



# Recomendação de conteúdo na escala do iFood

Everton Gago

# Agenda

1. Visão Geral
2. Personalização
3. Potencial
4. Técnicas
5. Resultados
6. Aprendizados
7. Próximos Passos

# Visão Geral

# Escala

- Abrangência nacional
- Estamos em vários países na américa latina
- + 60k req / min nos horários de pico (no Brasil)



O iFood sempre foi uma empresa 'data driven',  
mas já estava na hora de 'brincar mais sério'.

# Time

- Engenheiros
- Cientistas
- Analistas

O que tem sido feito?

# Coleta de eventos

- Visualizações
- Cliques
- Avaliações
- Compras



# Estruturação de plataforma

- Datalake
- Testes e experimentos
- Melhoria do ferramental analítico
- Plataforma para servir modelos
- Modelos diversos



Sem isso fica difícil inovar em produção!

O iFood sempre teve a cultura de experimentar,  
agora conseguimos isso com segurança.

Conciliar DS para larga escala e em produção

## Temos conseguido avançar em:

- Classificação de cardápio
- Predição de fraudes em compras on-line
- Predição do nível de serviço dos restaurantes
- Personalização de conteúdo

Personalização

# Personalização

- Novo aplicativo e novas listas
- Curadoria ajuda, mas não é personalização



As pessoas comem coisas diferentes em ocasiões diferentes.

Personalização é entregar o que você quer,  
naquele momento.



# Recomendação Contextual

Potencial

Surgiram questões...


Os usuários compram sempre nos mesmos restaurantes?

Qual é o perfil do usuário explorador?

Os usuários estão sempre dispostos a explorar,  
ou só em períodos específicos?

Qual canal a personalização tem maior impacto?

# Comportamento Exploratório







Existe potencial, mas como explorar?

Técnicas

# Optamos por explorar

- Collaborative Filtering
- Content-based

# Collaborative Filtering



# Collaborative Filtering

- Resolve o problema contextual
- Apresenta baixa cobertura devido a esparsidade dos dados
- Dificulta o cold-start
  - Novo usuários
  - Usuário conhecido em um novo local

## Content-based

- Cada usuário possui um vetor de preferência
- Cada restaurante possui um vetor de características
- O que fazemos é procurar restaurantes que se aproximem das preferências dos usuários


## Content-based

- Resolve o problema contextual
- Apresenta alta cobertura (não depende do estado global)
- Cold-start é mais fácil de resolver
- Entretanto, depende de mais features
  - Seleção e engenharia de features
  - Compreender o grau de relevância para o modelo











# Content-based - Capacidade Descritiva



# Content-based - Capacidade Descritiva



Importante para validar os experimentos e  
saber como melhorar

# Resultados

## Experimento com push

- Teste A/B
- Controle recebeu restaurantes mais populares
- Teste recebeu recomendações do content-based
- A conversão foi 4x > no grupo de teste



## Experimento com aplicativo

- Teste A/B
- Controle recebeu recomendações
- Teste recebeu recomendações do content-based
- Os resultados foram inconclusivos



## Por que?

- Com a entrada do app novo, mudou também a forma de identificar os usuários
- Muitos usuários conhecidos, foram identificados como novos usuários
- Não fizemos o desenho mais adequado para o experimento, dificultando:
  - Comparar controle e teste
  - Recuperação de informações dos logs

## Resultados inconclusivos

94%

Receberam cold-start

6%

Receberam teste



O que tiramos desse último experimento?





Aprendizados

# Aprendizados

- Ajustes das métricas
- Ajustes nos logs de operações para facilitar recuperação
- Re-desenho do experimento (controle e teste)
- Ajustes no modelo para atualizar features com mais frequência

Próximos Passos...



Obrigado

***ifood***

A red arrow pointing to the right, positioned below the word "ifood".