

Aula 4 – Filtragem Colaborativa Baseada em Memória (User-Based)

Você já parou para pensar como plataformas como Netflix, Amazon ou Spotify conseguem adivinhar o que você pode gostar, mesmo antes de você saber? Não é mágica, é ciência de dados! No mundo digital de hoje, onde somos bombardeados por escolhas, os sistemas de recomendação se tornaram nossos guias confiáveis, ajudando-nos a navegar por um oceano de filmes, músicas, produtos e até mesmo notícias. Eles transformam a sobrecarga de informação em uma experiência personalizada e relevante.

Imagine que você acabou de assistir a um filme e adorou. Automaticamente, a plataforma sugere outros títulos que parecem ter tudo a ver com seu gosto. Essa experiência não só nos poupa tempo, mas também nos conecta a conteúdos e produtos que talvez nunca encontrássemos por conta própria, enriquecendo nossa jornada digital. Mas como exatamente essas sugestões são geradas? Como a máquina "entende" o que nos agrada?

Nesta aula, vamos mergulhar em uma das abordagens mais intuitivas e fundamentais dos sistemas de recomendação: a Filtragem Colaborativa Baseada em Memória, com foco na perspectiva do usuário (User-Based). Nosso objetivo é que, ao final, você compreenda o princípio por trás dessa técnica, saiba como os algoritmos identificam usuários com gostos semelhantes e entenda os desafios de aplicá-la em larga escala. Prepare-se para desvendar os segredos por trás das recomendações que moldam sua experiência online.

O Princípio Fundamental

"Diga-me com quem andas..."

A ideia central da Filtragem Colaborativa Baseada em Memória (User-Based) é tão simples quanto um ditado popular: "Diga-me com quem andas e eu te direi quem és". No contexto dos sistemas de recomendação, isso se traduz em: **"usuários que gostaram das mesmas coisas que você, podem ter gostos semelhantes"**. É uma abordagem que se baseia na sabedoria coletiva, ou seja, nas interações e preferências de uma comunidade de usuários para fazer sugestões individuais.

Observação Social

O sistema observa o comportamento de milhares de pessoas


Identificação de Grupos

Identifica grupos com afinidades semelhantes

Recomendação Guiada

Usa essas afinidades para guiar suas recomendações

Pense em um grupo de amigos. Se você e seu amigo João gostam dos mesmos tipos de filmes de ação e ambos adoraram o último lançamento de ficção científica, é bem provável que, se João assistir a um novo filme de aventura e gostar, você também gostará. O sistema de recomendação User-Based tenta replicar essa lógica social, encontrando "amigos" virtuais com padrões de gosto parecidos e usando as preferências desses "amigos" para prever o que você pode querer.

 **Ponto-chave:** Essa abordagem é poderosa porque não exige que o sistema "entenda" o conteúdo do item em si (se é um filme de ação, um livro de romance ou um tipo específico de café). Em vez disso, ela se concentra nas relações entre os usuários e suas avaliações.

A Jornada do Algoritmo User-Based: Um Passo a Passo

Para transformar essa ideia intuitiva em um algoritmo funcional, precisamos de um processo estruturado. O User-Based Collaborative Filtering segue uma série de etapas lógicas para identificar usuários semelhantes e, a partir daí, gerar recomendações. É como um detetive que busca pistas no comportamento de um grupo para resolver um mistério de preferência individual.

01

Coleta de Dados e Representação

O sistema coleta todas as interações dos usuários com os itens. Isso pode ser uma nota de 1 a 5 estrelas para um filme, um "curtir" em uma música, ou a compra de um produto.

02

Organização em Matriz

Esses dados são geralmente organizados em uma matriz de usuário-item, onde as linhas representam os usuários, as colunas representam os itens, e os valores nas células são as avaliações.

