na preferência do afiliado. Primeiramente, como já visto na etapa anterior, o *autoencoder* é treinado para que sua saída gere uma matriz de interação reconstruída contendo uma aproximação de todos os valores da matriz de interação de entrada.

Cada valor da matriz (Quadro 3) é uma predição do valor de comportamento que o afiliado geraria como *feedback* implícito ou explícito. Este valor está relacionado com a preferência do afiliado com o item, ou seja, quanto maior o valor, mais relevante é a recomendação do item ao afiliado. Deste modo, para que o processo de recomendação de itens seja efetivo é preciso submeter o id único do afiliado para o sistema de recomendação. Assim, o sistema de recomendação seleciona o id único na matriz de interação reconstruída e retorna somente as previsões aprendidas pela rede *autoencoder* a partir das interações de determinado afiliado com os itens de interesse.

Quadro 3 – Matriz de interação *afiliado* × *item* reconstruída

Matriz de Interação Afiliado x Item Reconstruída						
	Item 1	Item 2	Item 3	Item 4	Item 5	Item N
Afiliado 1	1.35	0.69	2.49	3	1.14	0.13
Afiliado 2	2.26	1.45	3.21	-0.95	1.18	0.96
Afiliado 3	0.89	2.65	4.61	1.29	3	-0.13
Afiliado 4	1.59	0.14	5	3	0.92	0.65
Afiliado 5	-0.56	0.16	1.49	2.21	3.41	2
Afiliado N	0.46	0.29	3.56	1	0.08	2.59

Fonte: Elaborado pelo autor (2022).

Um exemplo utilizando o id do Afiliado 1 pode ser visto no esquema da Figura 14. O vetor do Afiliado 1 está totalmente preenchido com os valores de predição. O vetor é então ordenado de forma decrescente para elucidar os itens que o afiliado tem maior interesse (peso de maior valor). O retorno de recomendações é limitado para somente dez itens e pesos maiores do que zero.

Figura 14 – Afiliado 1 recebe a lista de recomendações de itens



Fonte: Elaborado pelo autor (2022).

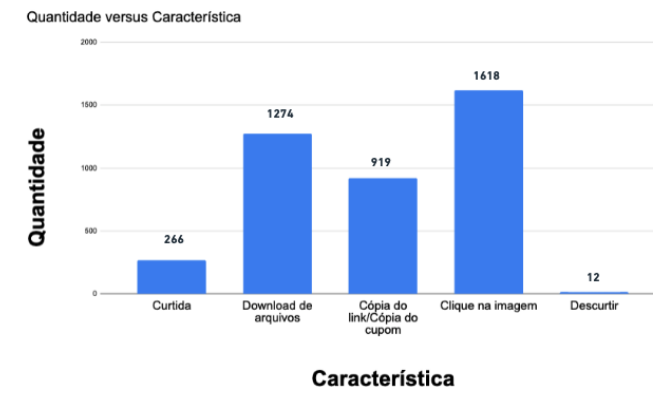
5 Resultados e Discussões

Nesta seção serão apresentados os resultados e discussões acerca do cenário de estudo e do projeto experimental referentes ao método de recomendação de itens no contexto de *marketing* de afiliados.

5.1 Cenário de estudo

O estudo foi desenvolvido considerando a plataforma de *marketing* de afiliados da empresa Magafílio⁴. Os dados utilizados para a avaliação do método proposto foram coletados a partir dos registros de comportamento dos afiliados na plataforma conforme descrito na Seção 4. O procedimento de coleta de informações ocorreu entre os dias 02/12/2021 e dia 11/02/2022 (aproximadamente dois meses e meio). O banco de dados da plataforma já havia cadastrado 4089 características de comportamento sobre 323 itens e 446 afiliados únicos, sendo que estes comportamentos coletados correspondem há somente 3% dos valores preenchidos na matriz de interação *afiliado* \times *item* de entrada, pois a matriz é composta por $N \times M$ valores (144058 posição). Na Figura 15, é visualizada a quantidade de interação dos afiliados na plataforma para cada característica de comportamento.

Figura 15 – Quantidade de interação de acordo com os comportamentos presentes na plataforma



Fonte: Elaborado pelo autor (2022).

O método proposto foi aplicado em uma plataforma real, ou seja, em ambiente de produção na empresa mencionada anteriormente. O servidor responsável por hospedar a plataforma é um computador EC2 disponibilizado pela Amazon Web Services[®] (AWS). As características do servidor são: 2GB de memória RAM, processador i386, de arquitetura X86_64 com um núcleo de processamento e sistema operacional Linux[®]. Quanto às tecnologias utilizadas no desenvolvimento do sistema que instancia o método menciona-se um servidor implementado em tecnologia NodeJS[®], com banco de dados não-relacional MongoDB[®] e com *frontend* da plataforma desenvolvido por meio do *framework* Vue.js[®].

