

UNICORN

機械学習ワークロードにおける Spot&AWS Batchの活用

11/11/2020 AWS 秋のスポットインスタンス祭り

SEKI INOUE

井上 碩

@peroxyacyl

博士（情報理工学）


TOP DATA SCIENTIST @ UNICORN, Inc.

CTO @ Mist Technologies, Inc.

特任研究員 @ 東京大学

ABOUT UNICORN

サービスのご紹介



UNICORN

デジタル広告の価値算定エンジン
+
買付プラットフォーム



広告枠
(2300万種類/月)

×



広告在庫
(6400種類/月)



ユーザー群の行動が
どう変わるか？

で価値算定

広告枠の相場 = 他社の値付けは
価値算定に一切考慮しない*

業界内の立ち位置はDSPだが、買い方はかなり異なる

*買付時はオークション理論に則って最適化



MODE:PERFORMANCE

DISPLAY ADS 自動最適化エンジン



APPLE SEARCH ADS

APPLE SEARCH ADS 自動最適化エンジン



COVERAGE - メガプラットフォームがリーチできない広告トラフィック

国内最大級の6,000億imp/月を用いて、Google及びSNS広告とは異なるユーザーのシチュエーションとカバーできない全領域にてリーチ可能。



WHY - なぜApple Search Adsが重要な広告商品なのか？

- 事業成長のコアに繋げる事ができる広告商品（自然流入の増加）
- ポストiOS14の環境で最も重要な広告商品

過去の行動を捉えるのではなく、



FRAUD PROTECTION - 徹底的なデータクレンジング


誤タップ誘導と不正imp&clickの検出、CTR/CVR分析、不正広告探知の専門機関によるコンバージョンデータの検収など、クライアントの広告費用と自社のコンバージョン率を保護

広告を広く買付する



PERFORMANCE - 自動最適化・高ARPUとROAS

「月間6,000億impのデータ学習 + 徹底的なデータクレンジング」を基に、最も理想的な「広告枠 x オーディエンス x クリエイティブ」の組み合わせを予測し、ターゲットKPIに合わせて自動最適化。



課題

解決案

運用	最適化の努力
● キーワード生成 ● キャンペーン構成の設計 ● キャンペーン / アドグループ設定 ● キーワード選定 / 設定 ● キーワード別の入札調整	● キャンペーン分類別のセグメント ● 完全一致キーワードに高い入札単価設定 ● ネガティブキーワードの活用 ● 新しいキーワードの探索活用
人々 = リソースの制限による運用可能なキーワード量の制限	
効果の最大化が難しい	


運用	最適化の努力
● キーワード生成 ● キャンペーン構成の設計 ● キャンペーン / アドグループ設定 ● キーワード選定 / 設定 ● キーワード別の入札調整	● キャンペーン分類別のセグメント ● 完全一致キーワードに高い入札単価設定 ● ネガティブキーワードの活用 ● 新しいキーワードの探索活用
人々ではコントロール不可能な量データを用いて、効果の最大化を実現	



HOW - 10万通り以上の「属性 x キーワードの組み合わせ」を自動最適化


- 100+ のユーザー属性の自動生成
- 1,000+ のキーワード自動収集
- 100,000+ のユーザー属性 x キーワードの組み合わせに対する自動入札最適化

UNICORN Tech Numbers



UNICORNの売上高／機械学習コスト推移

単位：百万円



AWSインフラコスト
が大部分を占める

スポットインスタンス
がなければ
ビジネスが成立しない

売上高は前年同期の246%と大幅に伸長。
引き続き、機械学習も加速させ順調に精度を向上。

About UNICORN

SPOT + UNIC

スポットインスタンスの利用状況

全体の半分以上がスポットインスタンス

ML推論・学習部分では94%

71%

Savings

\$0.0198

Average cost per VCPU-hour

\$0.0041

Average cost per mem(GiB)-hour

全体 : 333スポット/602インスタンス

うちML関連部分

12xlarge

ML学習 : 6スポット/6インスタンス

ML推論 : 301スポット/319インスタンス

DB : 0スポット/98インスタンス

学習

失敗可能なタスク → [Spot+Batch](#)

推論

オートスケール → [Spot+ELB](#)

DB

負荷が安定 → [Reserved](#)

UNICORN モデル群 学習スケジュール

学習タスクによって

- かかる時間
 - つかうCPU
 - 必要なメモリ
 - 必要なディスクサイズ
- が異なる

→ AWS Batchでその都度リソースを確保
第5世代 (c5, c5a, m5, r5)をSPOTで使用




UNICORN モデル群 学習スケジュール

学習タスクによって

- かかる時間
 - つかうCPU
 - 必要なメモリ
 - 必要なディスクサイズ
- が異なる

→ AWS Batchでその都度リソースを確保
第5世代 (c5, c5a, m5, r5)をSPOTで使用



BATCH + ML

AWS Batchと機械学習


ワークロードの概要

1. データのダウンロード
2. データの検証
3. 特徴量変換

1. 学習エポック1
2. 学習エポック2
- ...