03

Cálculo de Similaridade

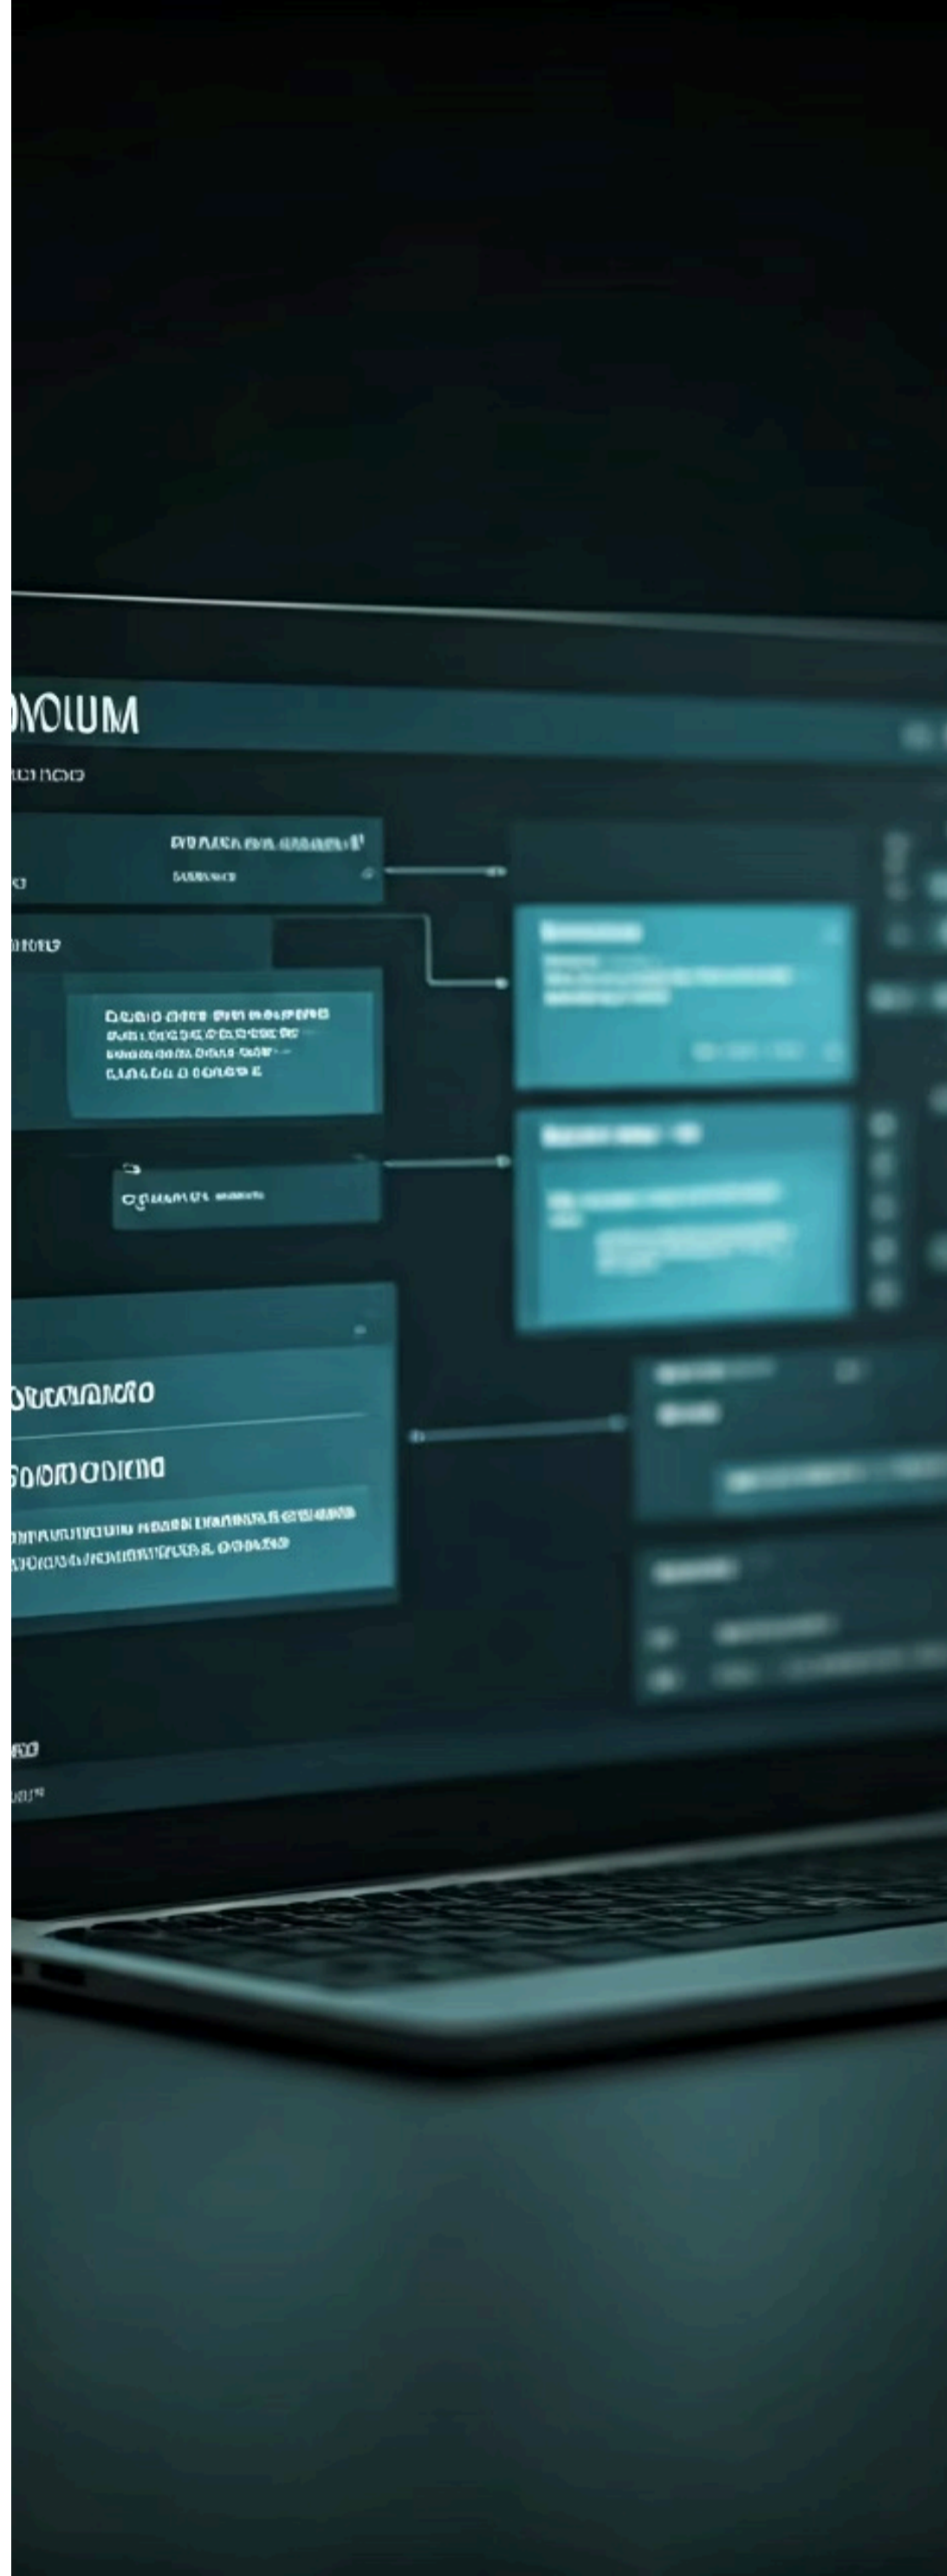
O algoritmo calcula a similaridade entre usuários usando métricas matemáticas específicas.

