



Tech企業における A/B test (公開用)

2020/5/16

@日本評価学会社会実験分科会

Shota Yasui

自己紹介



名前: 安井翔太 (32)

職業: Economic Research Scientist

web: <https://yasui-salmon.github.io/>

経歴:

2011年 立教大学 経済学部卒業

2013年 Norwegian School of Economics MSc in Economics

2013年 Cyberagent 入社 (総合職, 微妙な分析の量産)

2015年 アドテク部門へ異動 (専門職, MLの応用)

2017年 AILabへ異動 (研究職, ML + CI回りの応用)

良く使う言語: R, SQL, Python

AI Lab

Tech企業とA/Bテスト



CyberAgent.

テック企業とABテスト

amazon.com

Google



YAHOO!



Microsoft



ebay

Booking.com

テック企業で行われるABの量

The Google logo, consisting of the word "Google" in its characteristic multi-colored font.

+1000 test_{/day}



Microsoft

+200 test_{/day}



CyberAgent

+???

学会もある

CODE
@MIT

Conference on Digital Experiment([Link](#))



Computer Scienceでの研究も盛ん



- sequential experiment
- efficient adaptive experiment
- best arm identification


なぜそんなにABテストしているか？



長期的な利益につながるから


テック企業におけるRCT(A/Bテスト)の現実

一部のグローバルトップ企業



その他弱小ローカルテック企業

テック企業のABテストの考え方はこれ読むべき



Ron kohavi


テック企業でABテスト文化を作り上げた人
Computer Scienceのトップ会議でABテストのチュートリアルや研究発表を続けて啓蒙活動を行ってきた人。

CyberAgentでのA/Bテスト



CyberAgent.

ABテストの基本的なプロセス




CAでどんな実験をしているか？

例: 広告画像のABテスト



- どちらの画像の方がクリックされやすいだろうか？
- 数十～百程度のABテストが回っている
- 広告画像を作るクリエイターや営業の人が実施する

ABテストが始まるまでの流れ




CAでどんな実験をしているか？

例：広告の配信アルゴリズムのABテスト



- どちらのアルゴリズムの方が売上に貢献するだろうか？
- 月10回程度

ABテストが始まるまでの流れ



社会科学的な設定と異なる点

- **意思決定者=分析者**

- クリエイターがABを依頼して、自分で結果を見る。
- データサイエンティストがABを始め、自分で結果をみる。

- **分析と意思決定のサイクルが短い**

- 通常業務に加え、大量の分析と意思決定の日々。

- **検証したい介入の種類が多い**

- 改善しうるものはなんでも試したい

ここから生まれる需要

- **分析として正しい < 意思決定として正しい**
 - 最後の意思決定の質が重要
- **自動化の重要性**
 - 実験が多くなるとより面倒に...
- **複雑な設定の実験を簡素にする**
 - より多くの設定で実験を使える状態にしたい

→これにこたえたい

より効率的な意思決定の導入



CyberAgent.

意思決定する立場になると...

分析における
検出力の最大化？

意思決定における
Regretの最小化？

最適な選択との乖離 = Regret

一体どちらがゴールなのか？

考えるお題

あるユーザーに対してどちらの広告テンプレートを見せるべきか？



template_id: 26



template_id: 75

Regretという観点で実験を考え直す

1. トータルで1000万回広告を表示する
2. より多くのクリックを集めたい
3. 最初の200万回でABテストを行う
4. 良かった選択肢を選び続ける

実験では最適な選択との乖離が出来る=Regret

→ビジネスにおける損失

Regretという観点で実験を考え直す

1. トータルで1000万回広告を表示する
2. より多くのクリックを集めたい
3. **最初の200万回でABテストを行う←ここに無駄がある**
4. 良かった選択肢を選び続ける