1. 学習エポックN

1. モデルの検証
2. モデルのアップロード



スポットで中断しても良い学習バッチとは？



失敗したときのバックアッププランを考える

失敗してもよいML学習ワークロードの例

失敗した場合は
一つ前のバージョンを使う

① モデルのバージョンニング

学習のチューニング方針

- モデルバージョン間で大きな推論の差が出ないようにする

- データセットの期間を長く取る
- 環境変化に対する即応性とのトレードオフ

1. 学習正常終了 → S3へアップロード (S3 Versioning)
2. 推論側は、定期的にS3をポーリング




失敗してもよいML学習ワークロードの例

学習を短く、数を多く

② マイクロモデルをアンサンブルする

大きな単一のモデルで推論するのではなく、
小さなモデルを複数用意してそれらの平均を取る

学習を短く済ませ、歩留まりを上げる




失敗してもよいML学習ワークロードの例


即応性 + 安定性

③ バージョニング + アンサンブル


最新 N バージョンを加重平均する




1時間前




2時間前




3時間前
失敗



4時間前



5時間前



6時間前

...

$$p \leftarrow 0.5p' + 0.3p'' + 0.2p'''$$

BATCH+EBS

AWS BatchでEBSを使う方法

AWS Batchの基本容量はホストあたり8GB




ストレージを足す方法は3つ

① EFSをマウントする

EFS = スケーラブルなNAS


サイズ課金 + スループット課金



① EFSをマウントする


EFS = スケーラブルなNAS

サイズ課金 + スループット課金




② ホストのEBSをアップグレード

ルートボリュームを大きくしたAMIを作成する




② ホストのEBSをアップグレード

ルートボリュームを大きくしたAMIを作成する



③ EBSをコンテナにマウント

コンテナのdevice socket経由でEBSをマウントする



③Batch JobごとにEBSを動的アタッチ

Jobごとにサイズを可変にして効率化

AWS Batchで標準装備のEBS

Device name	Volume size (GiB)	Attachment status	Attachment time	Encrypted	KMS key ID	Delete on termination
/dev/xvda	8	✔ Attached	Thu Oct 22 2020 10:26:04 ...	No	–	Yes
/dev/xvdcz	22	✔ Attached	Thu Oct 22 2020 10:26:04 ...	No	–	Yes
/dev/xvdg	100	✔ Attached	Fri Oct 23 2020 03:56:28 G...	No	–	Yes
/dev/xvdh	50	✔ Attached	Fri Oct 23 2020 19:26:20 G...	No	–	Yes
/dev/xvdi	200	✔ Attached	Fri Oct 23 2020 20:08:23 G...	No	–	Yes

Jobごとに作成+アタッチされた揮発領域用のEBS

Dockerコンテナでストレージを使う3つの方法

デフォルトは、インスタンスあたり8GB

	EFSをマウント	EBSをホストにマウント	EBSをコンテナにマウント
共有範囲	全Jobで共有	ホスト内で共有	Jobで専有
マウントの タイミング	Job起動時	AMI作成時	Job起動時
メリット	データが永続的 全体で共有できる	コンテナがシンプル	Job毎にサイズ/IOPSが可変 burst creditがリセット 断片化しない(st1も視野)
デメリット	スループットが高価	サイズ/IOPSの事前設定が必要 十分なリソースの確保が必要	データが完全に揮発的 消しそこねると痛い

Dockerコンテナでストレージを使う

UNICORNのワークロードでの費用感

	EFSをマウント	EBSをホストにマウント	EBSをコンテナにマウント
必要な サイズ	2,500 GB	500 GB x 6 instances	合計 2,500 GB
必要な Provisioned IO	1,500 Mbps	io2 2,000 IOPS (500 IOPS x 4 job)	gp2 (起動時のburst creditで足りたため)
月間コスト (ap-northeast)	\$10,800 / month	\$1,314 / month	\$300 / month