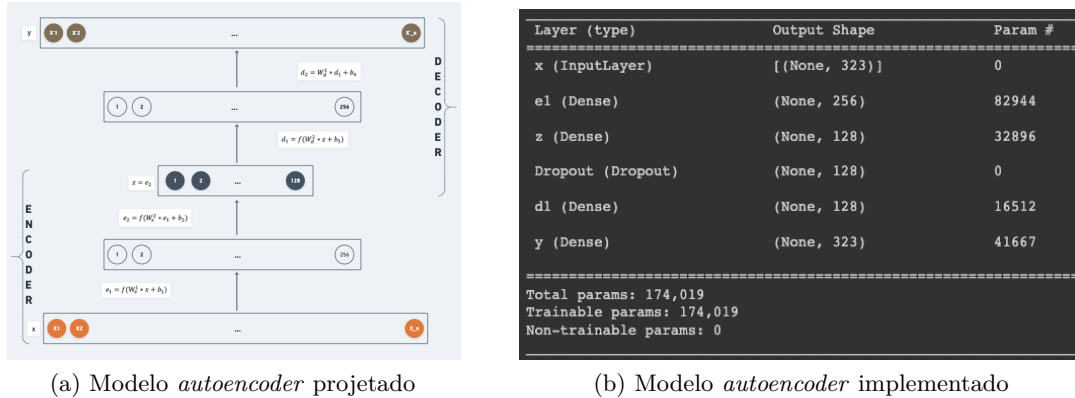
5.2 Projeto experimental

Para desenvolver o método proposto foi utilizada a linguagem de programação Python[®] e ambiente para implementação de código, o Google Colab[®].

⁴ <<https://magafilio.com.br/>>

Primeiramente, foi construída a matriz de interação a partir das informações de comportamento coletadas no cenário de estudo, subseção 5.1, sendo submetida como entrada da rede *autoencoder*. Estruturalmente, a rede é modelada por uma camada de entrada, três camadas ocultas e uma camada de saída (Figura 16) com suas respectivas funções de ativação.


Figura 16 – Estrutura da arquitetura *autoencoder* implementada



Fonte: Elaborado pelo autor (2022).

Para que a rede *autoencoder* consiga atingir a convergência foi realizado um processo de ajuste dos parâmetros da rede. Os parâmetros utilizados foram baseados no artigo de Kuchaiev e Ginsburg (2017). Deste modo, foram inseridos os parâmetros na rede e realizado um processo de treinamento e visualização da curva de erro. Este processo foi finalizado no momento em que a curva de erro se aproximou de valores muito próximos de zero. A partir disso, os parâmetros utilizados para o retorno da curva de erro (Figura 17) foram os escolhidos para este trabalho. Vale mencionar que cada arquitetura de rede sofre adaptações nos valores dos parâmetros de modo que se atinjam bons resultados.

Figura 17 – Valor de erro da rede em relação às épocas



Fonte: Elaborado pelo autor (2022).

Após os ajustes realizados, a camada de entrada \mathbf{x} recebe o vetor do afiliado em sua

forma esparsa (a linha da matriz). Em outras palavras, todos os itens de um determinado afiliado. Este vetor é codificado pela primeira camada do codificador $e1$ formada por 256 neurônios. Os dados são passados para a camada de espaço latente $z=e2$, formada por 128 neurônios utilizando a técnica de *Dropout*⁵ (configurada para 80%). Já na etapa de decodificação, a camada do decodificador $d1$, recebe os dados do espaço latente z , utilizando 256 neurônios. Todas as camadas até então, apresentam a função de ativação unidade linear exponencial escalonada (do inglês *Scaled Exponential Linear Unit* - SELU) (uma função de ativação não linear que fornece uma auto-normalização (SRIKANTH *et al.*, 2021)) e o *bias* b igual a 1.

Na última camada, representada pela camada de saída, utilizou-se o mesmo número de neurônios da camada de entrada, porém, foi configurada com uma função de ativação linear e *bias* b também igual a 1. A escolha da função linear para esta camada reside no fato de os valores na matriz de 0 a 5 estarem distribuídos na lógica de recomendação. A função de ativação linear consegue melhorar a predição dos dados na matriz de interação reconstruída (KUCHAIEV; GINSBURG, 2017).

Os parâmetros de treinamento da rede foram definidos conforme consta no Quadro 4.

Quadro 4 – Parâmetros definidos para o treinamento do *autoencoder*

Número de épocas - epochs	50
Tamanho do lote - batch_size	1
Otimizador - Optimizer	Adam
Função de perda - loss	Eq. 1
Taxa de aprendizado - learning_rate	0.0001

Fonte: Elaborado pelo autor (2022).

Após o treinamento da rede, a matriz de interação de entrada é reconstruída, contendo predições dos itens para cada afiliado.

