



第7回 Amazon SageMaker 事例祭り 2019.8.29



#sagemaker_fes

Amazon SageMaker の基礎

Amazon Web Services Japan
Machine Learning Solutions Architect

Shoko Utsunomiya

自己紹介

宇都宮 聖子

- 機械学習ソリューションアーキテクト
 - 機械学習サービスを担当
 - 前々職は量子情報の研究者
 - 前職は自動車OEMで自動運転開発
 - 担当領域
 - 自動運転、AIヘルスケア、AI ゲーム、Startup
- 好きなサービス
 - Amazon SageMaker



shokout

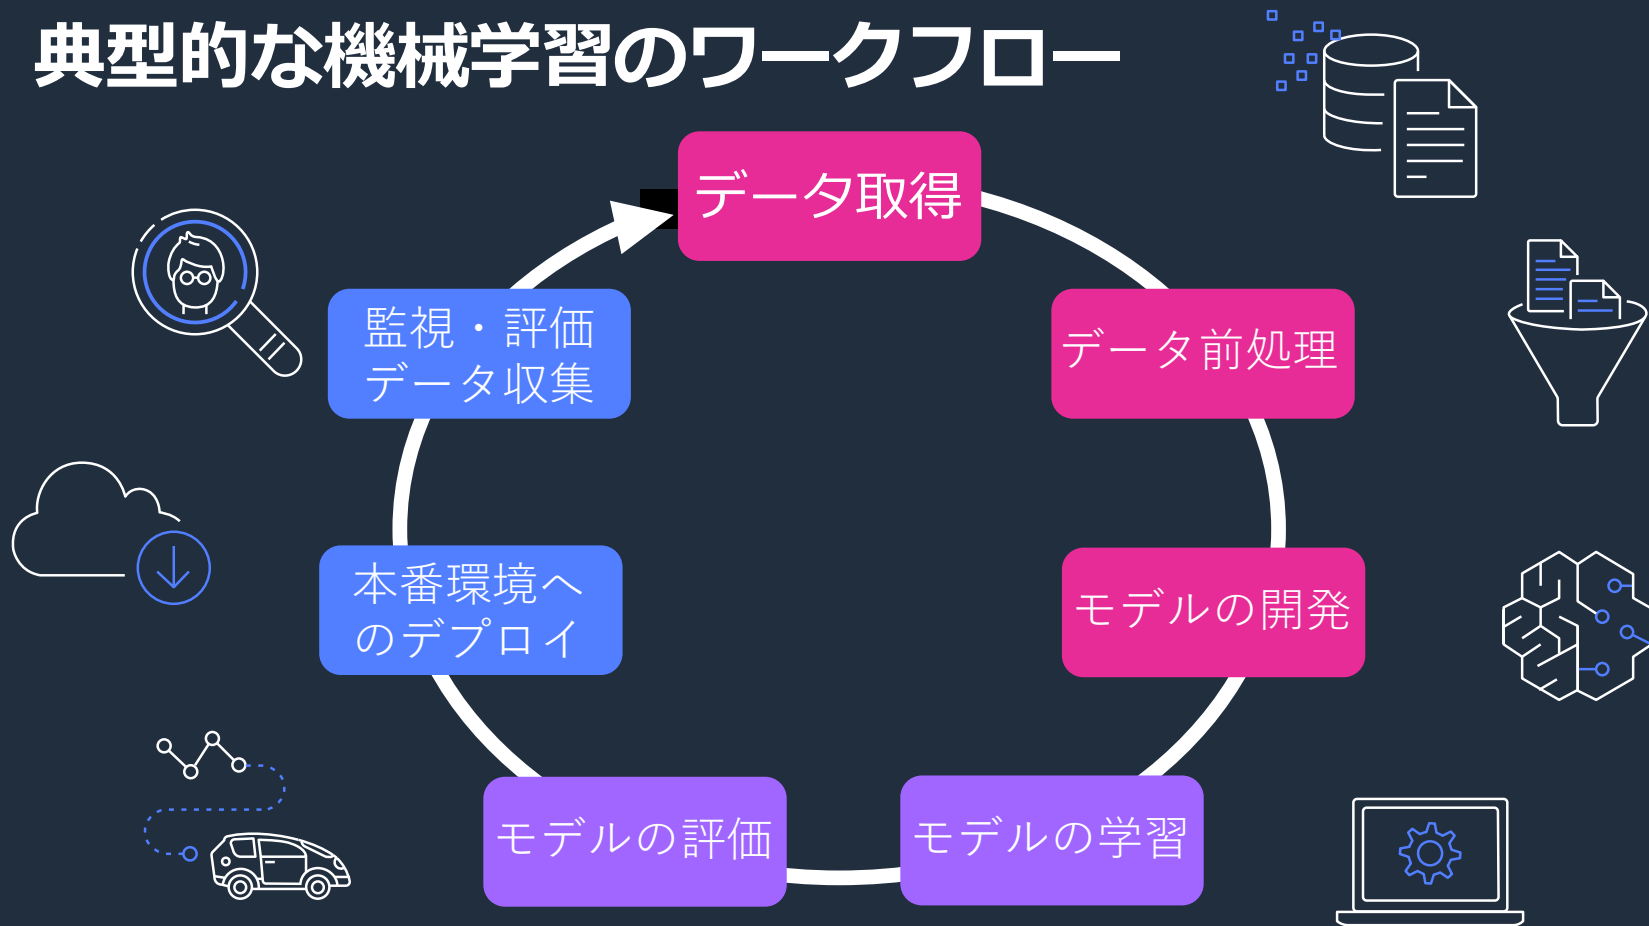
アジェンダ

- 機械学習の課題に対する SageMaker のメリット
- SageMaker を利用した機械学習プロセス
- 機械学習の開発・学習・推論を効率化する基本機能
- まとめ