04

Geração de Recomendações

Com base nos vizinhos mais semelhantes, o sistema prevê avaliações e sugere novos itens.

Primeiramente, o sistema precisa de dados. Muitos dados! Ele coleta as interações dos usuários com os itens, que podem ser avaliações explícitas (estrelas, notas) ou implícitas (cliques, tempo de visualização, compras). Esses dados são a base para construir o "perfil" de gosto de cada pessoa. Sem essa informação, o algoritmo não teria como começar a traçar paralelos entre os usuários.



Encontrando Seus "Vizinhos": O Cálculo de Vizinhança

Depois de organizar os dados, o próximo passo crucial é identificar quem são os "vizinhos" de um determinado usuário. No contexto da filtragem colaborativa, vizinhos são outros usuários que demonstraram padrões de gosto muito semelhantes. É como procurar pessoas em uma festa que riram das mesmas piadas que você, ou que têm opiniões parecidas sobre os filmes que acabaram de ser lançados.

Para encontrar esses vizinhos, o algoritmo precisa de uma maneira de medir a "distância" ou "similaridade" entre os perfis de gosto de dois usuários. Não estamos falando de distância geográfica, mas sim de quão alinhadas são suas preferências.



Seleção do Usuário Alvo

Escolhemos o usuário para quem queremos gerar recomendações (vamos chamá-lo de "Usuário Ativo").



Identificação de Itens em Comum

Para cada outro usuário no sistema, identificamos quais itens foram avaliados tanto pelo Usuário Ativo quanto por esse outro usuário.

$$\frac{f}{dx}$$

Cálculo da Similaridade

Usamos uma métrica matemática para quantificar o quão semelhantes são os gostos do Usuário Ativo e de cada um dos outros usuários.

Métricas de Similaridade Mais Comuns



Correlação de Pearson

Mede a correlação linear entre as avaliações de dois usuários. É boa para dados onde a escala de avaliação importa e os usuários podem ter diferentes "níveis" de avaliação.



Similaridade de Cosseno

Mede o cosseno do ângulo entre os vetores de avaliação de dois usuários. É útil para dados esparsos e trata as avaliações como direções no espaço.



Similaridade Euclidiana

Mede a distância geométrica entre os pontos de avaliação dos usuários. Quanto menor a distância, maior a similaridade.

Aprofundando no Cálculo de Similaridade: Correlação de Pearson

Entre as métricas de similaridade, a Correlação de Pearson é uma das mais utilizadas e robustas, especialmente quando lidamos com avaliações de usuários. Ela não apenas verifica se dois usuários gostaram ou não dos mesmos itens, mas também considera a "intensidade" desse gosto e, mais importante, a tendência geral de avaliação de cada usuário.

Imagine que você e seu amigo têm gostos muito parecidos para filmes. Ambos adoram comédias e detestam dramas. No entanto, você é mais generoso com suas notas (dá muitos 4s e 5s), enquanto seu amigo é mais crítico (dá muitos 2s e 3s, mesmo para filmes que ele gostou). A Correlação de Pearson consegue "normalizar" essas diferenças de escala, focando na tendência relativa das avaliações.

Vantagem Principal: Ela mede se, quando você gosta de um filme, seu amigo também tende a gostar, e vice-versa, independentemente de um dar uma nota 5 e o outro uma nota 3.

-1

Correlação Negativa

Gostos opostos

0

Sem Correlação

Nenhuma relação

+1

Correlação Positiva

Gostos idênticos

Exemplo Prático: Correlação de Pearson

Considere dois usuários, Alice e Bob, que avaliaram os seguintes filmes:

| Filme | Alice (Avaliação) | Bob (Avaliação) |
|-----------|-------------------|-----------------|
| Ação 1 | 5 | 4 |
| Comédia 2 | 3 | 2 |
| Drama 3 | 2 | 1 |
| Ficção 4 | 4 | 3 |

Para calcular a Correlação de Pearson, primeiro calculamos a média das avaliações de cada usuário para os itens em comum: Média de Alice: $(5+3+2+4) / 4 = 3.5$ | Média de Bob: $(4+2+1+3) / 4 = 2.5$

Em seguida, subtraímos a média de cada avaliação e multiplicamos os desvios, somamos e dividimos pelo produto dos desvios padrão. O cálculo completo ajusta as avaliações pela média de cada usuário, focando na co-ocorrência dos desvios.