5.3 Análise dos Resultados

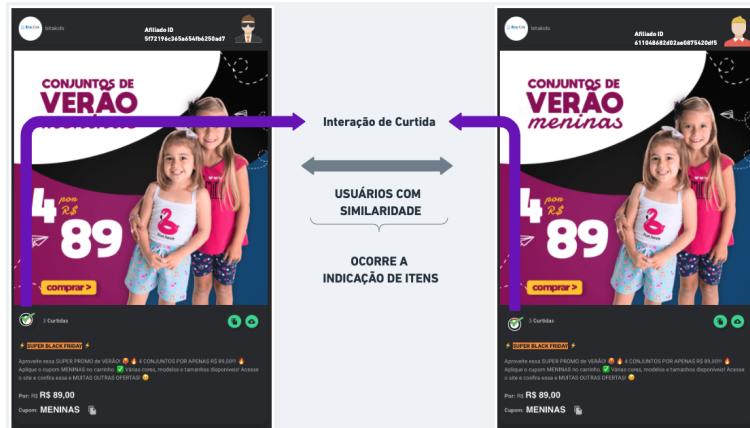
Após definir o cenário de estudo e o projeto experimental utilizado no RS para os afiliados da plataforma, faz-se necessária a análise de comportamentos característicos e suas relações com a recomendação de itens. Nesta seção, serão descritos três cenários, onde em cada um deles são escolhidos afiliados aleatoriamente no banco de dados da plataforma, retornando os itens que os mesmos têm interagido e as recomendações de itens retornadas pela rede *autoencoder*. Diante disso, é avaliado se os itens recomendados estão de acordo ou não com os interagidos na plataforma.

⁵ *Dropout* é uma técnica de regularização que, durante a etapa de treinamento da rede randomicamente escolhe alguns neurônios da camada para desabilitar, ou seja, define os neurônios para 0. O objetivo desta técnica é tornar a rede mais resiliente evitando o *overfitting*. Por exemplo, se um neurônio estiver desabilitado, outro neurônio da camada deverá realizar a tarefa que o desabilitado estava realizando.

5.3.1 Cenário 1

No cenário 01 (Figura 18), consideram-se dois usuários distintos (à esquerda - Afiliado 1 e à direita - Afiliado 2⁶) que acessaram a plataforma de afiliados. O item “**SUPER BLACK FRIDAY**” é listado para eles e ambos reagem de forma similar, curtindo a oferta apresentada. Como ambos tiveram a mesma característica de comportamento sobre a mesma oferta na plataforma é criada uma relação de similaridade entre os dois afiliados.

Figura 18 – Ofertas com a interação dos afiliados



Fonte: Elaborado pelo autor (2022).

Sendo assim, há uma grande probabilidade de que haja a indicação mútua de ofertas para os envolvidos. Na Figura 19, é possível identificar que tanto o Afiliado 1 (figura à esquerda) quanto o Afiliado 2 (figura à direita) se interessam por ofertas de promoções e liquidações⁷.

Figura 19 – Característica de comportamento dos afiliados na plataforma

A imagem mostra o perfil de dois afiliados com uma lista de ofertas curtidas e recomendadas. O Afiliado 1 (à esquerda) tem o ID 5f72196c365a654fb6250ad7. O Afiliado 2 (à direita) tem o ID 611048692602ae0875420df5. As ofertas incluem 'SUPER BLACK FRIDAY', 'CAMISETAS RIACCI', 'SUPER PRIMO DE VERÃO', 'MEGA BLACK JORNHA' e 'SUPER LIQUIDAÇÃO'. Uma seta verde indica a recomendação da oferta 'SUPER LIQUIDAÇÃO' para o Afiliado 2, e uma seta laranja indica a interação do Afiliado 1 com a oferta 'SUPER LIQUIDAÇÃO'.

Fonte: Elaborado pelo autor (2022).

Para o item da plataforma “**SUPER LIQUIDAÇÃO**”, em que o Afiliado 2 interagiu por meio de uma curtida, é possível identificar que mesmo o Afiliado 1 não tendo visualizado a oferta (identificado por uma seta verde na imagem referente ao Afiliado 2), (Figura 19), este receberá, pelo menos a recomendação que possui o maior *rating*⁸. Isso

⁶ Os Afiliados 1 e 2 representam os ids de afiliado único retirado da plataforma real que esta presente nas figuras dos cenários. Cada cenário ids de afiliados são diferentes.

⁷ Seta laranja - Indica o *match* dos afiliados sobre a oferta.
Seta verde - Indica a recomendação da oferta para o afiliado similar.

⁸ *Rating* - É uma nota que o sistema retorna para cada oferta recomendada, quanto maior a nota o sistema entende que o afiliado gostará mais.

ocorre pelo fato dos Afiliados 1 e 2 terem um comportamento semelhante ao curtirem a mesma oferta listada.