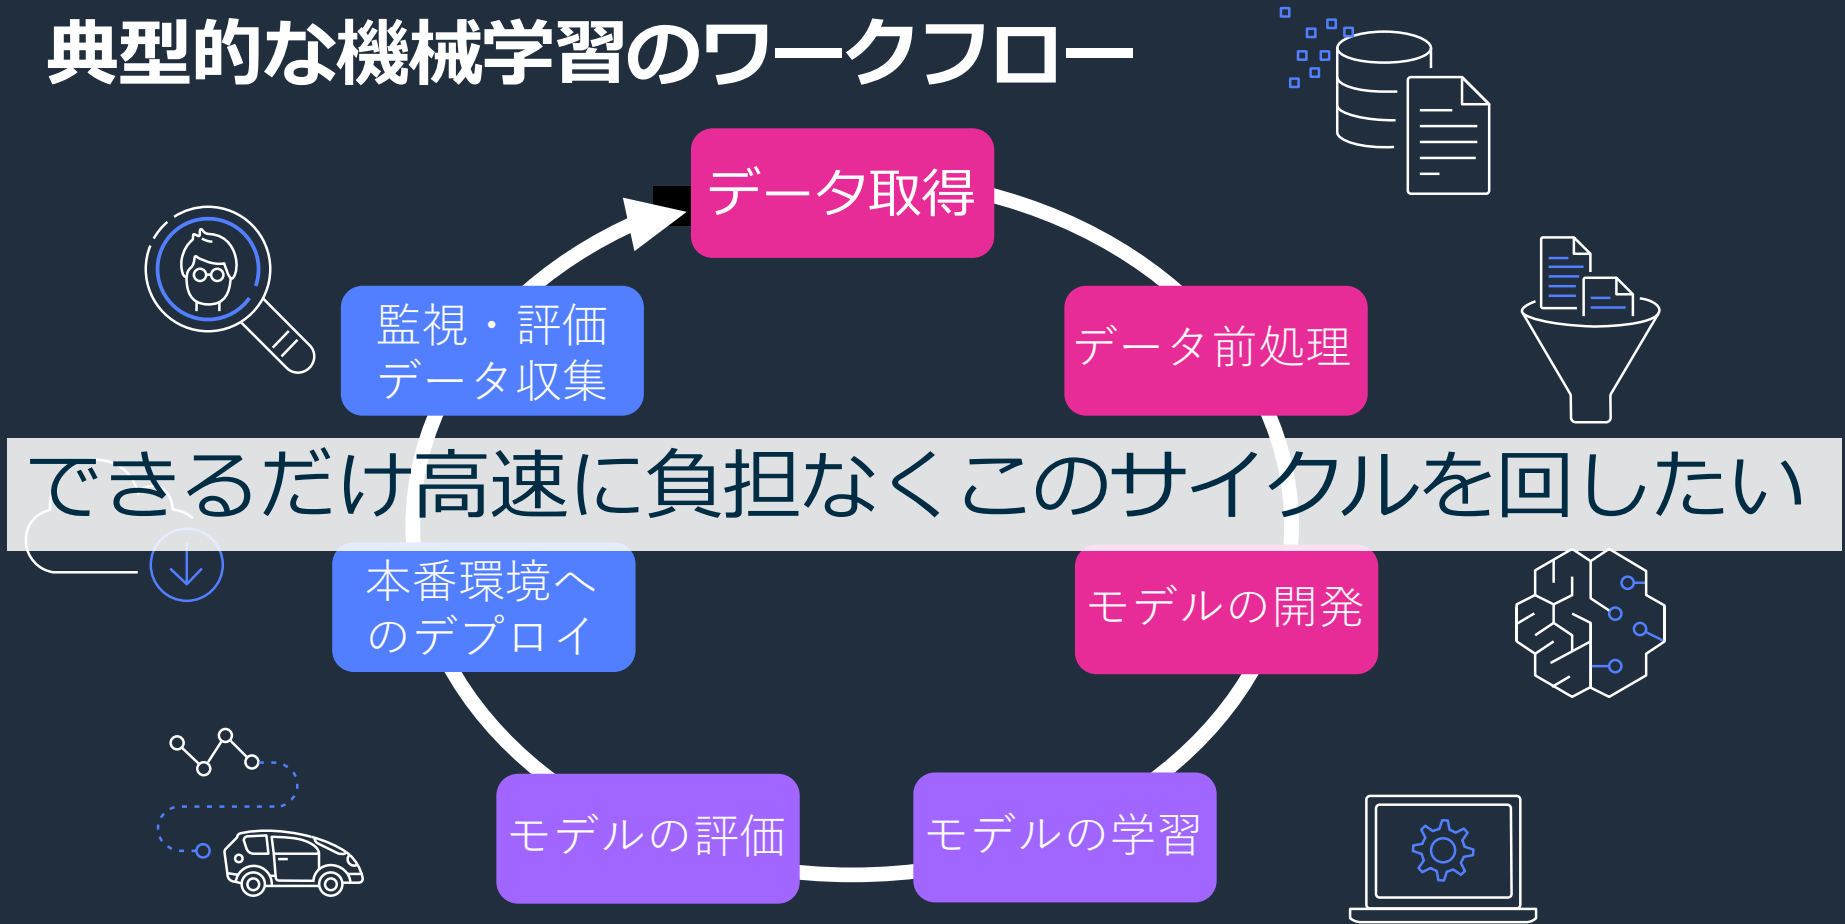
アジェンダ

- 機械学習の課題に対する SageMaker のメリット
- SageMaker を利用した機械学習プロセス
- 機械学習の開発・学習・推論を効率化する基本機能
- まとめ

典型的な機械学習のワークフロー



典型的な機械学習のワークフロー



機械学習における “Undifferentiated Heavy Lifting”

開発環境構築

- 必要なリソースの見積もりと購入の決断
- 開発チームで均一な開発環境構築
- フレームワークのインストール, バージョン管理

機械学習モデルの学習

- CPU/GPU など用途にあったハードウェア環境提供
- スケーラブルな分散学習構築と広帯域な通信環境

運用

- 推論環境の準備とモデルのホスティング
- 機械学習と異なるスキルセットが求められる

AWS の提供する機械学習スタック

AI SERVICES

App developers with little knowledge of ML



Vision



Speech



Language




Chatbots



Forecasting



Recommendations



ML SERVICES

ML developers and data scientists



Amazon SageMaker

Labeling

Ground Truth

Model development

Notebooks
Algorithms
Marketplace

Supervised Learning
Unsupervised Learning
Reinforcement Learning

Training

Training
Optimization (Neo)

Hosting

Deployment
Hosting


ML FRAMEWORKS & INFRASTRUCTURE

ML researchers and academics

Frameworks



Interfaces



Infrastructure



AWS の提供する機械学習スタック

マネージドサービスを活用し
ビジネスの価値にフォーカス

ML SERVICES

ML developers and
data scientists



Amazon
SageMaker

Labeling

Ground Truth

Model development

Notebooks
Algorithms
Marketplace

Supervised
Learning
Unsupervised
Learning
Reinforcement
Learning

Training

Training
Optimization
(Neo)

Hosting

Deployment
Hosting

ML FRAMEWORKS & INFRASTRUCTURE

ML researchers and
academics

Frameworks



Interfaces



Infrastructure



Amazon SageMaker とは

- 機械学習プロジェクトの課題を解決するためのマネージドサービスで、**数分で開発環境を起動でき、学習、推論環境は柔軟にスケール**
- **多数のAPI**を提供しており、他サービスとの自由度の高い連携が可能
- **東京**を含む**17**リージョンで提供
- ほとんどのコンテナ、SDKは**オープンソース**



ラベリング



開発



学習



モデル変換




推論

Amazon SageMaker Notebook instance

- SageMaker 上のワークフロー（環境・データのインポート、モデル定義、学習ジョブ、デプロイ、エンドポイント呼び出し）を SageMaker Python SDK で記述する

Jupyter Notebook



Training with Chainer

VGG is an architecture for deep convolution networks. In this example, we train a convolutional network to perform image classification using the CIFAR-10 dataset. CIFAR-10 consists of 60000 32x32 colour images in 10 classes, with 6000 images per class. There are 10000 training images and 10000 test images. We'll train a model on SageMaker, deploy it to Amazon SageMaker hosting, and then classify images using the deployed model.