Outra Perspectiva: Similaridade de Cosseno

Enquanto a Correlação de Pearson é excelente para capturar a relação linear entre as avaliações, a Similaridade de Cosseno oferece uma perspectiva ligeiramente diferente, focando na "direção" dos vetores de avaliação. Ela é particularmente útil em cenários onde a magnitude das avaliações pode não ser tão importante quanto o padrão geral de preferência, ou quando os dados são muito esparsos (muitos itens não avaliados).



Cada usuário = ponto no espaço

Cada dimensão representa um item



Medição do ângulo

Ângulo pequeno = gostos semelhantes



Foco na proporção

Não na magnitude absoluta

Exemplo Prático

Usando os mesmos dados de Alice e Bob:

- Vetor de Alice: [5, 3, 2, 4]
- Vetor de Bob: [4, 2, 1, 3]

Fórmula: $\text{Sim}(A, B) = (A \cdot B) / (||A|| * ||B||)$



Cálculo Detalhado

- $A \cdot B = 5 \times 4 + 3 \times 2 + 2 \times 1 + 4 \times 3 = 40$
- $||A|| = \sqrt{25 + 9 + 4 + 16} \approx 7.35$
- $||B|| = \sqrt{16 + 4 + 1 + 9} \approx 5.48$
- **Resultado: $40 / 40.278 \approx 0.993$**

Um valor muito próximo de 1 indica uma alta similaridade!

Essa métrica é menos sensível a diferenças absolutas nas escalas de avaliação e mais focada na proporção das avaliações. Por exemplo, se um usuário avalia todos os filmes que gosta com 5 estrelas e outro com 3 estrelas, mas ambos gostam dos mesmos filmes, a Similaridade de Cosseno ainda os considerará muito semelhantes.

Pearson vs. Cosseno: Qual Escolher?

A escolha entre Correlação de Pearson e Similaridade de Cosseno não é trivial e depende muito do contexto e das características dos seus dados. Ambas são ferramentas poderosas, mas atuam de maneiras ligeiramente diferentes, como dois tipos de bússolas que, embora apontem para o norte, usam princípios distintos para fazê-lo.

Correlação de Pearson

É particularmente boa quando você tem usuários que tendem a ser mais "generosos" ou mais "críticos" em suas avaliações. Ela normaliza essas tendências, focando na relação *relativa* entre as avaliações. Se um usuário sempre dá notas altas e outro sempre dá notas baixas, mas ambos concordam sobre quais itens são bons e quais são ruins, Pearson pode capturar essa similaridade subjacente.

Similaridade de Cosseno

Brilha em cenários onde a esparsidade dos dados é um problema comum – ou seja, quando a maioria dos usuários avaliou apenas uma pequena fração dos itens disponíveis. Ela é menos sensível a esses "buracos" na matriz de avaliações e foca na direção geral das preferências. Além disso, é computacionalmente mais eficiente em alguns casos, o que é uma vantagem em sistemas com milhões de usuários e itens.

Quadro Comparativo

| Característica | Correlação de Pearson | Similaridade de Cosseno |
|----------------------|---------------------------------------------------------------|-----------------------------------------------------------------|
| Base | Mede a correlação linear entre desvios da média | Mede o cosseno do ângulo entre vetores de avaliação |
| Normalização | Normaliza as avaliações pela média do usuário | Não normaliza pela média, foca na direção do vetor |
| Sensibilidade | Sensível a tendências de avaliação (generoso/crítico) | Menos sensível a diferenças absolutas na escala |
| Uso Ideal | Dados densos, onde a escala de avaliação varia entre usuários | Dados esparsos, onde a direção da preferência é mais importante |
| Intervalo | [-1, 1] | [0, 1] (se avaliações não negativas) |

Dica Prática: A decisão final muitas vezes envolve experimentação. Testar ambas as métricas e avaliar a qualidade das recomendações geradas é a melhor forma de determinar qual se adapta melhor ao seu problema específico.

Gerando Recomendações: A Média Ponderada

Com a lista de vizinhos e seus respectivos pesos de similaridade em mãos, o algoritmo User-Based está pronto para o passo final: prever a avaliação do Usuário Ativo para um item que ele ainda não viu. É como perguntar a um grupo de amigos confiáveis (seus vizinhos) o que eles acharam de um novo restaurante que você está pensando em experimentar.

Essa previsão é feita através de uma média ponderada das avaliações dos vizinhos para o item em questão. Cada avaliação é "pesada" pela similaridade do vizinho com o Usuário Ativo. Quanto mais semelhante o vizinho, maior o peso de sua avaliação na previsão final.

01

Identificar Vizinhos

Para o Usuário Ativo (U_a), encontramos um conjunto N dos k usuários mais semelhantes (vizinhos).

02

Selecionar Itens Não Avaliados

Identificamos os itens que o Usuário Ativo ainda não avaliou, mas que foram avaliados por pelo menos um de seus vizinhos.

03

Prever Avaliação

Para cada item i não avaliado, calculamos uma pontuação prevista usando a fórmula de média ponderada.