Figura 20 – Recomendações do sistema para o Afiliado 1

action_id	rating	name
61ae2308b718d010cd8b3537	1.835122	* SUPER LIQUIDAÇÃO *
619f75091c032c4ecf38443a	1.538742	O GERENTE FICOU MALUCO! 🤪🤪
619e3a0b1c032c4ecf2adde5	1.049527	O OUTLET MAIS AGUARDADO DO ANO CHEGOU! 🎉
61a910d19a0c0542ef999e33	0.972805	Jogo de Toalha Chronos 4 Peças Fio Penteado - ...
619f7b3c1c032c4ecf38a037	0.967803	* SUPER PROMO BLACK FRIDAY *
61a625b41c032c4ecf6cfdcf	0.887212	Moda para relaxar... 🌿
61ae2138b718d010cd8b1cbe	0.786245	Rasteiras Moleca 🍌
619e24d51c032c4ecf29728e	0.783114	* SUPER BLACK FRIDAY MODA PRIME *
6197bd471c032c4ecfbf67a5	0.658731	* SUPER PROMO DE VERÃO *
61e044210402f301662e2281	0.609873	* SUPER LIQUIDAÇÃO DE VERÃO *

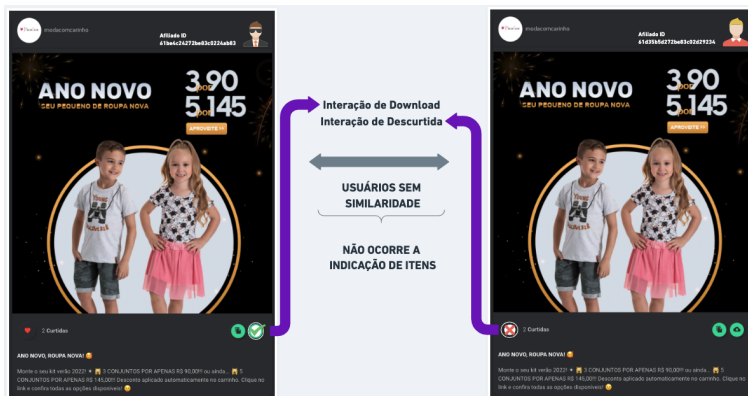
Fonte: Elaborado pelo autor (2022).

Por fim, a oferta “**SUPER LIQUIDAÇÃO**” só foi recomendada para o Afiliado 1, pois ele não tinha interagido ainda com esta oferta, visto que o RS não deve recomendar ofertas que determinado afiliado já interagiu.

5.3.2 Cenário 2

No cenário 02 (Figura 21), consideram-se também dois afiliados distintos, acessando a plataforma de afiliados. O item “**ANO NOVO, ROUPA NOVA!**” foi acessado por ambos. Porém, o Afiliado 1 realiza o *download* de arquivos para divulgar a oferta para terceiros, enquanto o outro afiliado (Afiliado 2) reage de maneira diferente, curtindo a oferta e na sequência descurtando a oferta, demonstrando desinteresse ou equívoco de interação com a plataforma. Como o Afiliado 2 descurtiu a oferta, o peso dessa interação passa a ser 0, conforme o Quadro 1. Desse modo, quando algum afiliado descurtir alguma oferta, não é criado nenhuma relação de similaridade entre os dois afiliados com base no conteúdo da oferta.


Figura 21 – Ofertas com a interação dos afiliados



Fonte: Elaborado pelo autor (2022).

Sendo assim, neste cenário há uma grande probabilidade de que não haja a indicação mútua de ofertas para os envolvidos com base em conteúdos consumidos por ambos. Na Figura 22, é possível identificar que tanto o Afiliado 1 (figura à esquerda) quanto o Afiliado 2 (figura à direita) se interessam por itens diferentes dispostos na plataforma.

Figura 22 – Característica de comportamento dos afiliados na plataforma



Fonte: Elaborado pelo autor (2022).

Na tabela de recomendação para o Afiliado 1 (Figura 23), é possível visualizar que as ofertas sugeridas e recomendadas não compõem nenhuma oferta interagida pelo Afiliado 2, pois, não é criada uma conexão de similaridade entre os dois afiliados. Assim, nenhuma oferta em que o Afiliado 2 tenha interagido é recomendado para o Afiliado 1.

Figura 23 – Recomendações do sistema para o Afiliado 1

action_id	rating	name
61eeb09a549e2e26cb384ad8	0.242304	COMPRE 5 PEÇAS INFANTIL POR R\$ 99,99! 🎉
61e198ac927c494414724dc4	0.228016	PROMOÇÃO DE VERÃO 2022 ✨
61dc65040402f301660ade38	0.224820	Para as pequenas curtirem o verão com todo o c...
61e044210402f301662e2281	0.221654	✨ SUPER LIQUIDAÇÃO DE VERÃO ✨
619f75091c032c4ecf38443a	0.221585	O GERENTE FICOU MALUCO! 🤪

Fonte: Elaborado pelo autor (2022).