The Chainer script runs inside of a Docker container running on SageMaker. For more information about the Chainer container, see the [sagemaker-chainer-containers](https://github.com/awssagemaker-chainer-containers) repository and the [sagemaker-python-sdk](https://github.com/awssagemaker-python-sdk) repository:

- <https://github.com/awssagemaker-chainer-containers>
- <https://github.com/awssagemaker-python-sdk>

For more on Chainer, please visit the Chainer repository:

- <https://github.com/chainer/chainer>

This notebook is adapted from the [CIFAR-10](#) example in the Chainer repository.

```
# In [ ]:
from sagemaker import get_execution_role
import sagemaker


sagemaker_session = sagemaker.Session()

# This role retrieves the SageMaker-compatible role used by this Notebook Instance.
role = get_execution_role()
```

Downloading training and test data

We use helper functions provided by `chainer` to download and preprocess the CIFAR10 data.

JupyterLab



Distributed Training with Chainer and ChainerMN

Chainer can train in two modes: single-machine, and distributed. Unlike the single-machine notebook example that trains an image classification model on the CIFAR-10 dataset, we will write a Chainer script that uses `ChainerMN` to distribute training to multiple instances.

VGG is an architecture for deep convolution networks. In this example, we train a convolutional network to perform image classification using the CIFAR-10 dataset on multiple instances. CIFAR-10 consists of 60000 32x32 colour images in 10 classes, with 6000 images per class. There are 50000 training images and 10000 test images. We'll train a model on SageMaker, deploy it to Amazon SageMaker, and then classify images using the deployed model.

The Chainer script runs inside of a Docker container running on SageMaker. For more information about the Chainer container, see the [sagemaker-chainer-containers](https://github.com/awssagemaker-chainer-containers) repository and the [sagemaker-python-sdk](https://github.com/awssagemaker-python-sdk) repository:

- <https://github.com/awssagemaker-chainer-containers>
- <https://github.com/awssagemaker-python-sdk>

```
import os
import shutil

import numpy as np

train_data = [element[0] for element in train]
train_labels = [element[1] for element in train]

test_data = [element[0] for element in test]
test_labels = [element[1] for element in test]

try:
    os.makedirs('/tmp/data/train_cifar')
    os.makedirs('/tmp/data/test_cifar')
    np.savez('/tmp/data/train_cifar/train.npz', data=train_data, la
    np.savez('/tmp/data/test_cifar/test.npz', data=test_data, label
```

学習: 分散学習や複数学習ジョブの同時実行

- APIを經由で学習用のインスタンスを起動可能で、**学習が完了すると自動で停止する**
- 高性能なインスタンスを手動で停止したりせずに済み、**簡単にコストを抑えることができる**
- 指定したインスタンス数で**分散学習環境が容易に構築できる**

リソース設定

インスタンスタイプ	インスタンス数	インスタンスあたりのボリュームサイズ (GB)
ml.m4.xlarge ▼	1	1
ml.m4.xlarge	ブション	
ml.m4.4xlarge	ose an existing KMS key or enter a key's ARN.	
ml.m4.10xlarge		
ml.c4.xlarge		
ml.c4.2xlarge		
ml.c4.8xlarge		
ml.p2.xlarge		hours ▼
ml.p2.8xlarge		
ml.p2.16xlarge		
ml.p3.2xlarge	ータ	
ml.p3.8xlarge		
ml.p3.16xlarge	ムでは、ハイパーパラメータセクションを使用できません。	
ml.c5.xlarge		
ml.c5.2xlarge		
ml.c5.4xlarge		
ml.c5.9xlarge	個のチャンネルを作成します。選択したアルゴリズムが複数の入力チャ:	
ml.c5.18xlarge	チャンネルを指定できます。参照 Algorithms Provided by Amazon Sage	

インスタンスタイプ、
起動数の指定



SageMaker が Managed Spot Training に対応！

- これまでの学習コストを最大で90%削減
- すべてのフレームワーク、モデル、学習構成で利用可能
- Checkpointing により Spot instance が落ちても途中から学習を再開

NEW!

```
from sagemaker.tensorflow import TensorFlow

mnist_estimator = TensorFlow(entry_point='mnist.py',
                             role=role,
                             train_instance_count=2,
                             train_instance_type='ml.p2.2xlarge',
                             train_max_run = 5000,
                             train_use_spot_instances=True,
                             train_max_wait = 7200)
```

```
In [8]: mnist_estimator.fit(training_data_uri)
```

```
Placeholder is deprecated. Please use tf.compat.v1.placeholder instead.
W0828 14:00:47.032024 140424720971520 training.py:181] Model not saved to S3.
odel. Your training job will not save any model files to S3.
For details of how to construct your training script see:
https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker/tensorflow-script
```

```
2019-08-28 14:00:53 Uploading - Uploading generated training manifest
2019-08-28 14:00:53 Completed - Training job completed
Training seconds: 1544
Billable seconds: 620
Managed Spot Training savings: 59.8%
```

<https://aws.amazon.com/jp/blogs/aws/managed-spot-training-save-up-to-90-on-your-amazon-sagemaker-training-jobs/>

推論: API エンドポイントやバッチ推論

- 一般に作業負荷の大きい推論環境の構築を、**API1つで簡単に実現**
- 推論の負荷にあわせてGPUをアタッチできる**Elastic Inference**
- バッチ推論を使えば、**必要なときだけエンドポイントを利用可能**
- エンドポイントは**オートスケール対応**
- **A/Bテスト**をサポート

本番稼働用バリエーション					
モデル名	バリエーション名	インスタンスタイプ	初期インスタンス数	初期重量	アクション
linear-learner-2018-02-28-02-32-38-500	Logistic Regression	ml.m4.xlarge	1	0.7	編集 削除
sagemaker-tensorflow-py2-cpu-2018-02-17-01-06-59-578	DNN	ml.p3.2xlarge	2	0.2	編集 削除
decision-trees-sample-01-2018-01-16-11-49-32-223	Decision Tree	ml.c5.xlarge	3	0.1	編集 削除
モデルの追加					


オートスケールの設定やA/Bテスト用にリクエストの割り振りが可能

開発・学習・推論は個別に利用可能

例 1: 部署全員に対してマネージドノートブック環境を提供したい場合
管理不要のノートブックをホストする環境として SageMaker を利用



例 2: プロダクション環境がオンプレミスにすでにある場合
スケーラブルな学習環境としてのみ SageMaker を利用可能



例 3: オンプレミスに豊富な GPU クラスタを持っている場合
オンプレミスで学習済のモデルを AWS 上のプロダクション環境にデプロイ




アジェンダ


- 機械学習の課題に対する SageMaker のメリット
- SageMaker を利用した機械学習プロセス
- 機械学習の開発・学習・推論を効率化する基本機能
- まとめ