04

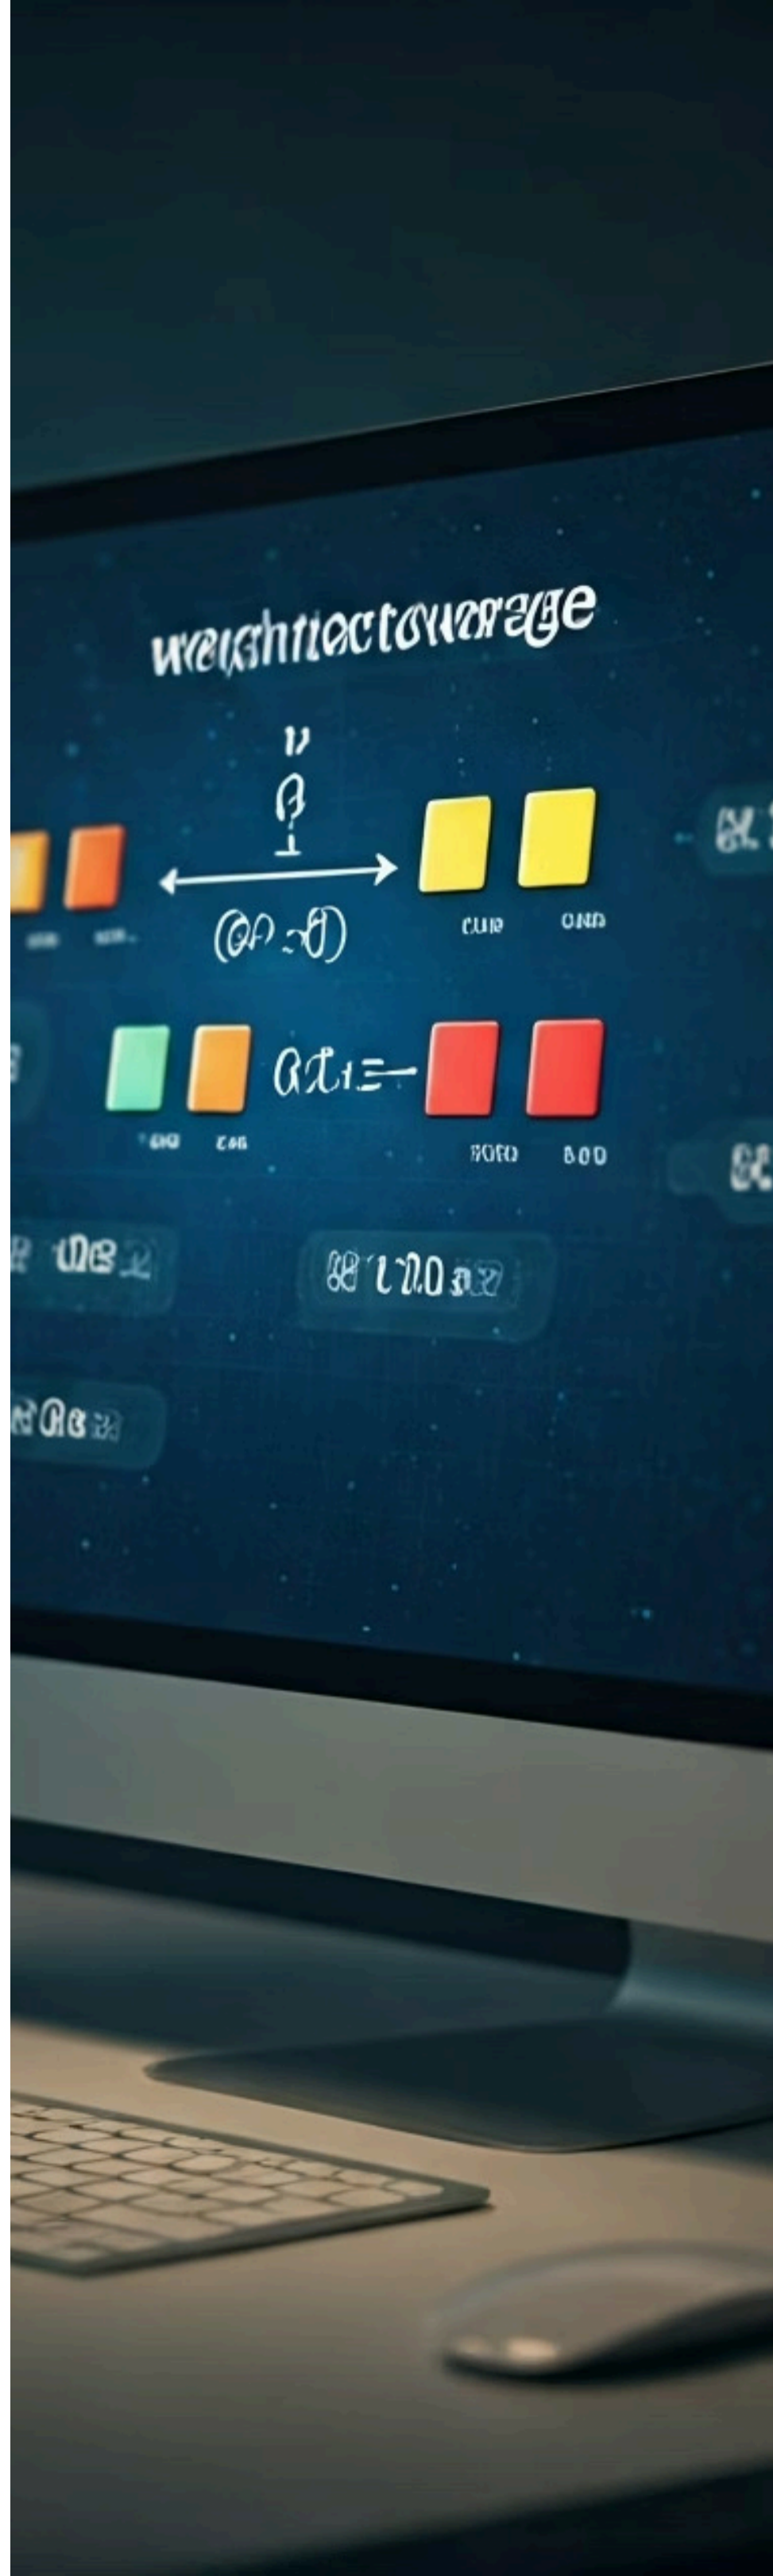
Gerar Lista de Recomendações

Os itens com as maiores pontuações previstas são apresentados ao Usuário Ativo como recomendações.

