

Recomendação de Provedores de Serviços

Uma Abordagem Inovadora

FERRERAS, RICARDO Pompeu
USP, ICMC, Especialista em Ciência de Dados
ricardo.ferrerass@gmail.com

Resumo

Este projeto utiliza ciência de dados para desenvolver um sistema de recomendação de provedores de serviços, aplicável em diversos setores como manufatura, saúde e finanças. O sistema, desenvolvido em *Python* e publicado via *API*¹, utiliza técnicas de aprendizado de máquina e análise de dados para fornecer recomendações personalizadas e adaptáveis. A metodologia inclui coleta e pré-processamento de dados, desenvolvimento de modelos e treinamento para garantir precisão e relevância. Resultados mostram uma economia de custos de 12,84% e um aumento de 18,43% na satisfação dos usuários. O sistema analisa desempenho anterior, avaliações de clientes e características dos provedores para identificar padrões e tendências, melhorando a experiência do cliente e a eficiência operacional. A abordagem baseada em dados concretos permite decisões assertivas, destacando o valor da ciência de dados na recomendação de serviços e demonstrando seu potencial para inovação. **Palavras-chave:** ciência de dados, recomendação, *python*

1 Introdução

No cenário atual, onde a escolha do provedor de serviços certo pode determinar o sucesso ou fracasso de um atendimento ou projeto, a recomendação de provedores se torna uma ferramenta essencial. Imagine um mundo onde é possível encontrar o parceiro perfeito para as necessidades de negócios com apenas alguns cliques. Esse é o poder da ciência de dados (CD) aplicada à recomendação de provedores.

A recomendação de provedores não é apenas uma questão de conveniência; é uma questão de estratégia. Empresas de todos os tamanhos enfrentam o desafio de selecionar provedores que não apenas atendam às suas necessidades imediatas, mas que também se alinhem com seus objetivos de longo prazo. A escolha errada pode resultar em custos elevados, atrasos e, em última análise, em perda de competitividade. Por outro lado, a escolha certa pode impulsionar a eficiência, a inovação e o crescimento.

Neste projeto, explora-se como a CD pode transformar a maneira como a empresa escolhe seus provedores de serviços. Utilizando técnicas de aprendizado de máquina e análise de dados, foi criado um sistema de recomendação (SR) que oferece sugestões personalizadas e altamente precisas. Este sistema não apenas considera as necessidades específicas do usuário, mas também se adapta com o tempo, melhorando continuamente suas recomendações.

A CD oferece uma abordagem baseada em evidências para a recomendação de provedores. Em vez de confiar em intuições ou opiniões subjetivas, a empresa pode tomar decisões assertivas com base em dados concretos. Isso inclui análises de desempenho anteriores, avaliações de clientes, características específicas dos provedores e muito mais. Com essas informações, o SR pode iden-

tificar padrões e tendências que seriam impossíveis de detectar manualmente.

Além disso, a recomendação de provedores de serviços baseada em CD pode ser aplicada em uma variedade de setores. Desde a indústria de manufatura até a saúde, passando pela construção e serviços financeiros, as possibilidades são infinitas. Cada setor tem suas próprias necessidades e desafios únicos e o SR pode ser personalizado para atender a essas especificidades.

Um dos principais benefícios dessa abordagem é a capacidade de melhorar a experiência do cliente. Ao fornecer recomendações precisas e relevantes, as empresas podem garantir que seus clientes encontrem os provedores certos rapidamente e com confiança. Isso não apenas aumenta a satisfação do cliente, mas também fortalece a lealdade e a confiança na marca.

Com isso, a eficiência operacional é significativamente aprimorada. Com um SR automatizado, a empresa pode economizar tempo e recursos que seriam gastos na busca e avaliação de provedores. Isso permite que as equipes se concentrem em atividades mais estratégicas e de maior valor agregado.

2 Revisão da Literatura

Nos últimos anos, as pessoas e empresas têm sido inundadas por uma grande onda de informação e de dados referentes a todas as áreas da vida em sociedade. Dessa forma, o usuário depara-se com um gigantesco oceano de informação, que nem sempre está bem-organizado ou representado. Ademais, os processos de busca e recuperação da informação são cada vez mais complicados e nem sempre a pessoa está preparada ou tem a experiência necessária para elaborar as estratégias de busca que o levem ao encontro da informação que precisa.

¹Interface de Programação de Aplicações, conjunto de padrões, ferramentas e protocolos que permite a comunicação entre diferentes sistemas e aplicações.