SageMaker の基本構成要素

SageMaker
Python SDK



Amazon S3



Amazon SageMaker



Amazon ECR

学習データ



学習スクリプト

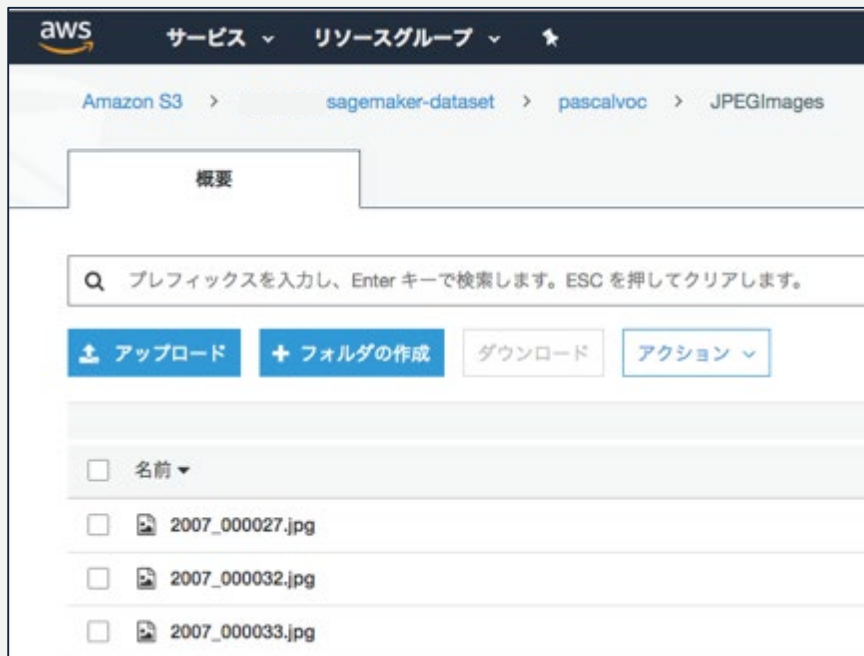


DL / ML
実行環境



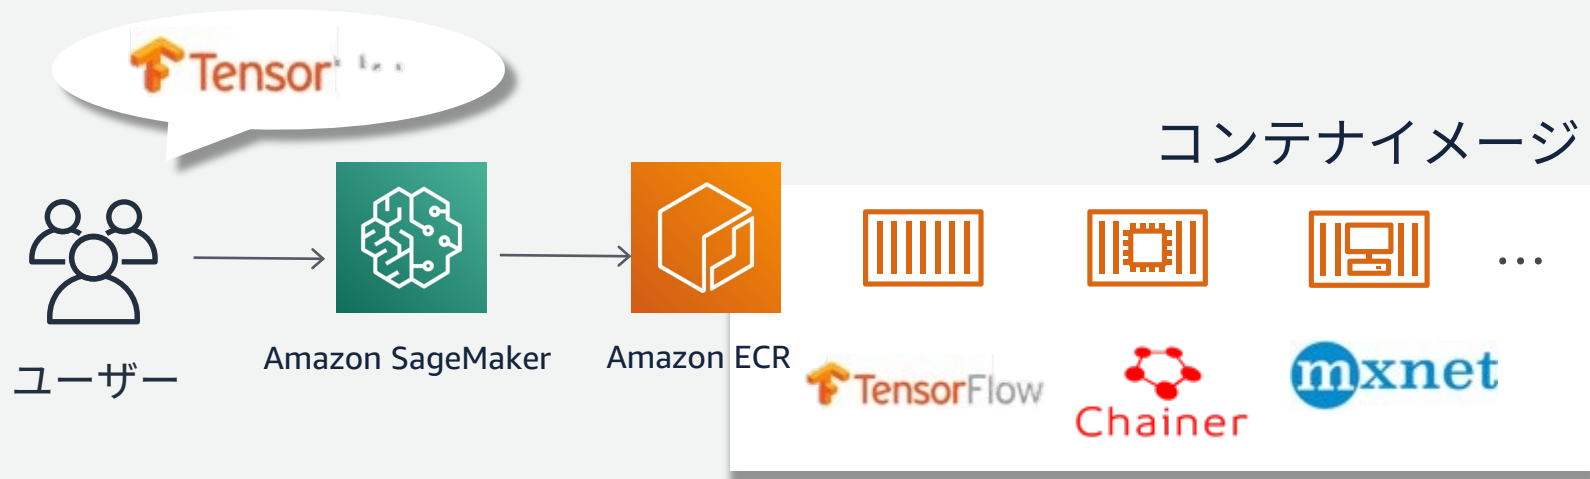
学習データの準備

- 学習データはオブジェクトストレージの Amazon S3 におく
- 学習用のコードで読める形式であれば、学習データの形式は自由
- コンソールからでも、API 経由でもアップロード可能



機械学習の実行環境をコンテナイメージで提供

- 実行環境をコンテナイメージとして Amazon ECR (Elastic Container Registry) におく
- ユーザは、自身が利用したい環境 (TensorFlow など) をコンテナイメージから選んで利用



SageMakerに合わせた学習・推論コードの書き方

```
class MLP(chainer.Chain):
    def __init__(self, n_units, n_out):
        super(MLP, self).__init__()
        ...

    def __call__(self, x):
        h1 = F.relu(self.l1(x))
        h2 = F.relu(self.l2(h1))
        return self.l3(h2)

if __name__ == '__main__':
    parser = argparse.ArgumentParser()
    parser.add_argument('--epochs', type=int, default=50)
    ...
    parser.add_argument('--test', type=str, default=os.environ['SM_CHANNEL_TEST'])
    args, _ = parser.parse_known_args()

    train_data = np.load(os.path.join(args.train, 'train.npz'))['images']
    ...

    model = L.Classifier(MLP(1000, 10))
    optimizer = chainer.optimizers.Adam()
    optimizer.setup(model)
    ...
    trainer.run()
    serializers.save_npz(os.path.join(args.model_dir, 'model.npz'), model)

def model_fn(model_dir):
    model = L.Classifier(MLP(1000, 10))
    serializers.load_npz(os.path.join(model_dir, 'model.npz'), model)
    return model.predictor
```