5.3.3 Cenário 3

No cenário 03 (Figura 24), a oferta **“O VERÃO CHEGOU COM TUDO!”** é listado para os afiliados, porém o Afiliado 1 realiza a interação de clique na imagem demonstrando interesse sobre a oferta, enquanto Afiliado 2 se interessa pela oferta e pretende divulgar os arquivos de *download* para terceiros. Ambos apresentaram diferentes características de comportamento sobre o mesmo item na plataforma, logo é criado uma relação de baixa similaridade entre os dois afiliados (os pesos são diferentes), com base no *feedback* explícito, via botões de interação da plataforma.

Sendo assim, mesmo com diferentes características de comportamento, há a probabilidade de que haja uma recomendação mútua de ofertas para os envolvidos com base em conteúdos interagidos por ambos. Na Figura 25, é possível identificar que tanto o Afiliado 1 (figura à esquerda) quanto o Afiliado 2 (figura à direita) se interessam por diferentes ofertas da plataforma, e também pela oferta **“O VERÃO CHEGOU COM TUDO!”** (o que garante a similaridade entre eles).

Como os afiliados possuem um grau de similaridade, a recomendação pode ser realizada de forma mútua. Para a oferta da plataforma **“O VERÃO CHEGOU COM TUDO!”**, por exemplo, visto e interagido pelos Afiliados 1 e 2, é possível identificar na

Figura 24 – Ofertas com a interação dos afiliados



Fonte: Elaborado pelo autor (2022).

Figura 25 – Característica de comportamento dos afiliados na plataforma

Affiliate ID	action_id	rating	name
6145e0207d4bc76ee9ff6b2a	61a9121e9b0c0542ef9a0045	2.0	* SUPER PROMO DE VERÃO *
	61a628bc1c032c4ecf6d4c05	1.0	O verão chegou com tudo!
611d051a78aed554e08cf33	61debd30402f301661e8377	5.0	As meninas amam. 🥰
	61e0460504022f301662e54d5	5.0	* SUPER LANÇAMENTO DE VERÃO *
	61e0485e04022f301662e5337	3.0	Novidades NO SITE! 📢
	61ddc79f04022f3016618c8bd	3.0	Desconto EXCLUSIVO 🥰🥰
	61a627af1c032c4ecf6d2f6b	3.0	Vestido Kloe 🌟
	61d965004022f30166124f09	3.0	Para as Mini Babes Fashionistas! 🥰
	61a628bc1c032c4ecf6d4c05	3.0	O verão chegou com tudo! 🌟
	61a9121e9b0c0542ef9a0045	3.0	* SUPER PROMO DE VERÃO *

Fonte: Elaborado pelo autor (2022).

tabela de recomendação para o Afiliado 1 (Figura 26), que a quinta oferta foi recomendada como uma oferta de interesse em comum. Importante ressaltar que não faz sentido um sistema de recomendação sugerir algo que já foi visto, pois se espera que a recomendação seja de novas ofertas.

Figura 26 – Recomendações do sistema para o Afiliado 1

rating	name
0.254042	* SUPER LIQUIDAÇÃO *
0.227469	Você merece o melhor! 🌟
0.200015	O GERENTE FICOU MALUCO! 🤪
0.196140	Rasteiras Moleca 🥰
0.170385	COMPRE 5 PEÇAS INFANTIL POR R\$ 99,99! 📢
0.143592	Vestido Kloe 🌟
0.140332	As meninas amam. 🥰
0.132778	Natal é com a Mix da Moda! 🥰🌟
0.131936	Tudo o que você queria para fazer um jantar li...
0.126219	Para as pequenas curtirem o verão com todo o c...

Fonte: Elaborado pelo autor (2022).

5.4 Avaliação das Recomendações

Esta etapa de avaliação é de fundamental importância para o método proposto. Tem como objetivo aferir a acurácia das recomendações efetuadas, ou seja, a verificação se o modelo de recomendação consegue ser efetivo no contexto de *marketing* de afiliados. Assim sendo, para este trabalho utilizou-se o processo de avaliação para analisar o desempenho do sistema de recomendação do tipo *autoencoder* para sugerir ofertas à afiliados a partir de outros afiliados com perfis similares, visto que o trabalho em questão utiliza a abordagem de filtragem colaborativa usuário-usuário.

A partir disso, foram selecionadas 5% das características de comportamento (interações dos afiliados sobre as ofertas) salvas no banco de dados, conforme consta na Seção 5.1, mais precisamente, 204 valores de características de comportamento de afiliados similares. Sendo que para o teste não foi utilizado o mesmo afiliado mais de uma vez, visto que o objetivo é abranger o maior número possível de afiliados da plataforma.

Para medir a efetividade do RS foi treinada a rede *autoencoder* condizente aos parâmetros demonstrados no Quadro 4. Após o treinamento da rede foram realizados os testes conforme demonstrados nos cenários da Seção 5.3. Por fim, os testes realizados com o conjunto de dados produziu uma acurácia de 87,37%, em que esta porcentagem representa a assertividade obtida pelo sistema ao recomendar uma oferta que um determinado afiliado similar ainda não viu e que possivelmente teria interesse.