実験では最適な選択との乖離が出来る=Regret

→ビジネスにおける損失

Adaptiveな実験としてのバンディット

あるユーザーに対してどちらの広告テンプレートを見せるべきか？

→クリックがより起きそうな方を**都度**選ぶべき

(クリックを増やしたいなら)




template_id: 26



template_id: 75

Thompson Sampling MAB



Adaptiveな実験としてのバンディット

あるユーザーに対してどちらの広告テンプレートを見せるべきか？

→クリックがより起きそうな方を選ぶべき(クリックを増やしたいなら)

→機械学習で予測して、予測値が大き方を選べば良いのでは？




template_id: 26




template_id: 75

Thompson Sampling Contextual Bandit



男性には26だけど女性には75が良いといった傾向が汲み取れる

Thompson Sampling Contextual Bandit



男性には26だけど女性には75が良いといった傾向が汲み取れる

バンディットの利点

- **Regretが一定のバウンドに収まる**
 - 意思決定の質がある程度担保される
- **分析→意思決定のフローが自動**
 - 意思決定者としては楽
 - ちゃんと動作しているか？という運用コストが発生
 - この辺りはデータサイエンティストが頑張る？

バンディットのログから 評価を行う



CyberAgent.

分析・評価の必要性

- **広告主に対するレポート**

- 次にどんな広告画像を作るべきなのか？
- 配信した広告画像は何が良かったのか？

- **バンディットの実行には分析が必要**

- バンディットの実行オプションを増減させたい
- 今ある実行オプションの中でいらないものはどれか？

→効果の推定が必要になる

バンディットフィードバック

- **Thompson Samplingの特徴**


- ある確率にしたがって腕を選択する＝ABテスト
- X毎に選択確率が異なる＝X毎に異なる確率でAB

- **因果推論からの観点**

- 腕の選択確率＝真の傾向スコア
- Xは全て既知

→IPWで因果効果が推定できる状況

Biased Result




- template_id毎にCTRを計算する
- template_id:26のCTRが高そう

→Biasを含んだ結果

営業や事業責任者の方が見るデータ



IPW result




- バイアスがある程度減っているはず。
- 26がよかったというのは幻想だった。
- CTRはどれも大差ないという結果。

ATEベースで意思決定して良いか？



Heterogeneity



- interstitial
 - 1: 全画面で見せる
 - 0: 記事の中で見せる
- 非インステ枠では26が良い
- インステ枠では75が良い


- ATEで悪くとも、あるXでは良い腕も存在しているかもしれない。
- ATEにしたがった意思決定をしても、改善出来ない可能性がある。

複雑な状況での効果検証




CyberAgent.

広告オークションにおける機械学習の役割



- オークションで落札すると広告が表示出来る
 - 落札するとコストが発生する
 - 広告をクリックして物が買われると嬉しい
- 機械学習は購買確率やクリック確率を予測している

機械学習のABテスト



何が難しいか？

- **費用の側面と収益の側面がある**

- 薬であれば効果と副作用？

- **どの様に意思決定すればよいか？**

- 収益と費用が同じ単位ではない場合が多い
 - 収益 vs ユーザー体験など
- 収益も増えるけど、費用も増えるモデルは良いモデルなのか？

→実験が出来ても意思決定が難しい

取り敢えずの対処

- **以下の結果以外では結論が出る**

- 費用が変わらないけど、収益が増える。
- 収益が変わらないけど、費用が減る。

- **何かしらの重みを決めてスコアを出す**

- Overall Evaluation Criteria (OEC) と呼ばれるもの
 - Google, Amazon, Microsoft, etc は OEC を決めるチームが存在する
- スコアに差があれば結論を出す

ある実験結果

CV	Cost	CPA
+31%*	+28%*	-2%

Table 3: Online relative comparison of FFM and FFMIW. The values shown are the relative change in the FFMIW against the FFM. * denotes statistical significance.

- 機械学習におけるデータのバイアスを除去してABテスト
- CPA: 購買を1件獲得するあたりの平均コスト
- Cost: 広告費用

→平均コストは有意な差が無いが、広告費用は有意に増加。
広告配信ビジネス的には嬉しい結果。

おしまい