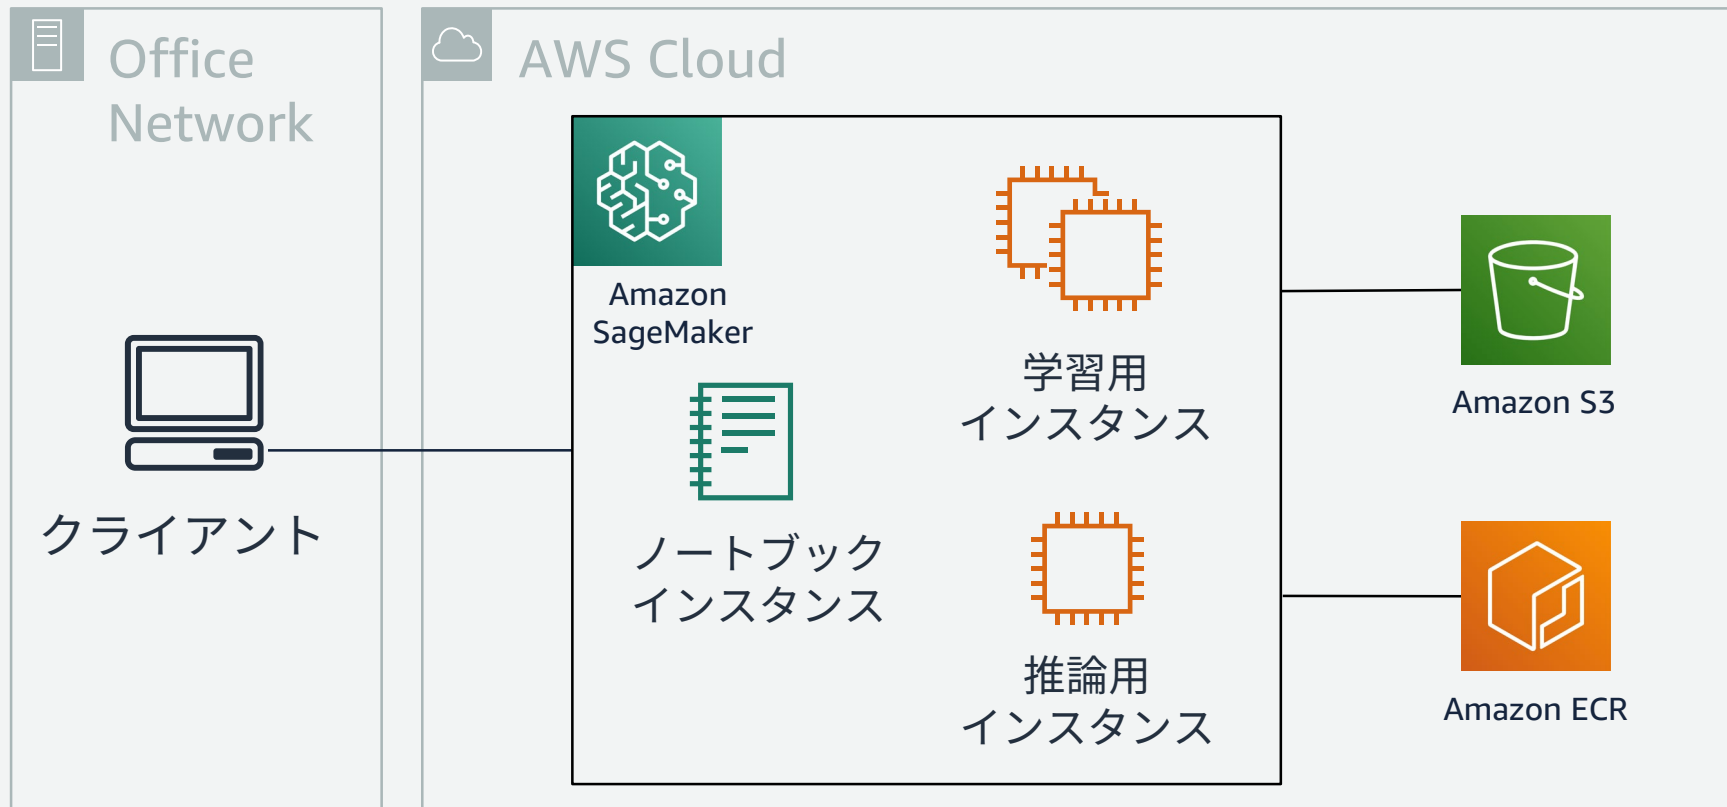
①環境変数の渡し方

Chainer の場合、基本的には main 関数の中に学習処理をベタ書きすれば OK
ハイパーパラメータや入力データのパス等は、SageMaker 側で引数として引き渡し、argparse で取り出す