6 Considerações Finais e Trabalhos Futuros

Considerando a expansão do *marketing* de afiliados no mercado, muitas plataformas que se utilizam deste serviço relatam que grande parte dos seus afiliados cadastrados nunca efetuou uma venda. Neste sentido, o presente trabalho propôs um método suportado por um sistema de recomendação baseado em filtragem colaborativa utilizando aprendizado profundo *autoencoder* para uma plataforma de *marketing* de afiliados ativa no mercado. Possui o intuito de recomendar produtos e ofertas em alta para afiliados com baixas taxas de conversão, de modo que estes tenham maior clareza do que ofertar em seus canais de mídia social, por exemplo.

Para tal, foi realizada a etapa de coleta de dados, mais precisamente, o comportamento dos afiliados levando em conta algumas características, entre elas, *click* em botões específicos e *download* de arquivos das ofertas cadastradas na plataforma, a fim de conhecer as preferências dos afiliados. A partir disso, realizou-se o treinamento da rede neural profunda *autoencoder* que suporta as recomendações e, em seguida, foram realizados dois tipos de testes. Primeiro, através de cenários descrevendo o comportamento dos afiliados e o resultado das recomendações. Na sequência, avaliando a efetividade do sistema de recomendação implementado que alcançou resultados satisfatórios, com uma acurácia de 87,37%. Sendo assim, o sistema de recomendação atendeu o objetivo de prever itens que sejam da preferência do afiliado, demonstrando que a sua implementação possui impacto na taxa de conversão em lojas virtuais.

Cabe mencionar que a rede neural *autoencoder* utilizada neste trabalho possui escalabilidade, visto que tal arquitetura consegue lidar adequadamente com o incremento de novos itens. Isto ocorre, essencialmente, devido ao processo de compactação dos dados realizado pelo codificador. Todavia, considerando o fato de que novos itens e afiliados são inseridos diariamente na plataforma, alguma estratégia de retreinamento frequente terá que ser adotada para refletir o estado atual dos dados.

Embora os resultados atingidos sejam promissores, para uma maior confiabilidade em um ambiente real se faz necessário a utilização de mais dados para o treinamento da rede *autoencoder* com o intuito de aprimorar o índice de acurácia do sistema de recomendação. Para além disso, a evolução da arquitetura da rede neural *autoencoder*, por exemplo, acrescentando mais camadas ocultas ou adicionando modelos híbridos de redes neurais, poderia melhorar os resultados. Ademais, considerando a evolução frequente do campo de pesquisa de DL, novas arquiteturas de redes neurais poderiam ser avaliadas visando incrementar a efetividade das recomendações.

Ainda como trabalhos futuros, vislumbram-se melhorias principalmente no sistema de recomendação, agregando novas funcionalidades que garantam maior robustez e efetividade. Uma das estratégias de melhoria consiste na implementação de novos recursos para a coleta de características de comportamento dos afiliados na plataforma. Soma-se a isto, o estudo e desenvolvimento de estratégias de exibição de ofertas, como novos filtros com os produtos mais vistos na última semana, os produtos ou ofertas que mais tiveram interesse por parte dos afiliados, entre outras.

Sob a perspectiva de evolução da plataforma em que este trabalho foi aplicado, vislumbra-se o desenvolvimento de uma API REST (em linguagem de programação Python® ou outra que atenda este propósito) possibilitando uma maior flexibilidade entre a camada de negócio e a camada de interação do usuário (*frontend*).

Referências

ANUSHA; BIRADAR, Shilpa. Recommender Systems: A Survey. **International Journal of Latest Technology in Engineering, Management Applied Science**, v. 5, n. 1, p. 42–45, 2016.

ARORA, Mansi. **Collaborative based Recommendation system Using SVD**. [S.l.: s.n.], 2020. medium. Disponível em: <https://medium.com/analytics-vidhya/collaborative-based-recommendation-system-using-svd-9adc5b6b3b8>. Acesso em: 07 Jan. 2022.

ARSENIJEVIC, Uroš; JOVIC, Marija. Artificial Intelligence Marketing: Chatbots, p. 19–193, 2019. DOI: <10.1109/IC-AIAI48757.2019.00010>.

BATHLA, Gourav; AGGARWAL, Himanshu; RANI, Rinkle. AutoTrustRec: Recommender system with social trust and deep learning using autoEncoder. **Multimedia Tools and Applications**, Springer, v. 79, n. 29, p. 20845–20860, 2020.

COBRA, Marcos. **Administração de marketing no Brasil**. 3. ed. São Paulo: Editora Elsevier, 2009.

DOSHI, Sanket. **Brief on Recommender Systems**. [S.l.: s.n.], 2019. towards data science. Disponível em: <https://towardsdatascience.com/brief-on-recommender-systems-b86a1068a4dd>. Acesso em: 06 Jan. 2022.

DRUCKER, Peter F. Tasks, responsibilities, practices. **New Yorks Row**, p. 121–122, 1974.