Uma das ferramentas atualmente mais usadas para diminuir esse problema é a utilização dos Sistemas de Recomendação (SR) nos diferentes ambientes ou sistemas de informação, os quais facilitam o encontro de dados durante os processos de busca e navegação, oferecendo aos usuários indicações daqueles produtos e serviços que poderiam estar associados ou relacionados às suas necessidades. Segundo Resnick and Varian [1997], os SR são:

"[...] sistemas que utilizam as opiniões de uma comunidade de usuários para auxiliar indivíduos desta mesma comunidade a identificarem conteúdos de interesse em um conjunto de opções que poderiam caracterizar uma sobrecarga"

No entanto, para o adequado funcionamento desses sistemas, eles devem dispor de um amplo conhecimento sobre os usuários/provedores com os quais interagem, saber sobre as suas capacidades, características e necessidades. Para tanto, os elementos essenciais são a coleta, o processamento e o armazenamento dos dados dos usuários/provedores, que possibilitam a identificação deles ao mesmo tempo que facilitam o oferecimento das informações sobre aqueles produtos que têm relação com seus perfis.

A coleta dos dados dos usuários/provedores pode acontecer de forma explícita, comumente chamada de customização, onde a pessoa indica quais são seus interesses criando um perfil sobre seus gostos e prioridades; ou de forma implícita, quando o sistema sugere os gostos e preferências dos usuários através da sua operação principal.

Uma vez coletadas as informações sobre os usuários e os produtos, outro problema se apresenta: definir quais produtos indicar para cada usuário. Isso faz com que os sistemas de informação apresentem grande dificuldade na entrega dos dados buscados em cada momento, tornando imprescindível realizar o processo de filtragem da informação como elemento primordial na identificação de padrões de comportamento e de personalização do relacionamento sistema-usuários.

Segundo Belkin and Croft [1992]

"filtragem de informação é o nome utilizado para descrever uma variedade de processos que envolvem a entrega de informação para as pessoas que realmente necessitam delas"

São três as técnicas de filtragem mais usadas:

- **Filtragem baseada em conteúdo:** realiza uma seleção baseada na análise de conteúdo dos itens e no perfil do usuário.
- **Filtragem colaborativa:** a essência está na troca de experiências entre as pessoas que possuem interesses comuns.
- **Filtragem híbrida:** procura combinar os pontos fortes da filtragem colaborativa e filtragem baseada em conteúdo visando criar um sistema que possa melhor atender às necessidades do usuário Reategui and Cazella [2005].

Uma vez filtrada a informação, é o momento de oferecer a cada usuário aquelas recomendações adequadas ao perfil individual. São várias as estratégias de recomendação utilizadas pelos SR:

- **Listas de recomendação:** consiste em manter lista de itens organizados por tipos de interesses.
- **Avaliações de usuários:** consiste na recomendação baseada na avaliação dos produtos feita pelos usuários.

3 Metodologia

Para desenvolver o SR, foi utilizado um conjunto de dados próprio, incluindo capacidade de atendimento, características dos provedores e histórico de serviços. Aplicaram-se técnicas de pré-processamento para limpar e preparar os dados, seguidas por algoritmos de similaridade. O sistema foi desenvolvido em *python*, com publicação em *API*¹ e treinamento mensal dos modelos. A seguir, detalham-se cada etapa do processo:

3.1 Coleta e Pré-processamento de dados

Os dados utilizados no sistema foram estruturados com várias chaves importantes, como o pilar de atuação (por exemplo, psicológico, social, legal etc.), a abordagem (individual, casal, familiar ou em grupo), a clientela (adultos, crianças etc.), o idioma, o código postal, a modalidade de atendimento (online ou presencial), a formação do provedor (por exemplo, psicologia, psiquiatra, assistente social, advogado etc.), a gravidade do caso. Esses dados foram coletados de diversas fontes e passaram por um processo de limpeza e normalização para garantir a consistência e a qualidade das informações.

3.2 Desenvolvimento do Modelo

Utilizou-se *python* como linguagem principal para o desenvolvimento do modelo de recomendação. As bibliotecas principais incluíram *pandas* para manipulação de dados, *scikit-learn* para algoritmos de aprendizado de máquina.

3.3 Publicação em *API*¹

Para facilitar o acesso e a integração do SR com outras plataformas, desenvolveu-se uma *API*¹. Utilizou-se o *framework*² *flask* para criar *endpoints*³ que permitem a consulta e a atualização dos dados, bem como a obtenção de recomendações em tempo real.