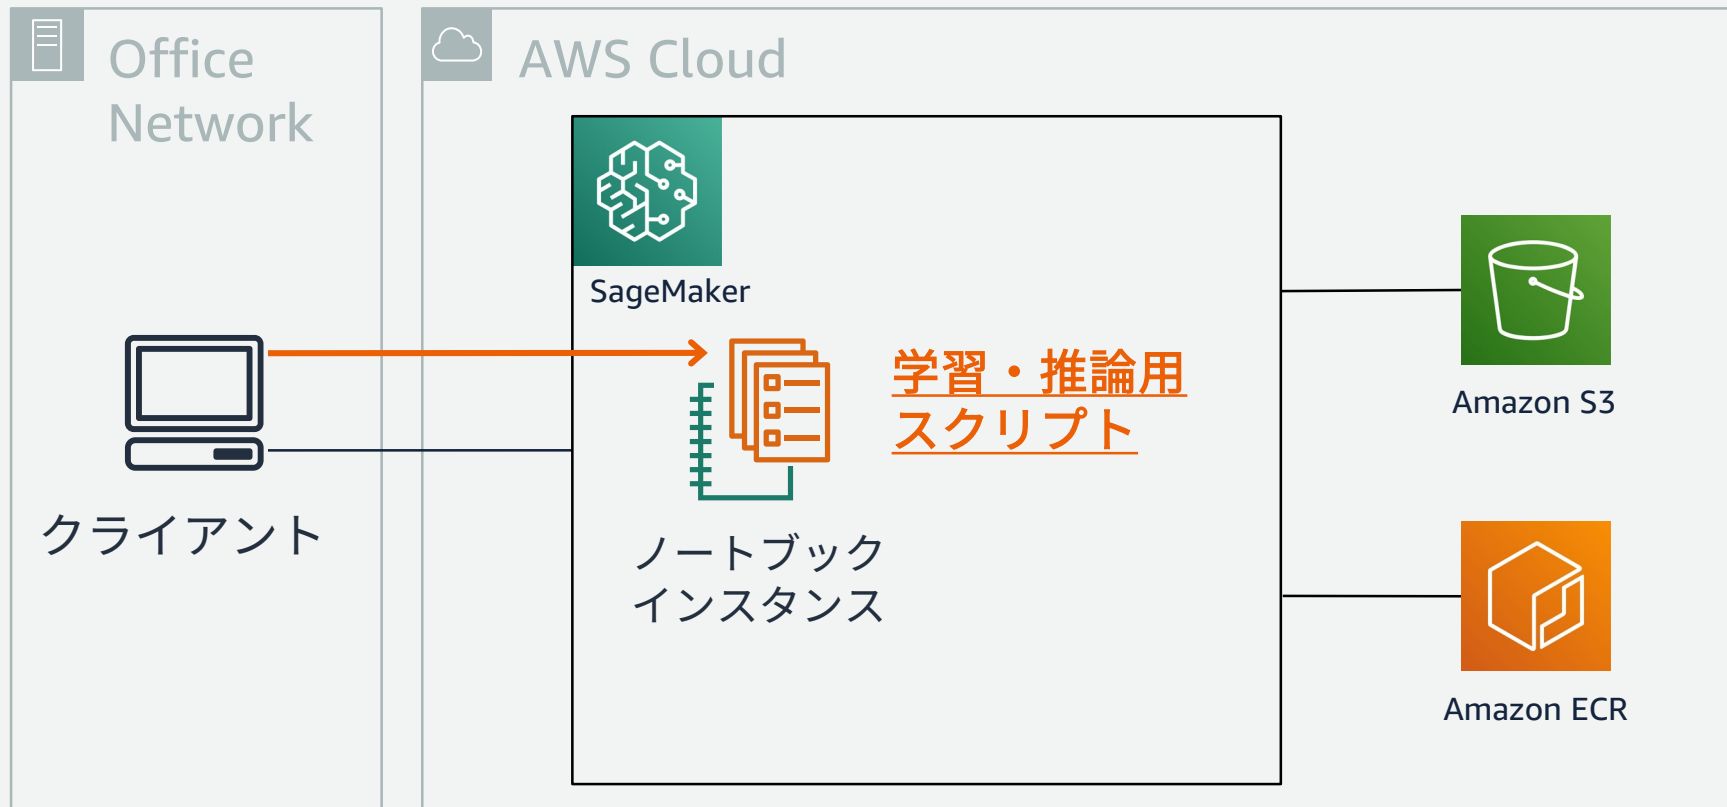
②データの入出力

推論エンドポイントにおけるモデルのロード処理を、`model_fn()` 内に記述しておく。あとは SageMaker で提供される推論コンテナが、そのモデルを使ってくれる