- FAUSTINO, Paulo. **Marketing Digital na Prática: como criar do zero uma estratégia de marketing digital para promover negócios ou produtos**. São Paulo: Editora Sextante, 2017.
- GHOSAL, Indrajit. Predicting Factors influencing Consumer's purchase intention: A Study of Consumers redirected through Affiliate Marketing Program. *Pacific Business Review International*, v. 13, p. 76–86, 2021.
- GOLDBERG, David *et al.* Using collaborative filtering to weave an information tapestry. **Communications of the ACM**, ACM New York, NY, USA, v. 35, n. 12, p. 61–70, 1992.
- GUNDLACH, Gregory T. The American Marketing Association's 2004 definition of marketing: Perspectives on its implications for scholarship and the role and responsibility of marketing in society. **Journal of Public policy & marketing**, SAGE Publications Sage CA: Los Angeles, CA, v. 26, n. 2, p. 243–250, 2007.
- HOLZINGER, Andreas. Introduction to Machine Learning & Knowledge Extraction (MAKE). **Mach. Learn. Knowl. Extr.**, v. 1, n. 1, p. 1–20, 2019.
- ISINKAYE, Folasade Olubusola; FOLAJIMI, Yetunde O; OJOKOH, Bolande Adefowoke. Recommendation systems: Principles, methods and evaluation. **Egyptian informatics journal**, Elsevier, v. 16, n. 3, p. 261–273, 2015.
- IWASHITA, Motoi; TANIMOTO, Shigeaki. Highly secure transaction system for affiliate marketing, p. 1–3, 2016. DOI: <10.1109/GCCE.2016.7800492>.
- JIANG, Liaoliang *et al.* A trust-based collaborative filtering algorithm for E-commerce recommendation system. **Journal of ambient intelligence and humanized computing**, Springer, v. 10, n. 8, p. 3023–3034, 2019.
- KHAN, Zafran *et al.* Contextual recommender system for E-commerce applications. **Applied Soft Computing**, Elsevier, v. 109, p. 107552, 2021.
- KONSTAN, Joseph A; RIEDL, John. Recommender systems: from algorithms to user experience. **User modeling and user-adapted interaction**, Springer, v. 22, n. 1, p. 101–123, 2012.
- KOTLER, Philip; KARTAJAYA, Hermawan; SETIAWAN, Iwan. **Marketing 4.0 do tradicional ao digital**. 1. ed. Rio de Janeiro: Editora Sextante, 2017.
- KOTLER, Philip; KELLER, Kevin L. **Administração de marketing**. 14. ed. São Paulo: Editora Pearson, 2012.
- KUCHAIEV, Oleksii; GINSBURG, Boris. Training deep autoencoders for collaborative filtering. **arXiv preprint arXiv:1708.01715**, 2017.
- KUMAR, Mallari Vijay; KUMAR, Pavan. Recommendation systems: Principles, methods and evaluation. **International Journal of Recent Technology and Engineering (IJRTE)**, Blue Eyes Intelligence Engineering Sciences Publication, v. 7, p. 38–41, 2019.
- LEE, Ying-Lien; HUANG, Fei-Hui. Recommender system architecture for adaptive green marketing. **Expert Systems with Applications**, Elsevier, v. 38, n. 8, p. 9696–9703, 2011.
- LI, Li *et al.* Artificial intelligence test: A case study of intelligent vehicles. **Artificial Intelligence Review**, Springer, v. 50, n. 3, p. 441–465, 2018.
- LIANG, Ruxia; WANG, Jianqiang. A Linguistic Intuitionistic Cloud Decision Support Model with Sentiment Analysis for Product Selection in E-commerce. **International Journal of Fuzzy Systems**, v. 21, p. 963–977, 2019.