3.4 Treinamento

O modelo de recomendação é treinado mensalmente para incorporar novos dados e melhorar a precisão das recomendações. Durante o treinamento, o modelo é ajustado para considerar as mudanças nas preferências dos usuários e nas características dos provedores de serviços.

²estrutura de suporte que serve como base para o desenvolvimento de software

³ponto de acesso específico onde as solicitações de *API*¹ são recebidas e processadas

3.5 Algoritmos de Recomendação

Implementou-se o algoritmo da distância de cosseno, amplamente recomendado para medir a similaridade entre vetores em espaços de alta dimensão, sendo particularmente eficaz em tarefas de mineração de texto e recomendação de conteúdo. Ao focar no ângulo entre vetores, em vez de sua magnitude, a fórmula da distância de cosseno permite identificar padrões e relações sem se preocupar com a escala dos dados. Essa medida é frequentemente utilizada em SR, onde a similaridade entre itens ou usuários é fundamental para sugerir conteúdos relevantes.

A distância dos cossenos entre dois vetores **A** e **B** é dada pela fórmula:

$$\text{dist}_{\text{cos}}(\mathbf{A}, \mathbf{B}) = 1 - \frac{\mathbf{A} \cdot \mathbf{B}}{\|\mathbf{A}\| \|\mathbf{B}\|}$$

onde $\mathbf{A} \cdot \mathbf{B}$ é o produto escalar dos vetores e $\|\mathbf{A}\|$ e $\|\mathbf{B}\|$ são as normas (ou magnitudes) dos vetores.

Por fim, implementou-se uma filtragem híbrida.

3.6 Exemplo de Uso

Quando um usuário solicita uma recomendação, o sistema processa as informações fornecidas, como o pilar de atuação, a abordagem, a clientela, o idioma, o código postal, a modalidade de atendimento, a formação do provedor, a gravidade do caso e a informa a quantidade de recomendações desejadas. Com base nesses dados, o sistema retorna uma lista de provedores de serviços que melhor atendem às necessidades especificadas, priorizando critérios pré-estabelecidos.

GET	/api/recomendador/ chamada principal do recomendador
Body	application/json
<pre>{ "Protocolo": "aabbc", "Pilar": "Psicologico", "Abordagem": "Individual", "Clientela": "Adultos", "Idioma": "Portugues", "CEP": "066123-001", "Modalidade": "Online", "Formacao": "Psicologia", "Gravidade": "Moderado" }</pre>	
Response	application/json
200 ok	<pre>{ "Protocolo": "aabbc", "Recomendacao": [{ "ordem": "1", "Nome": "IDM - INSTITUTO DE DIAGNOSTICO MULTI PROFISSIONAL", "Codigo": "PSC2617" }] }</pre>

⁴escolha de forma tradicional

4 Resultados

Os resultados do nosso SR de provedores foram notáveis, especialmente em termos de economia de custos e satisfação do usuário. Ao comparar o desempenho do nosso sistema com a escolha tradicional de provedores, utilizado de janeiro a dezembro de 2024, observamos uma economia de 12,84% no valor dos serviços prestados. Já a satisfação dos usuários passou de 53,33% satisfeitos para mais de 63% um aumento de 18,43%. A probabilidade de recomendar a empresa aumentou 1,3% e a satisfação com o acesso aumentou 14,03%.

4.1 Economia dos custos

A análise dos resultados na Tabela 1, mostrou que, ao utilizar nosso SR, a empresa conseguiu reduzir significativamente os custos associados à contratação de provedores de serviços. Essa economia de 12,84% foi alcançada graças à capacidade do nosso modelo de identificar provedores que oferecem um excelente equilíbrio entre custo e qualidade, sem comprometer a eficácia do serviço prestado.

Provedor escolhido ⁴	R\$ 44.751,60
Provedor na 1ª escolha do SR	R\$ 39.007,20
Economia R\$	R\$ 5.744,40
Economia (%)	12,84%

Tabela 1: Resultado financeiro

4.2 Respostas dos usuários

As respostas dos usuários nas Tabelas 2, 3 e 4 também aumentaram significativamente. Os resultados foram coletados por e-mail e de forma opcional a todos os usuários de provedores, sejam eles escolhidos de forma tradicional ou pelo recomendador de provedores, indicaram que os usuários estão fortemente satisfeitos em 53,33% da forma tradicional e 63,16% com os provedores escolhidos pelo recomendador de provedores. A relevância das recomendações fornecidas e a capacidade de encontrar provedores de serviços que atendem às suas necessidades específicas resultou em uma experiência mais positiva e eficiente.

