

Recomendação de Produtos Financeiros

Unindo Inteligência Artificial ao conhecimento de especialistas



xpinvestimentos.com.br

Conteúdo

- A necessidade por recomendações
- Sistemas de recomendação
- Machine Learning e Otimização
- Criando Recomendações de Carteiras – Pipeline e Resultados



Assessoria Private

A partir de ^{R\$}5 milhões
em investimentos

Equipe altamente especializada
e soluções sob medida.

[Saiba mais](#)



Assessoria Exclusiva

A partir de ^{R\$}300 mil
em investimentos

Relacionamento próximo,
acompanhamento individual e
carteira de investimentos
personalizada.

[Saiba mais](#)



Assessoria On Demand

Entre ^{R\$}50-300 mil
em investimentos

O melhor da experiência XP em
um formato ágil e dinâmico.

[Saiba mais](#)




Assessoria Digital

Até ^{R\$}50 mil
em investimentos

A porta de entrada para uma
nova relação com os seus
investimentos.

[Saiba mais](#)

Otimização




Métricas

Recomendação



Produto

Projeção



Cenário

Conteúdo

- A necessidade por recomendações
- **Sistemas de recomendação**
- Machine Learning e Otimização
- Criando Recomendações de Carteiras – Pipeline e Resultados

Sistemas de recomendação

Para começar, um sisRec é um sistema que normalmente tenta prever um valor X para ser consumido por um usuário Y em um determinado universo U .

NETFLIX

amazon.com[®]



SisRec – Usuários e Itens

Em aplicações de recomendação, lidamos com duas entidades: **Usuários** e **Itens**.

Usuários preferem um determinado item e essa preferência devem ser explicitadas nos dados.

O dado ideal para um SisRec é representado por uma matriz $U \times I$ onde cada célula representa o grau de preferência de um usuário U por um item I , criando uma grande matriz esparsa

	i_1	i_2	\dots	i_k	\dots	i_n
U_1	5	?	...	3	...	4
U_2	?	?	...	4	...	5
\vdots
U_k	2	5	...	?	...	3
\vdots
U_m	5	4	...	2	...	?

Tipos de SisRec

Existem dois tipos básicos de Sistemas de recomendação

- Content Based Filtering: O sistema foca em propriedades dos itens, criando recomendações baseadas em itens parecidos, apenas.
- Collaborative Filtering: O sistema foca no relacionamento entre os usuários com os respectivos itens. Um item é similar a outro se dois usuários similares gostaram dos mesmos.

Content Based Filtering (CB)


- Nesse tipo de filtro, construímos para cada item um **'profile'** que contém informações sobre as características individuais de cada item.
- Se um usuário interage com um determinado item, itens parecidos são sugeridos apenas com base em características similares



Collaborative Filtering (CF)

Recomendações são baseados no comportamento do usuário no passado. Organizamos em duas categorias de CF

- **User-Based:** Tenta medir a similaridade entre o usuário target e outros usuários
- **Item-Based:** Tentar medir a similaridade entre o item que o usuário target interagiu e outros itens



CF – User Based

Calculamos a similaridade entre usuários (**Horizontalmente**)

Métricas normalmente utilizadas para calcular a similaridade user-user ou item-item são: Similaridade de cossenos e Correlação de Pearson

Por exemplo medindo a similaridade de produtos utilizados por usuários (com relação ao usuário E)

	Produto 1	Produto 2	Produto 3	Produto 4	Produto 5	Similaridade (x,E)
A	2	2		4		NA
B	5		4		1	0.87
C		0	5	3		1
D		1	0	5	4	-1
E			4		2	1

Collaborative Filtering (CF)

Agora podemos preencher o resto da tabela para o usuário E

	Produto 1	Produto 2	Produto 3	Produto 4	Produto 5	Similaridade (x,E)
A	2	2		4		NA
B	5		4		1	0.87
C		4	5	1		1
D		1	0	5	4	-1
E	4*	3.5*	4	0.8*	2	1

CF – Item Based

Calculamos a similaridade entre Itens baseado no item em que o usuário target usou (**Verticalmente**)
Por exemplo medindo a similaridade entre itens utilizados por um usuário do Produto 5

	Produto 1	Produto 2	Produto 3	Produto 4	Produto 5
A	2	2		4	2*
B	5		4		1
C		0	5	3	4
D		1	0	5	4
E			4		2
F	4	5		1	1
Sim	-1	-1	0.86	1	NA