Fórmula da Média Ponderada

$$P(U_a, i) = \frac{\sum [\text{Sim}(U_a, U_v) \times (\text{Avaliação}(U_v, i) - \text{Média}(U_v))]}{\sum |\text{Sim}(U_a, U_v)|} + \text{Média}(U_a)$$

Essa fórmula ajusta a avaliação do vizinho pela sua própria média, para compensar usuários que avaliam de forma mais generosa ou crítica, e então pondera pelo grau de similaridade.



Um Exemplo Completo de User-Based Collaborative Filtering

Para solidificar o entendimento, vamos percorrer um exemplo simplificado de como um sistema User-Based Collaborative Filtering funcionaria na prática. Imagine uma pequena plataforma de filmes com alguns usuários e suas avaliações. Nosso objetivo é recomendar um filme para o Usuário Ativo, "Carla".

Cenário: Matriz de Avaliações

| Usuário | Filme A | Filme B | Filme C | Filme D | Filme E |
|---------|---------|---------|---------|---------|---------|
| Carla | 5 | ? | 4 | ? | 3 |
| João | 4 | 3 | 5 | 2 | 4 |
| Maria | 5 | 4 | 3 | 1 | 2 |
| Pedro | 3 | 2 | 4 | 5 | 1 |



Passo 1: Encontrar Vizinhos de Carla

- **Carla vs. João:** Similaridade (Pearson) ≈ 0.85 (alta)
- **Carla vs. Maria:** Similaridade (Pearson) ≈ 0.95 (muito alta)
- **Carla vs. Pedro:** Similaridade (Pearson) ≈ -0.5 (baixa/negativa)

Maria é a vizinha mais próxima de Carla, seguida por João.



Passo 2: Prever Avaliação para Filme B

Vizinhos que avaliaram Filme B: João (3), Maria (4), Pedro (2)

Média de Carla = 4

Cálculo: $P(\text{Carla}, B) = 4 + [(0.85 \times -1.33) + (0.95 \times 0.67) + (-0.5 \times -0.67)] / 2.3$

Resultado: ≈ 3.93



Passo 3: Prever Avaliação para Filme D

Vizinhos que avaliaram Filme D: João (2), Maria (1), Pedro (5)

Média de Carla = 4

Cálculo: $P(\text{Carla}, D) = 4 + [(0.85 \times -2.33) + (0.95 \times -2.33) + (-0.5 \times 2.33)] / 2.3$

Resultado: ≈ 1.68

Conclusão

O sistema preveria que Carla daria uma nota de aproximadamente **3.93 para o Filme B** e **1.68 para o Filme D**. Portanto, o Filme B seria recomendado a ela, enquanto o Filme D provavelmente não.

Limitações e Desafios de Escalabilidade da Abordagem

Apesar de sua simplicidade e intuição, a Filtragem Colaborativa Baseada em Memória (User-Based) enfrenta desafios significativos, especialmente quando aplicada a sistemas do mundo real com milhões de usuários e itens. É como tentar organizar uma festa para milhares de pessoas: a ideia é boa, mas a logística se torna um pesadelo.

Custo Computacional Elevado

Problema: Calcular a similaridade entre um usuário e *todos* os outros usuários, e depois prever avaliações para *todos* os itens não avaliados, é extremamente custoso em sistemas com muitos usuários e itens. A complexidade cresce quadraticamente com o número de usuários.

Impacto: Dificulta a aplicação em tempo real e em larga escala, pois as recomendações demorariam muito para serem geradas.

Problema do Cold Start (Usuário Novo)

Problema: Se um usuário é novo no sistema e ainda não avaliou muitos itens, o algoritmo não tem dados suficientes para encontrar vizinhos semelhantes ou para calcular similaridades de forma confiável.

Impacto: Novos usuários não recebem recomendações personalizadas, o que pode levar à frustração e à desistência.

Problema do Cold Start (Item Novo)

Problema: Itens recém-adicionados ao sistema (um novo filme, um novo produto) não têm avaliações de usuários. Consequentemente, não podem ser recomendados, pois não há dados para calcular a similaridade ou prever avaliações.

Impacto: Itens novos demoram a ganhar visibilidade, mesmo que sejam de alta qualidade.

Esparsidade dos Dados

Problema: A maioria dos usuários avalia apenas uma pequena fração dos itens disponíveis. A matriz de usuário-item é, portanto, muito esparsa (cheia de zeros ou valores ausentes).

Impacto: Dificulta a identificação de itens em comum entre usuários e a obtenção de similaridades robustas, levando a recomendações imprecisas.

"Shilling Attacks" (Ataques de Manipulação)


Problema: Usuários mal-intencionados podem criar perfis falsos e avaliar itens de forma estratégica para manipular as recomendações (por exemplo, inflacionar a avaliação de seus próprios produtos ou prejudicar a concorrência).