Qual a probabilidade de você recomendar a empresa para outras pessoas?

Não utilizou um provedor recomendado	92,0%
Utilizou um provedor recomendado	93,2%
Variação (%)	1,3%

Tabela 2: Recomendação

No Geral, qual é o seu grau de satisfação com os serviços prestados pela empresa?

Não utilizou um provedor recomendado	53,33%
Utilizou um provedor recomendado	63,16%
Variação (%)	18,43%

Tabela 3: Satisfação

Quão satisfeito você ficou com o acesso aos serviços?	
Não utilizou um provedor recomendado	60,0%
Utilizou um provedor recomendado	68,4%
Variação (%)	14,03%

Tabela 4: Acesso

4.3 Melhoria contínua

Ao comparar nosso sistema com o modelo tradicional utilizado no início de 2024, ficou claro que nossa abordagem baseada em CD oferece vantagens substanciais. Além da economia de custos, nosso sistema apresentou uma taxa de satisfação do usuário satisfatória.

O treinamento mensal do modelo permite que o sistema se adapte continuamente às mudanças nas preferências dos usuários e nas características dos provedores de serviços. Isso garante que as recomendações permaneçam precisas e relevantes ao longo do tempo.

Em resumo, nosso SR de provedores de serviços não apenas oferece uma solução eficiente e personalizada, mas também proporciona uma economia significativa de custos. Esses resultados destacam o valor da aplicação de ciência de dados na recomendação de serviços e demonstram o potencial de inovação e melhoria contínua nessa área.

5 Conclusão

Nesta pesquisa, apresentamos uma solução inovadora para a recomendação de provedores de serviços, utilizando técnicas avançadas de ciência de dados. Desenvolvemos um sistema robusto em *python*, disponibilizado

por meio de uma *API*¹, que é treinado mensalmente para garantir a precisão e relevância das recomendações.

Nossa solução oferece uma economia média de 12,84% no valor dos serviços recomendados, comparado ao sistema tradicional, de janeiro a dezembro de 2024. Além da redução de custos, o sistema proporciona recomendações altamente precisas e personalizadas, aumentando significativamente a satisfação dos usuários. A metodologia envolveu a coleta e pré-processamento de dados detalhados, o desenvolvimento de algoritmos de filtragem colaborativa e baseada em conteúdo, e a avaliação contínua do desempenho do sistema. A publicação em *API*¹ facilita a integração com outras plataformas, tornando o sistema acessível e fácil de usar.

O valor agregado ao serviço vai além da simples economia de custos. Nosso sistema melhora a eficiência operacional ao automatizar o processo de recomendação, permitindo que as empresas se concentrem em atividades estratégicas de maior valor. Além disso, a personalização das recomendações garante que os usuários encontrem provedores que atendam exatamente às suas necessidades, resultando em uma experiência mais satisfatória e confiável.

Em resumo, a aplicação de ciência de dados na recomendação de provedores de serviços mostrou-se altamente eficaz, oferecendo benefícios tangíveis tanto em termos de economia de custos quanto de satisfação do usuário. Este documento destaca o valor dessa abordagem e abre caminho para futuras inovações e melhorias contínuas no campo da recomendação de serviços. Estamos apenas começando a explorar o potencial dessas tecnologias, e o futuro promete ainda mais avanços e descobertas.

Referências

- Nicholas J. Belkin and W. Bruce Croft. Information filtering and information retrieval: two sides of the same coin? *Commun. ACM*, 35(12):29–38, December 1992. ISSN 0001-0782. doi: 10.1145/138859.138861. URL <https://doi.org/10.1145/138859.138861>.
- Eliseo Reategui and Silvio Cazella. Sistemas de recomendação. *XXV Congresso da Sociedade Brasileira de Computação*, page 319, 01 2005.
- Paul Resnick and Hal R. Varian. Recommender systems. *Commun. ACM*, 40(3):56–58, March 1997. ISSN 0001-0782. doi: 10.1145/245108.245121. URL <https://doi.org/10.1145/245108.245121>.
- pandas. pandas: powerful python data analysis toolkit, version 1.4.4. <https://pandas.pydata.org>. Accessed: 2024-12-30.
- flask. Flask (version 1.1.2) [computer software]. <https://flask.palletsprojects.com>. Accessed: 2024-12-30.
- python. Python language reference, version 3.8. <https://www.python.org>. Accessed: 2024-12-30.
- scikit-learn. Scikit-learn: Machine learning in python, version 1.1.0. <https://scikit-learn.org>. Accessed: 2024-12-30.