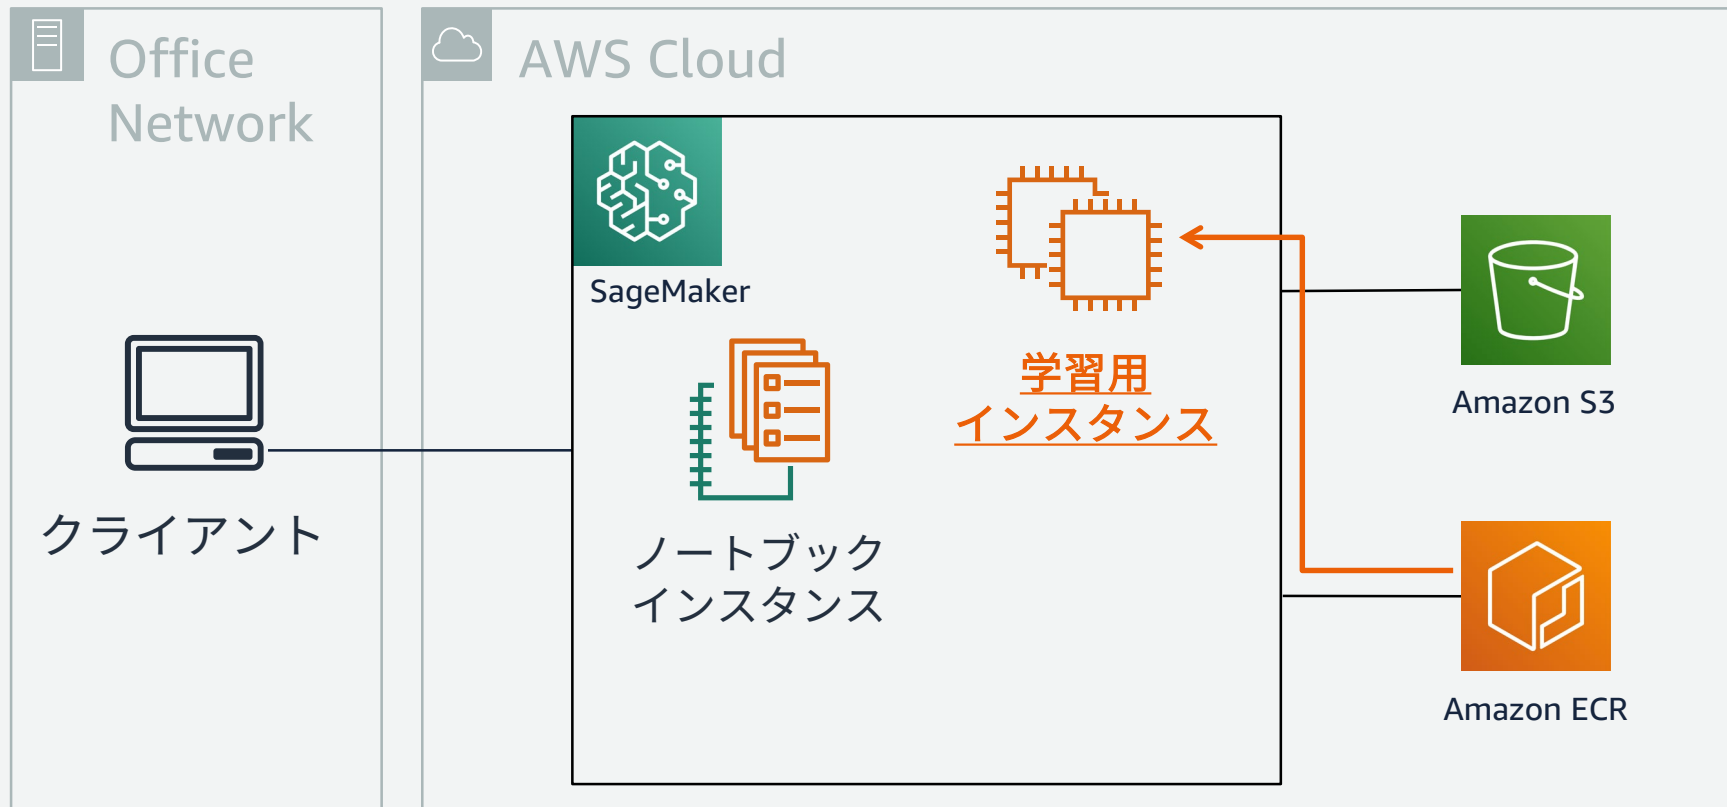
Amazon SageMaker のアーキテクチャ



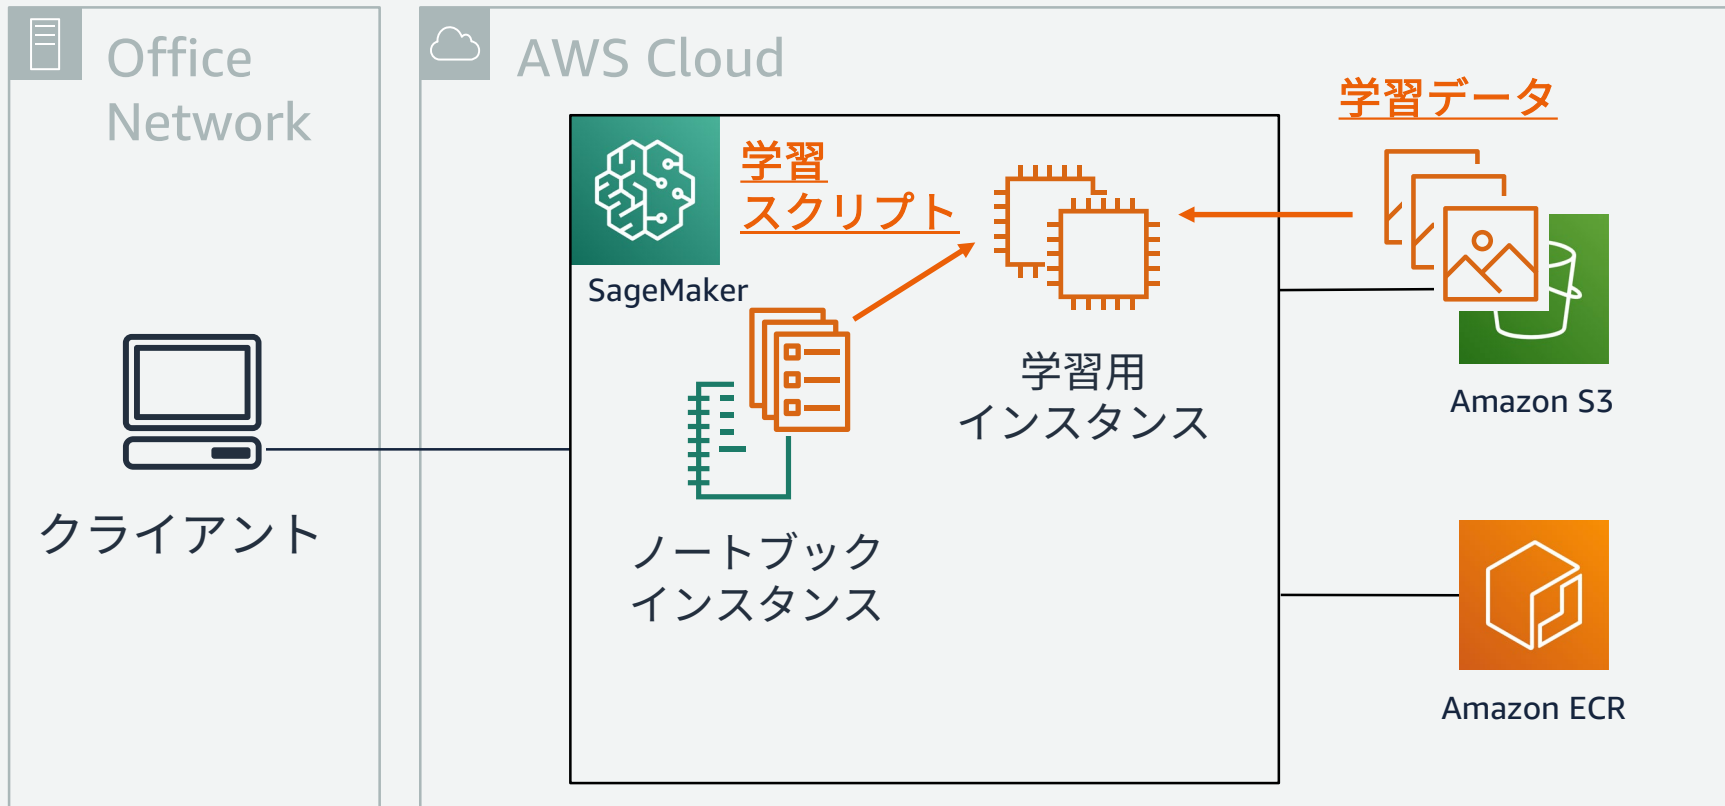
1. ノートブックインスタンスへコードを移行