Impacto: Comprometimento da integridade e confiança do sistema de recomendação.

Evolução para **Deep Learning**: Superando Limitações com Embeddings

As limitações da filtragem colaborativa baseada em memória, especialmente a esparsidade e a escalabilidade, impulsionaram a pesquisa para abordagens mais sofisticadas. Uma das evoluções mais impactantes veio do campo do Deep Learning, com a adoção massiva de redes neurais, e em particular, a técnica de **Embeddings**.

Imagine que, em vez de comparar diretamente as avaliações de usuários, pudéssemos representar cada usuário e cada item como um ponto em um espaço vetorial de alta dimensão. Nesse espaço, usuários com gostos semelhantes estariam próximos uns dos outros, e itens semelhantes também estariam próximos. Essa representação compacta e densa é o que chamamos de "embedding". É como transformar as complexas preferências de um usuário em um "DNA digital" que pode ser facilmente comparado com o DNA de outros usuários ou itens.




Deep Learning e Embeddings: Uma Nova Era



O que são Embeddings

São representações vetoriais densas de usuários e itens em um espaço de baixa dimensão. Cada dimensão do vetor pode representar uma característica latente (não observável diretamente) do usuário ou item.



Como funcionam

Redes neurais são treinadas para aprender esses embeddings. Por exemplo, um modelo pode tentar prever se um usuário gostará de um item, e no processo de aprendizado, ele ajusta os vetores de embedding.

Vantagens dos Embeddings

Lidam com Esparsidade

Embeddings conseguem generalizar a partir de poucas interações, preenchendo os "buracos" da matriz de usuário-item.

Escalabilidade

Uma vez que os embeddings são gerados, a similaridade pode ser calculada rapidamente, e a busca por vizinhos se torna muito mais eficiente.

Capturam Relações Complexas

Redes neurais podem aprender padrões não lineares e interações sutis que métodos mais simples não conseguiriam.

Incorporam Informações Contextuais

Além das interações, embeddings podem incorporar metadados de itens (gênero, diretor) e de usuários (idade, localização), enriquecendo as representações.

Recommendation as a Service (RaaS) e MLOps: A Operacionalização

A evolução dos algoritmos de recomendação não se limita apenas à sofisticação matemática; ela também abrange a forma como esses sistemas são construídos, implantados e mantidos em produção. Aqui entram conceitos como **Recommendation as a Service (RaaS)** e **MLOps**, que são cruciais para transformar modelos de pesquisa em soluções robustas e escaláveis no mundo real.

Recommendation as a Service (RaaS)

Conceito: Provedores de nuvem oferecem APIs e ferramentas para construir e integrar sistemas de recomendação.

Benefícios: Reduz a complexidade e o custo de desenvolvimento, acelera a implantação, permite escalabilidade sob demanda.

Exemplos: Amazon Personalize (AWS), Google Cloud Recommendations AI, Azure Personalizer.




MLOps (Machine Learning Operations)

Conceito: Disciplina que aplica princípios de DevOps ao Machine Learning, cobrindo todo o ciclo de vida do modelo.

Importância: Garante que os sistemas de recomendação sejam robustos, confiáveis, escaláveis e que suas recomendações permaneçam relevantes ao longo do tempo.

Etapas Chave do MLOps



Experimentação

Gerenciamento de experimentos, controle de versão



Treinamento

Automação do treinamento e validação



Implantação

Colocação do modelo em produção




Monitoramento

Acompanhamento de desempenho



Retreinamento

Atualização com novos dados



Ética e Responsabilidade (**Responsible AI**): O Lado Humano da IA

À medida que os sistemas de recomendação se tornam mais poderosos e onipresentes, a preocupação com suas implicações éticas e sociais cresce exponencialmente. Não basta que um sistema seja tecnicamente eficiente; ele também precisa ser justo, transparente e responsável. A área de **Ética e Responsabilidade (Responsible AI)** surge para abordar essas questões, garantindo que a inteligência artificial sirva à humanidade de forma benéfica.



Viés (Bias)

O que é: Tendências ou preconceitos indesejados nos dados de treinamento que levam o modelo a fazer recomendações injustas ou discriminatórias.

Exemplos: Recomendar apenas filmes de ação para homens e filmes de romance para mulheres, ou não recomendar produtos de nicho para certos grupos demográficos.

Mitigação: Auditoria de dados, técnicas de debiasing em algoritmos, diversidade nas recomendações.



Justiça (Fairness)

O que é: Garantir que as recomendações sejam equitativas e não discriminatórias para diferentes grupos de usuários ou itens.

Tipos de Justiça:

- **Justiça para o Usuário:** Todos os usuários recebem recomendações de qualidade similar.
- **Justiça para o Item:** Todos os itens (ou grupos de itens) têm uma chance justa de serem recomendados.



Transparência e Explicabilidade

O que é: Capacidade de entender como e por que uma recomendação foi feita.

Importância: Constrói confiança do usuário, ajuda a depurar vieses e aprimorar o sistema.



Responsabilidade

O que é: O compromisso de projetar, desenvolver e implantar sistemas de recomendação que sejam seguros, confiáveis e benéficos para a sociedade.

Implicações: Considerar o impacto social, econômico e cultural das recomendações.