③ EBSをコンテナにマウント

【EBSをdeviceとしてアクセスする】

※ 要privilegeフラグ

Dockerコンテナ起動時のENTRYPOINTで以下の処理を行う

① awscliでEBSを作成

```
$ aws ec2 create-volume
```

② 使用可能なデバイスファイルを探す (例: /dev/xvdf)

```
$ [while文などで]
```

③ 作ったEBSをホストインスタンスにアタッチ

```
$ aws ec2 attach-volume
```

④ デバイスのファイルシステムをフォーマット

```
$ mkfs.xfs -f /dev/$DEVNAME
```

⑤ マウント

```
$ mount /dev/$DEVNAME $EBS_PATH
```

⑥ EBS削除の設定 (後述)



EBSの削除

EBSが残ると課金が続く



確実な削除が必要

lambdaで監視するのも有効

EBS削除のタイミングと方針

1. 正常終了

ENTRYPOINTでコマンド後に実行

2. プログラムの異常終了

ENTRYPOINTでtrapする

```
function rmebs {  
    set +e  
    umount -l /media/data  
    aws ec2 detach-volume --force --volume-id $VOLUME_ID  
    timeout 600 bash -c "waitebsstate $VOLUME_ID available"  
    aws ec2 delete-volume --volume-id $VOLUME_ID && echo "volume successfully deleted"  
}  
trap rmebs EXIT  
mkebs  
  
$@
```



EBSの削除

EBSが残ると課金が続く



確実な削除が必要

lambdaで監視するのも有効

EBS削除のタイミングと方針

3. スポットインスタンスの回収

4. ジョブの手動キャンセル

中断通知内のdetachが間に合わない

キャンセルの場合は即時に落ちる

→ Delete On Termination機能を使う

```
echo "enable DeletionOnTermination to ensure eventual deletion"
cat << EOF >> mapping.json
[
  {
    "DeviceName": "/dev/${DEVNAME}",
    "Ebs": {
      "DeleteOnTermination": true
    }
  }
]
EOF
aws ec2 modify-instance-attribute --instance-id $INSTANCE_ID --block-device-mappings file://mapping.json
```



Tips

/devをコンテナにマウント

コンテナ内の/devは
デバイス追加時に更新されない



/devを仮想ボリュームとして
コンテナにマウントする

第三者のdocker imageには注意

Host

/dev

/xvda ... 8GB
/xvdf ... 200GB ← EBSをアタッチしても...

Container

/dev

/xvda

← ここは増えない

/hostdev

/xvda

/xvdf

← こっちは増える

マウント


-v /dev:/hostdev



EBSベンチマーク

コンテナ直接アタッチのパフォーマンスは問題なし

fio Benchmark



Dockerコンテナでストレージを使う


UNICORNのワークロードでの費用感

	EFSをマウント	EBSをホストにマウント	EBSをコンテナにマウント
必要な サイズ	2,500 GB	500 GB x 6 instances	合計 2,500 GB
必要な Provisioned IO	1,500 Mbps	io2 2,000 IOPS (500 IOPS x 4 job)	gp2 (起動時のburst creditで足りたため)
月間コスト (ap-northeast)	\$10,800 / month	\$1,314 / month	\$300 / month

EBSベンチマーク

コンテナ直接アタッチのパフォーマンスは問題なし

fio Benchmark



開発でもBatchを使う

チューニングなどの高コストな計算をクラウドにオフロード

```
$ ./runbatch.sh --cpu 4 --memory 16000 --volume 100 "python optuna.py"
```

このコマンドは下記を行う

- ディレクトリをdockerに固めてECRにpush
- job definitionの発行
- 4 vCPUs, 16GB メモリ, 100GB EBSを確保
- batch上で `python optuna.py` を起動
- Log StreamのURLを出力



まとめ

1. 弊社ではスポットインスタンスでコストをオンデマンドより **71%** 下げている
2. 学習ワークロードでは、**失敗したときのバックアッププラン** を作る
 - a. **アンサンブル学習** が歩留まりを上げるために有効な一例

1. AWS BatchはJobごとに異なる負荷を持つときに効率的
...だが、作業用ストレージ領域が足りない

1. **EBSをコンテナに直接マウント** する方式が有効
2. 開発やチューニングにもAWS Batchは使える



We are hiring

JS SDK

自然言語処理

Data ETL

Data Visualization

Rich Creative Design

App SDK

SRE

強化学習

Microservice Orch.

Tech. Account Managing

golang
ruby
rust
assembly
TypeScript
SQL

WE ARE HIRING W UNICORN



unicorn.lnc