Pontos Importantes

- **Cold Start:** Como reagir a um usuário ou item novo que não apresenta nenhuma interação em seu histórico? (CF)
- **Sparsity problem:** Como atualizar constantemente uma matriz gigantesca de milhões de linhas x milhares de colunas (CF)
- **Overfit:** Um sistema de recomendação do tipo (CB) não irá recomendar produtos onde comportamento do usuário não explicita nenhuma evidência sobre o mesmo, causando recomendações óbvias

Pontos Importantes

- Todos os tipos de algoritmos (CB, CFub, CFib) apresentam vantagens e desvantagens, podemos alternar o sistemas entre ele sem apresentar uma solução definitiva para todos os problemas
- Precisamos de um método que consiga derivar tanto o comportamento individual de cada usuário quanto a particularidade de cada item: **Low-Rank Matrix Factorization**

Conteúdo

- A necessidade por recomendações
- Sistemas de recomendação
- **Machine Learning e Otimização**
- Criando Recomendações de Carteiras – Pipeline e Resultados

Machine Learning

- Com nosso dado pronto para um algoritmo supervisionado, a versão final utilizada consiste em vários modelos XGBOOST, um para cada tipo diferente de classificação/recomendação.
- XGBoost “Extreme Gradient Boosting” é atualmente um dos algoritmos dominantes em competições Kaggle, é uma implementação do Gradient Boosted Decision Trees focando na otimização de recursos computacionais, por isso o termo “Extreme”

Otimização

- Com o modelo em mãos já conseguimos criar recomendações de produtos macro mas não ainda de produtos individualizados. É onde entra a parte mais importante do motor de recomendação criado: A otimização de carteira.
- Utilizando a expertise de especialistas, a partir da recomendação gerada para cada usuário na etapa de Machine Learning, regras de negócios dinâmicas são impostas a cada saída do modelo criando a recomendação de carteira final .

Otimização

- Várias métricas são utilizadas para a escolha de um produto. Para fundos de investimentos, por exemplo, é levando em consideração: retorno, volatilidade, DrawDown, consistência, investimento inicial, correlação entre os produtos, liquidez, etc.
- Além de métricas próprias que são feitas por nossos melhores especialistas.