- ❑ **Reflexão Importante:** Um dos maiores desafios é o viés. Os sistemas de recomendação aprendem com dados históricos, e se esses dados refletem preconceitos sociais existentes, o sistema pode perpetuar e até amplificar esses vieses em suas recomendações.

O Futuro da Filtragem Colaborativa: **Híbridos e Contexto**

A Filtragem Colaborativa Baseada em Memória (User-Based) é um pilar fundamental, mas o campo dos sistemas de recomendação está em constante evolução. As abordagens mais modernas frequentemente combinam diferentes técnicas para superar as limitações de cada uma.

Sistemas Híbridos

Mesclam a filtragem colaborativa com a filtragem baseada em conteúdo (que analisa as características dos itens) para oferecer recomendações mais robustas e precisas.

Informações Contextuais

Não é apenas "o que" você gostou, mas "quando", "onde" e "com quem" você interagiu com um item. Recomendar um restaurante para o almoço de domingo é diferente de recomendar um para um jantar de negócios na terça-feira.

Deep Learning Avançado

Redes neurais cada vez mais sofisticadas capturam padrões complexos e relações não lineares entre usuários, itens e contextos.

Evolução Contínua

A jornada da filtragem colaborativa nos mostra como uma ideia simples pode ser aprimorada e expandida para lidar com a complexidade do mundo digital. Desde os primeiros algoritmos baseados em vizinhança até as redes neurais e as preocupações éticas, a busca por recomendações perfeitas continua.

📌 **Objetivo Final:** Conectar pessoas aos conteúdos e produtos que realmente importam para elas, sempre com o objetivo de melhorar a experiência do usuário de forma ética e responsável.

Em Prática: Aplicando o Conhecimento

Compreender a Filtragem Colaborativa Baseada em Memória (User-Based) é o primeiro passo para desvendar o funcionamento de muitos sistemas de recomendação que você usa diariamente. Você agora entende como as plataformas buscam usuários com gostos semelhantes aos seus para sugerir novos conteúdos. Essa base é crucial para analisar criticamente as recomendações que recebe e para, futuramente, projetar seus próprios sistemas.

- Lembre-se:** Apesar de suas limitações, a lógica de "vizinhos" é a espinha dorsal de muitas inovações em sistemas de recomendação.

Autoavaliação

Questão 1

Qual o princípio fundamental da Filtragem Colaborativa Baseada em Memória (User-Based)?

1

1. Recomendar itens com base nas características do próprio item.
2. Recomendar itens que são populares entre a maioria dos usuários.
3. Recomendar itens com base nas preferências de usuários com gostos semelhantes.
4. Recomendar itens aleatoriamente para garantir diversidade.

Questão 2

Qual das seguintes métricas é mais adequada para calcular a similaridade entre usuários quando há uma preocupação com a tendência de alguns usuários darem notas consistentemente mais altas ou mais baixas que outros?

2

1. Similaridade Euclidiana
2. Similaridade de Cosseno
3. Correlação de Pearson
4. Distância de Manhattan

Questão 3

Um dos principais desafios da Filtragem Colaborativa Baseada em Memória em sistemas de larga escala é:

3

1. A dificuldade em entender o conteúdo dos itens.
2. O alto custo computacional para calcular similaridades entre todos os usuários.
3. A incapacidade de lidar com avaliações explícitas.
4. A necessidade de muitos metadados sobre os itens.

Questão 4

Como os Embeddings, impulsionados pelo Deep Learning, ajudam a superar as limitações da filtragem colaborativa tradicional?

4

1. Eles eliminam completamente a necessidade de dados de interação.
2. Eles transformam usuários e itens em representações vetoriais densas, facilitando o cálculo de similaridade e a generalização.
3. Eles exigem que os usuários avaliem todos os itens disponíveis.
4. Eles substituem a necessidade de qualquer algoritmo de Machine Learning.

Questão 5 (Dissertativa)

5

Explique como a preocupação com o "viés" (bias) se manifesta em sistemas de recomendação e qual a importância das práticas de "Responsible AI" para mitigar esse problema.

Gabarito

1

Resposta

c) Recomendar itens com base nas preferências de usuários com gostos semelhantes.

2

Resposta

c) Correlação de Pearson

3

Resposta

b) O alto custo computacional para calcular similaridades entre todos os usuários.

4

Resposta

b) Eles transformam usuários e itens em representações vetoriais densas, facilitando o cálculo de similaridade e a generalização.

Próxima Aula

Aula 5 – Filtragem Colaborativa Baseada em Memória (Item-Based)

Na próxima aula, exploraremos uma perspectiva complementar à que vimos hoje. Em vez de buscar usuários semelhantes, focaremos em encontrar **itens semelhantes**, o que traz novas vantagens e desafios. Prepare-se para inverter a lógica e ver como os sistemas podem aprender a partir das relações entre os próprios produtos ou conteúdos.

Recursos Adicionais

- **Artigo Clássico**

"Item-Based Collaborative Filtering Recommendation Algorithms" (B. Sarwar et al., 2001) – Clássico que introduz a abordagem Item-Based.

- **Livro de Referência**

"Recommender Systems: An Introduction" (Dietmar Jannach et al.) – Referência abrangente sobre o tema.

- **Plataformas de Aprendizado**

Coursera ou edX – Cursos de Machine Learning e Sistemas de Recomendação para aprofundamento prático.

NOTA IMPORTANTE: As informações regulatórias/legais/técnicas desta aula estão atualizadas até 2025. Consulte sempre fontes oficiais para verificar alterações.