- LIMEIRA, Tania M Vidigal. **E-marketing: o marketing na internet com casos brasileiros**. 2. ed. São Paulo: Editora Saraiva, 2012.
- MACKENZIE, Ian; MEYER, Chris; NOBLE, Steve. **How retailers can keep up with consumers**. [S.l.: s.n.], 2013. McKinsey Company. Disponível em: <https://www.mckinsey.com/industries/retail/our-insights/how-retailers-can-keep-up-with-consumers>. Acesso em: 06 Jan. 2022.
- MADANI, Youness *et al.* Social collaborative filtering approach for recommending courses in an E-learning platform. **Procedia Computer Science**, Elsevier, v. 151, p. 1164–1169, 2019.
- MANGALINDAN, JP. **Amazon's recommendation secret**. [S.l.: s.n.], 2012. FORTUNE. Disponível em: <https://fortune.com/2012/07/30/amazons-recommendation-secret/>. Acesso em: 06 Jan. 2022.
- MATHEW, George; SMITH, Steven T.; PASSARELLI, John. Large Scale Open Source Video Recommender Tool Using Metadata Surrogates, p. 1974–1977, 2018. DOI: <10.1109/BigData.2018.8622221>.
- MU, Ruihui. A survey of recommender systems based on deep learning. **IEEE Access**, v. 6, p. 69009–69022, 2018. DOI: <10.1109/ACCESS.2018.2880197>.
- OLIVEIRA MACHADO, Roseli de. MARKETING DIGITAL: ANÁLISE DAS PRINCÍPIAS ESTRATÉGIAS USADAS NO COMÉRCIO ELETRÔNICO BRASILEIRO. **Revista Eletrônica de Administração e Turismo-ReAT**, v. 12, n. 7, p. 1693–1712, 2018.
- PANDEY, Kamal Kishor; BHATIA, Megha; VARSHNEY, Ms Nidhi. THE NEW INVESTMENT POLICY: ISSUES AND CHALLENGES IN THE COVID-19 ERA. **Paradigm Shifts in Management Practices In the Era of Industry 4.0**, p. 37, 2021.
- PATRICK, Zurina; HEE, Ong Choon. Affiliate Marketing in SMEs: The Moderating Effect of Developmental Culture. **Pertanika Journal of Social Sciences & Humanities**, v. 29, n. 2, 2021.
- RADISIC, Igor; LAZAREVIC, Sasa. Application of Similarity Metrics in Collaborative Filtering Based Recommendation Systems, p. 82–85, 2019.
- RAHAL, Amine. **Affiliate Marketing In 2020: What It Is And How Beginners Can Get Started**: Forbes. [S.l.: s.n.], 2020. Disponível em: <<<https://www.forbes.com/sites/theyec/2020/01/23/affiliate-marketing-in-2020-what-it-is-and-how-beginners-can-get-started/?sh=675eb45c61c2>>>.
- REPORT, Awin. **2020 in review**: Awin. [S.l.: s.n.], 2021. Disponível em: <<<https://www.awin.com/awin-report/2021/global/2020-review/>>>.
- RICCI, Francesco *et al.* **Recommender Systems Handbook**. [S.l.]: Editora Springer, 2011.
- RODRIGUES, Jonas Almeida; KROIS, Joachim; SCHWENDICKE, Falk. Demystifying artificial intelligence and deep learning in dentistry. **Brazilian oral research**, SciELO Brasil, v. 35, 2021.

- ROLIM; SIMÕES; FIGUEIREDO. Network and Revenue Analysis of an Affiliate Marketing Program in the Travel Industry. SBC, Cuiabá, p. 120–131, 2020b. ISSN 2595-6094. DOI: <10.5753/brasnam.2020.11168>. Disponível em: <<<https://sol.sbc.org.br/index.php/brasnam/article/view/11168>>>.
- ROLIM; SIMÕES; FIGUEIREDO. Network and Revenue of the Clube Hurb Affiliate Marketing Program: A Story of Two Tales, p. 544–548, 2020a. DOI: <10.1109/ASONAM49781.2020.9381447>.
- SANTOS, Felipe André dos. Marketing na era digital: análise da marca Chico Rei. **Juiz de Fora Fevereiro de**, 2014.
- SCHAFER, J Ben; KONSTAN, Joseph A; RIEDL, John. E-commerce recommendation applications. **Data mining and knowledge discovery**, Springer, v. 5, n. 1, p. 115–153, 2001.
- SRIKANTH, Purushothaman *et al.* Movie Recommendation System Using Deep Autoencoder, p. 1059–1064, 2021.
- STUART, Russel J.; PETER, Norvig. **Artificial Intelligence A Modern Approach**. 3. ed. Nova Jersey, EUA: Editora Prentice Hall, 2009.
- SURYANARAYANA, Sharadhi Alape; SARNE, David; KRAUS, Sarit. Information Design in Affiliate Marketing. **Autonomous Agents and Multi-Agent Systems**, Springer, v. 35, n. 2, p. 1–28, 2021.
- TAHMASEBI, Hossein; RAVANMEHR, Reza; MOHAMADREZAEI, Rezvan. Social movie recommender system based on deep autoencoder network using Twitter data. **Neural Computing and Applications**, Springer, v. 33, n. 5, p. 1607–1623, 2021.
- VALOIS, Cleomar; OLIVEIRA, Marcius Armada de. Recommender systems in social networks. **JISTEM-Journal of Information Systems and Technology Management**, SciELO Brasil, v. 8, n. 3, p. 681–716, 2011.
- XIAO, Ying; EZEIFE, CI. E-commerce product recommendation using historical purchases and clickstream data, p. 70–82, 2018.
- YU, Chengchao *et al.* A Recommender System for Ordering Platform Based on an Improved Collaborative Filtering Algorithm, p. 298–302, 2018. DOI: <10.1109/ICALIP.2018.8455852>.
- ZHANG, Guijuan; LIU, Yang; JIN, Xiaoning. A survey of autoencoder-based recommender systems. **Frontiers of Computer Science**, Springer, v. 14, n. 2, p. 430–450, 2020.