



7º WSMPI:

Otimização de preços em um contexto de restrições no número de amostras

Representante: Roberto Nalon


Pesquisador: Lucas Nissenbaum

Contexto

Determinar o preço ótimo a que deve ser vendido um produto é fundamental para qualquer empresa, em particular, em lojas de varejo. Qualquer que seja o segmento, essas lojas costumam atender um grande número de pessoas, que invariavelmente possuem sensibilidades diferentes a preços. Naturalmente a percepção do valor de um item é diferente para cada pessoa. Isso significa que, oferecer um produto a um preço muito acima do valor percebido pelo cliente pode implicar em um número muito baixo de produtos vendidos. Nesse caso, mesmo o maior lucro por produto pode não ser suficiente para compensar a perda em vendas. Por outro lado, oferecer o mesmo produto a um preço muito baixo leva a um lucro abaixo do desejado por produto, por mais que haja um aumento significativo no número de vendas. O segredo então se encontra na diferenciação de preços: cada consumidor é "convidado" a pagar por um determinado item o preço que condiz com sua percepção de valor para o mesmo item, dadas as restrições particulares da empresa em relação àquele item (e.g., preço mínimo, margem desejada,


etc.). A otimização deste preço é crucial para maximizar o resultado de qualquer companhia.

Figura 1: Otimização do lucro com diferenciação de preços²



Em um contexto de uma rede com um grande número de lojas e produtos, o preço ótimo pode ser encontrado através de experimentação usando um framework de Reinforcement Learning¹ com multi-armed bandits, ou ainda, através da extrapolação de curvas de elasticidade². Estudos mostram que a diferenciação de preço tipicamente traz retornos da ordem de 4% a 10% em lucro bruto³. Muitos setores já se valem dessa otimização de preços. Por exemplo, companhias aéreas diferenciam preços por horário do dia, dia da semana e uma série de outras variáveis. Gigantes da internet, como Amazon, praticam essa diferenciação de preço em uma escala altamente granular, chegando a diferenciar o preço do mesmo item várias vezes ao longo do dia. A figura abaixo é um bom exemplo desse caso, em que um mesmo item variou amplamente de preço ao longo do tempo.

Figura 2: Variação do preço do item Lipton Black Tea Bags observado no site da Amazon



Por outro lado, algumas áreas de negócios ainda estão para trás na adoção de estratégias similares. Um desafio particular aparece nos cenários com

restrição de amostras, seja no número de lojas ou itens. Nestes cenários, a experimentação é praticamente proibitiva, já que não se tem uma massa relevante de amostras. Por outro lado, essas empresas tipicamente não alteram seus preços com frequência, o que também dificulta o estudo de elasticidades.

Big Data's PriceO

A Big Data desenvolveu o seu produto de precificação dinâmica, chamado PriceO, para um cenário em que é possível usar experimentação. Este sistema tem como objetivo determinar o preço ótimo de cada item em cada loja, e alcança este objetivo por meio de um sistema de reinforcement learning, balanceando as etapas de *exploration-exploitation* para a avaliação de preços. Em linhas gerais, o produto se vale de um grande volume de variáveis explicativas (e.g., renda, fluxo de trânsito, índice de concorrência, clima, criminalidade, entre outros) para segmentar as lojas. Em seguida, uma abordagem baseada em Thompson Sampling⁴ é usada para a etapa de experimentação de preços. Nesse processo, preços campeões são recompensados, enquanto os preços perdedores vão ficando pelo caminho, até chegar ao subconjunto de preços ótimos.

Problema

Embora já executado com sucesso em diversos clientes, o produto PriceO da Big Data não é apropriado para cenários em que consideramos uma rede com um número pequeno de lojas. Como mencionado antes, este cenário deixa a experimentação quase proibitiva, dado o pequeno número de amostras e portanto o PriceO não é indicado para a obtenção dos preços ótimos.

Nosso objetivo neste workshop é propor caminhos para otimizar este sistema no contexto de um pequeno número de lojas com poucas alterações históricas de preços. Quais modificações podem ser implementadas para alcançarmos uma solução de forma mais eficiente, ainda que esta solução não seja uma solução ótima global? Quais outros artifícios podem ser usados como *surrogate* nesse

caso? É possível criar um bom modelo para o preço ótimo, que não dependa de experimentação, nesse cenário? Neste sentido, estudaremos desde soluções que substituam parte deste sistema a soluções alternativas a este sistema como um todo. O objetivo deste projeto será definir metodologias a serem implementadas e estudadas pela Big Data no futuro.

Sobre a Big Data

A Big Data é líder no Brasil em Inteligência Artificial aplicada a negócios, ajudando clientes como AMBEV, BRF, BR Distribuidora, Burger King, GSK, Dexco e outras, além de forte atuação internacional.

Nossa paixão é por resolver os problemas de negócio mais complexos através de ciência de dados. Nosso foco é 100% em performance e geração de resultados, sem subjetividades.

Referências

1. Richard Sutton. Reinforcement Learning: An Introduction. Bradford Book, 2018.
2. H. Simon. Confessions of the Pricing Man. Springer, 2015.
3. A. Montgomery. Creating Micro-Marketing Pricing Strategies Using Supermarket Scanner Data. Marketing Science, 1997.
4. R. Ganti et al. Thompson Sampling for Dynamic Pricing. ArXiv, 2018.