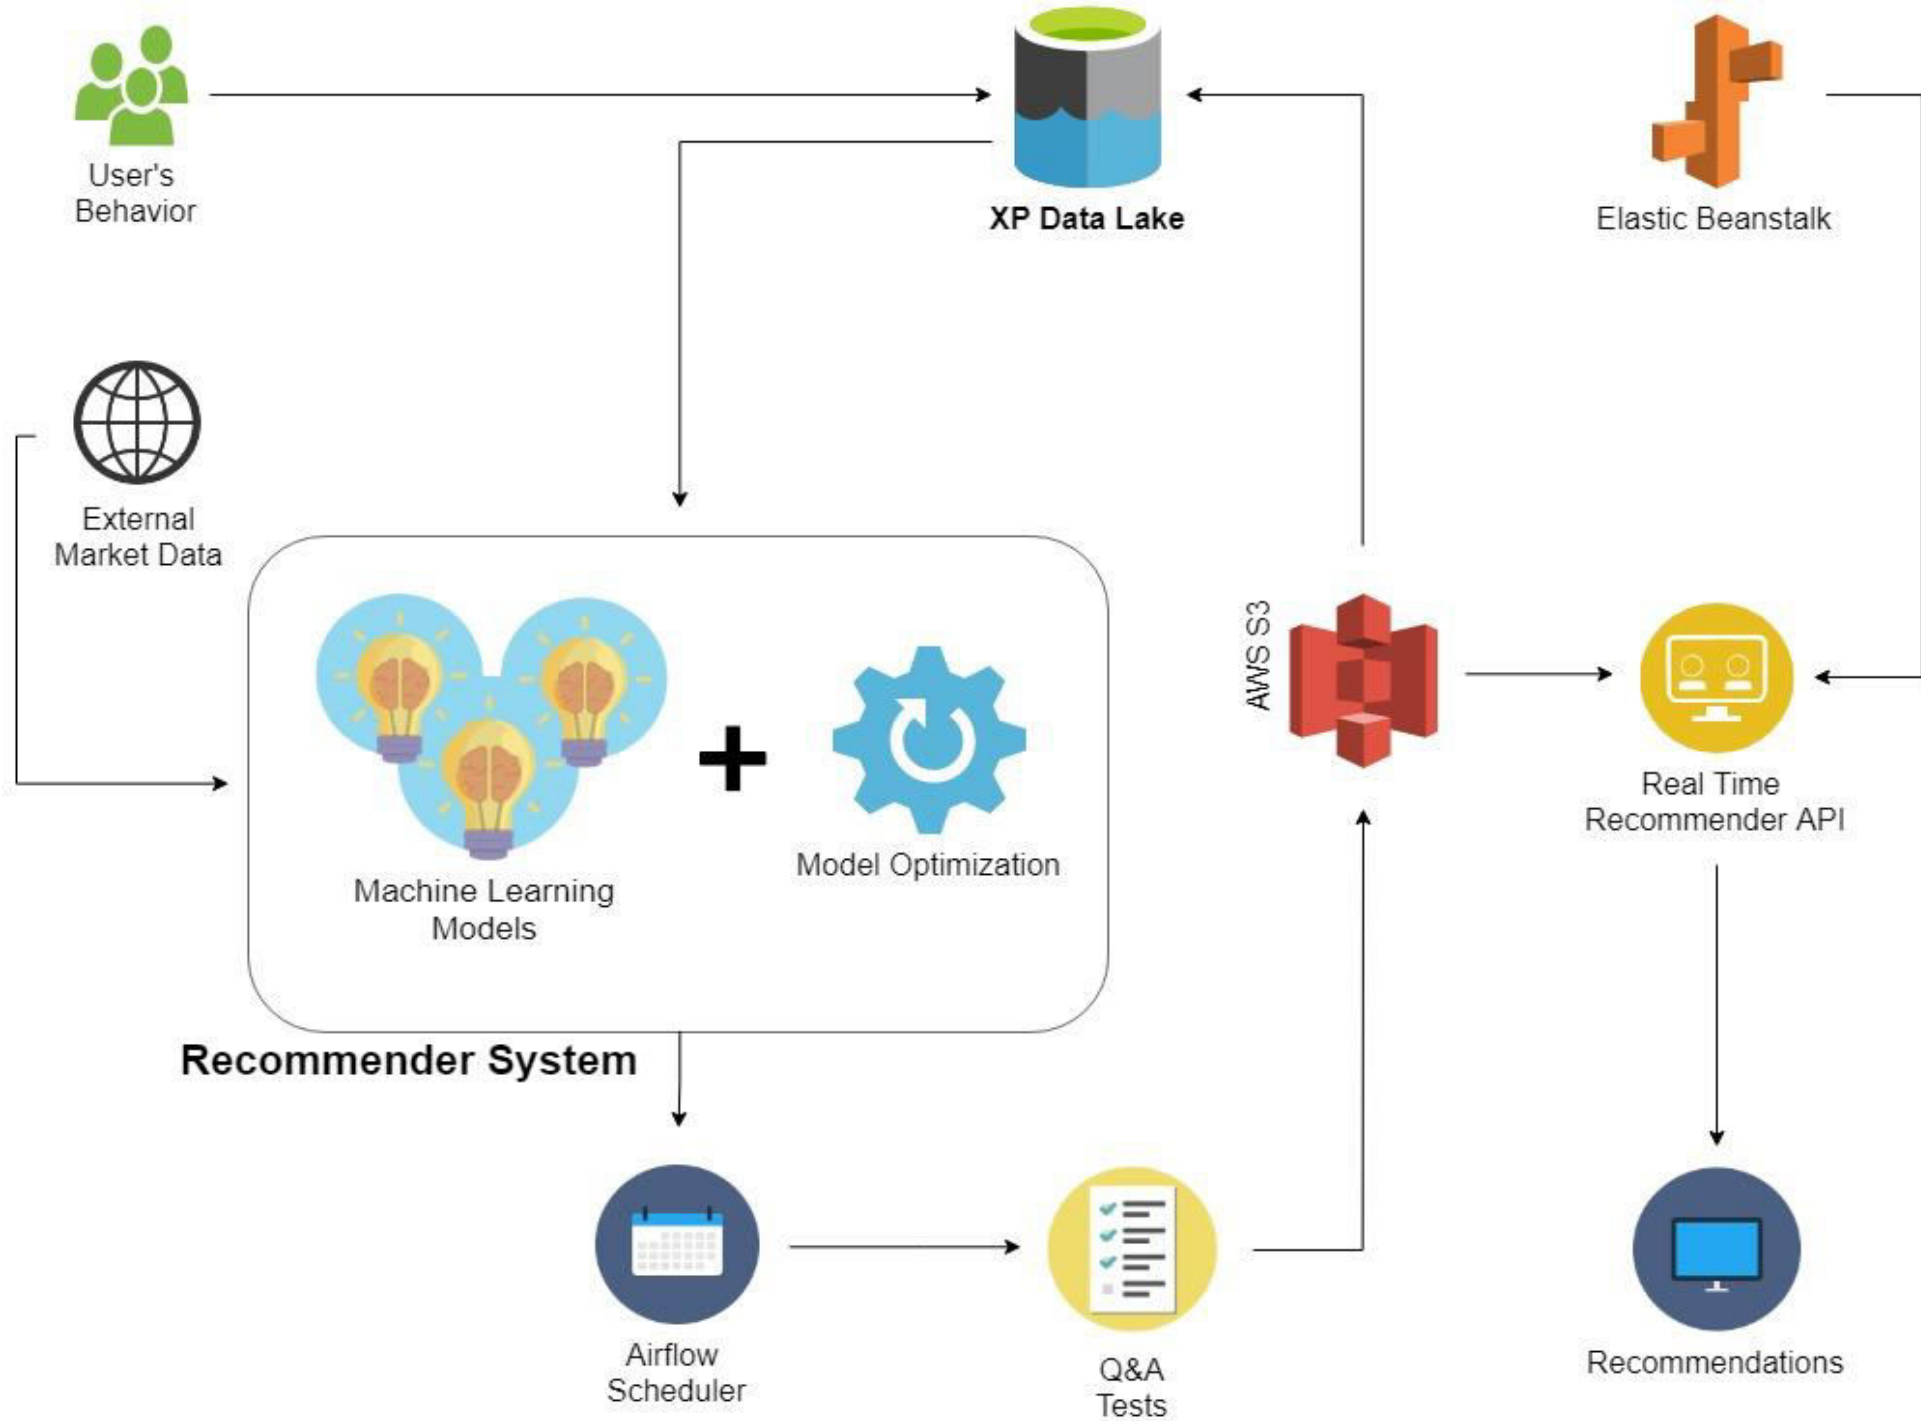
Conteúdo

- A necessidade por recomendações
- Sistemas de recomendação
- Implementação XP
- Machine Learning e Otimização
- **Criando Recomendações de Carteiras – Pipeline e Resultados**

Criando Recomendações

“Mais vale um código em rodando produção do que cinco modelos jupyter notebook rodando localmente”

- Para qualquer projeto de Data Science, atualmente, no mercado nota-se a dificuldade de migrar a aplicação para ambientes produtivos. A XP conta com a expertise de diferentes profissionais em um ambiente ágil para entregar projetos completos em poucas sprints. Temos o modelo e a otimização, precisamos apenas dispor os resultados de alguma maneira.



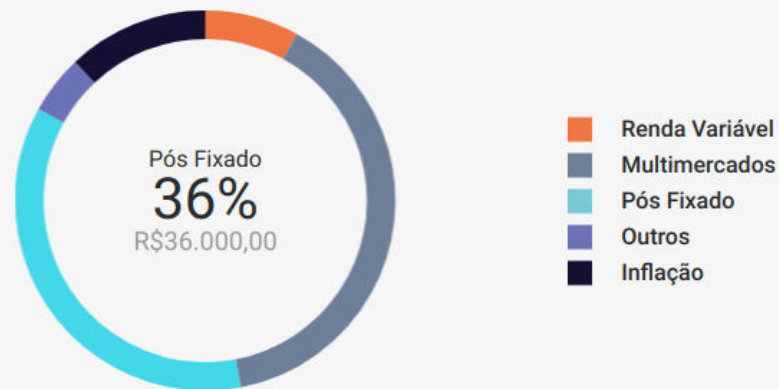
Resultados

- Utilizando uma estratégia parecida com uma criação de cache conseguimos dispor via API recomendações rápidas a qualquer momento, deixando o acesso prático e rápido inteiramente orquestrado por serviços AWS.
- Recomendações para mais de 600 mil clientes

Sua carteira

Investimento inicial	Perfil de investimentos
R\$100.000,00	 Moderado
Objetivo da carteira	Rentabilidade estimada em 10 anos
115% DO CDI	R\$228.716,70

Alocação dos investimentos



*A carteira de investimentos apresentada nesse material é compatível com o seu perfil de investidor, que está definido como Moderado. Para visualizar o seu perfil de investidor atual clique [aqui](#)

Produto de Investimento	Alocação (%)	Valor	
Renda Variável	8%	R\$8.000,00	
Constellation Institucional FIC FIA	8%	R\$8.000,00	Investir
Multimercados	39%	R\$39.000,00	
Solana Absolutto FIC FIM	20%	R\$20.000,00	Investir
Kondor Long Short FIM	19%	R\$19.000,00	Investir
Pós Fixado	36%	R\$36.000,00	
XP Investor FI Renda Fixa Crédito Privado LP	9%	R\$9.000,00	Investir