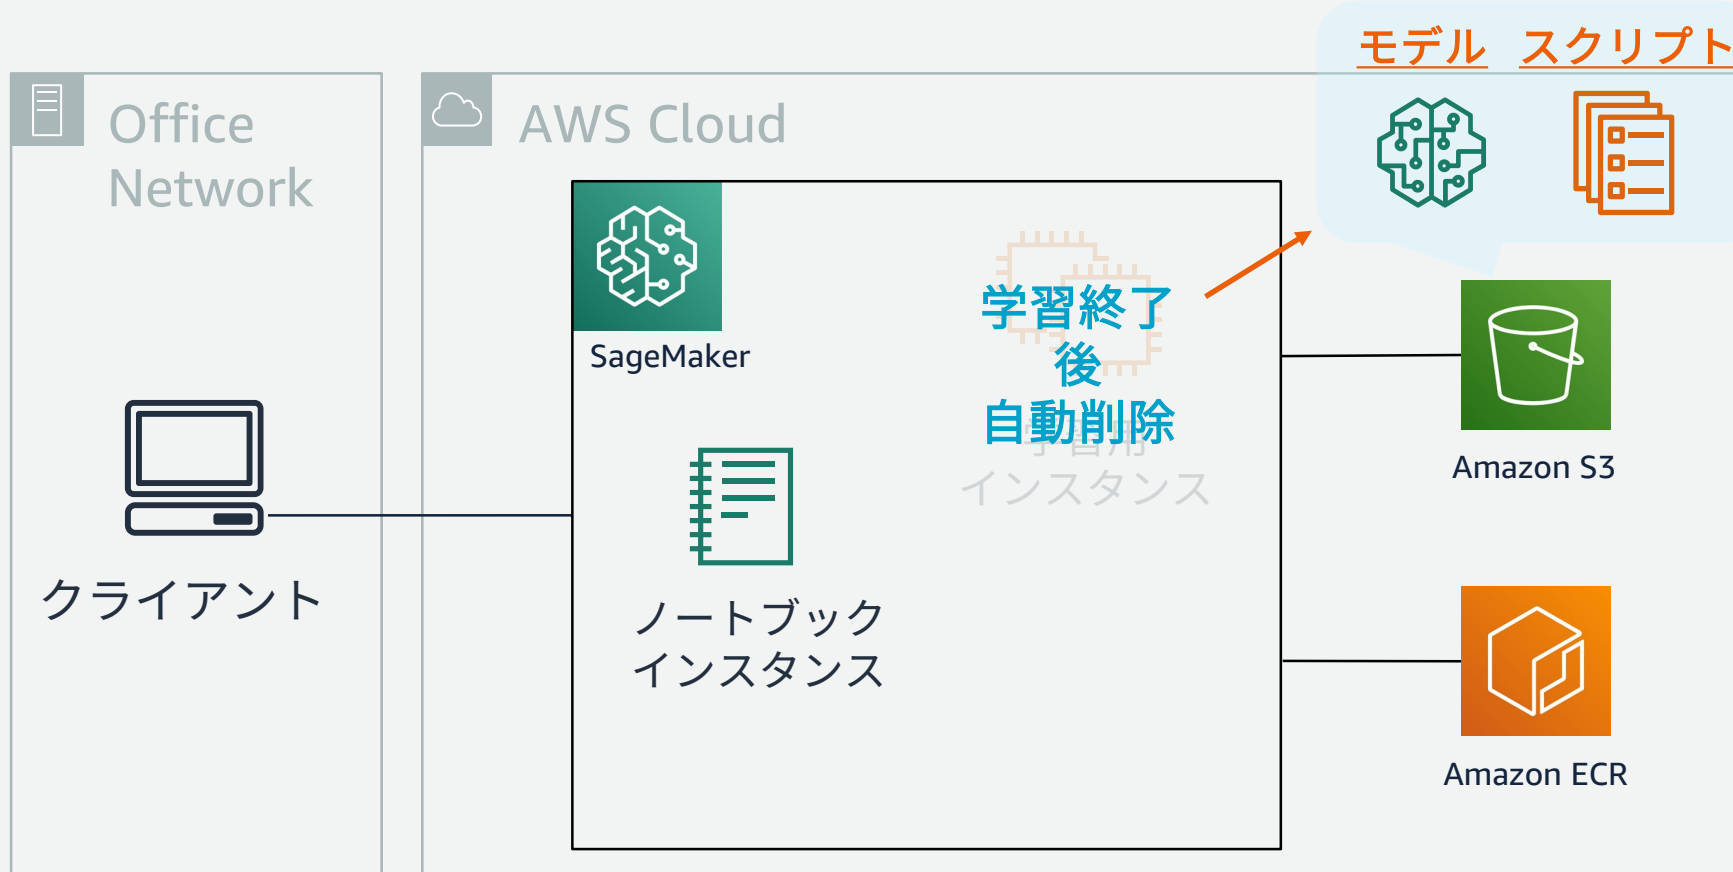
2. コンテナイメージから学習用インスタンスを起動



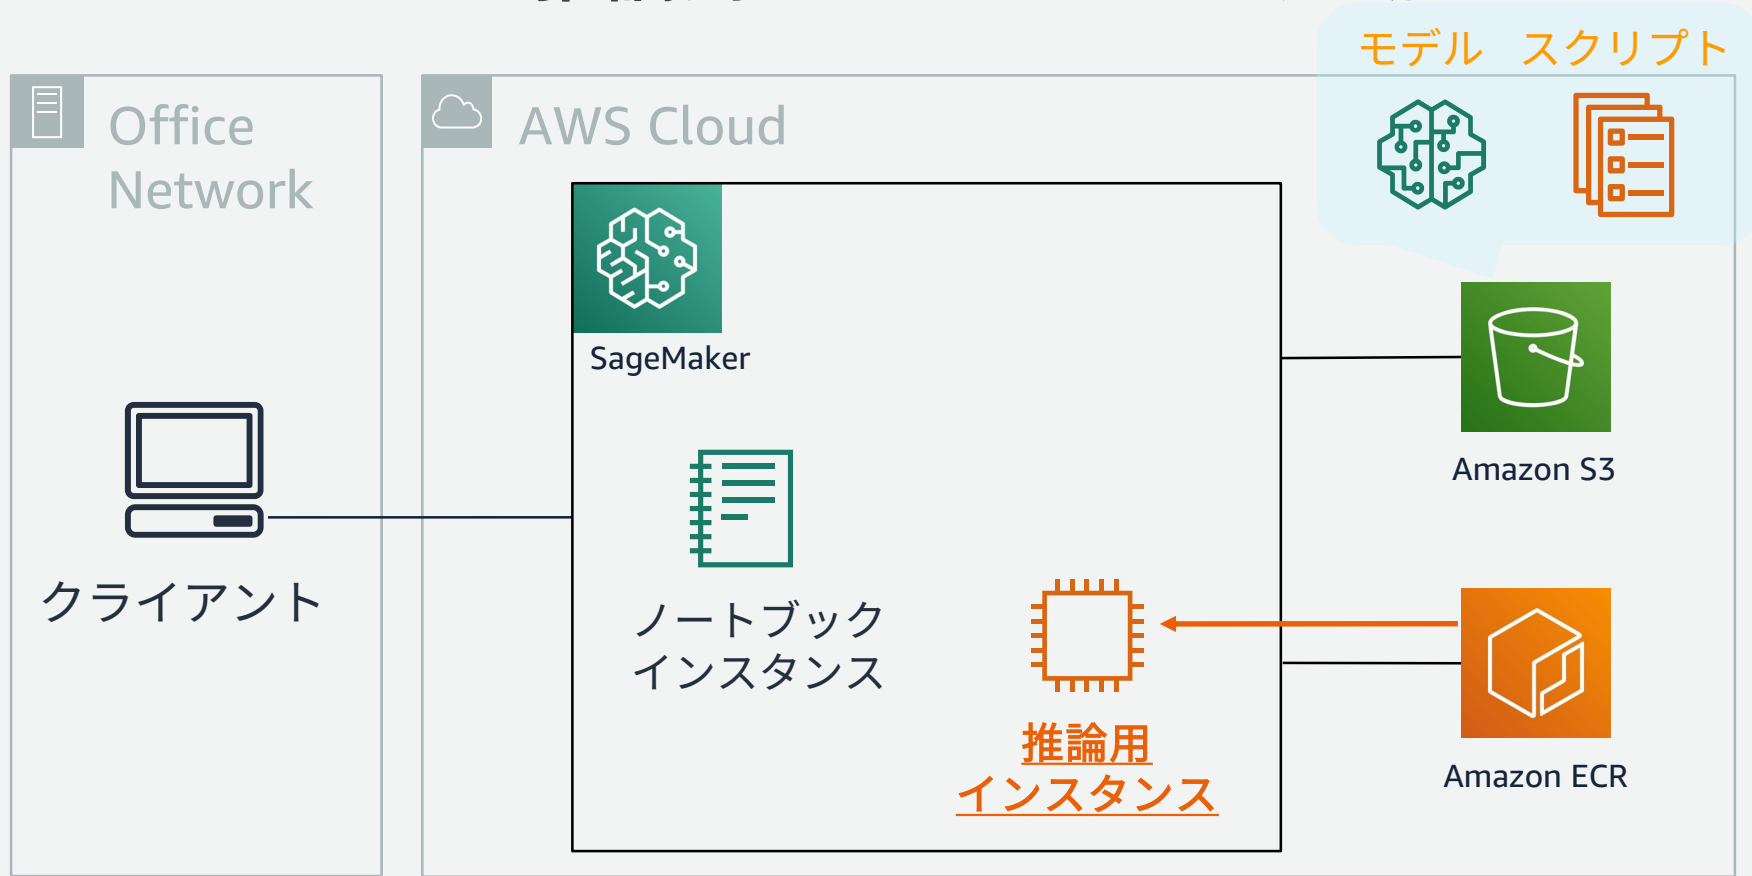
3. データとスクリプトを読み込み学習を実行



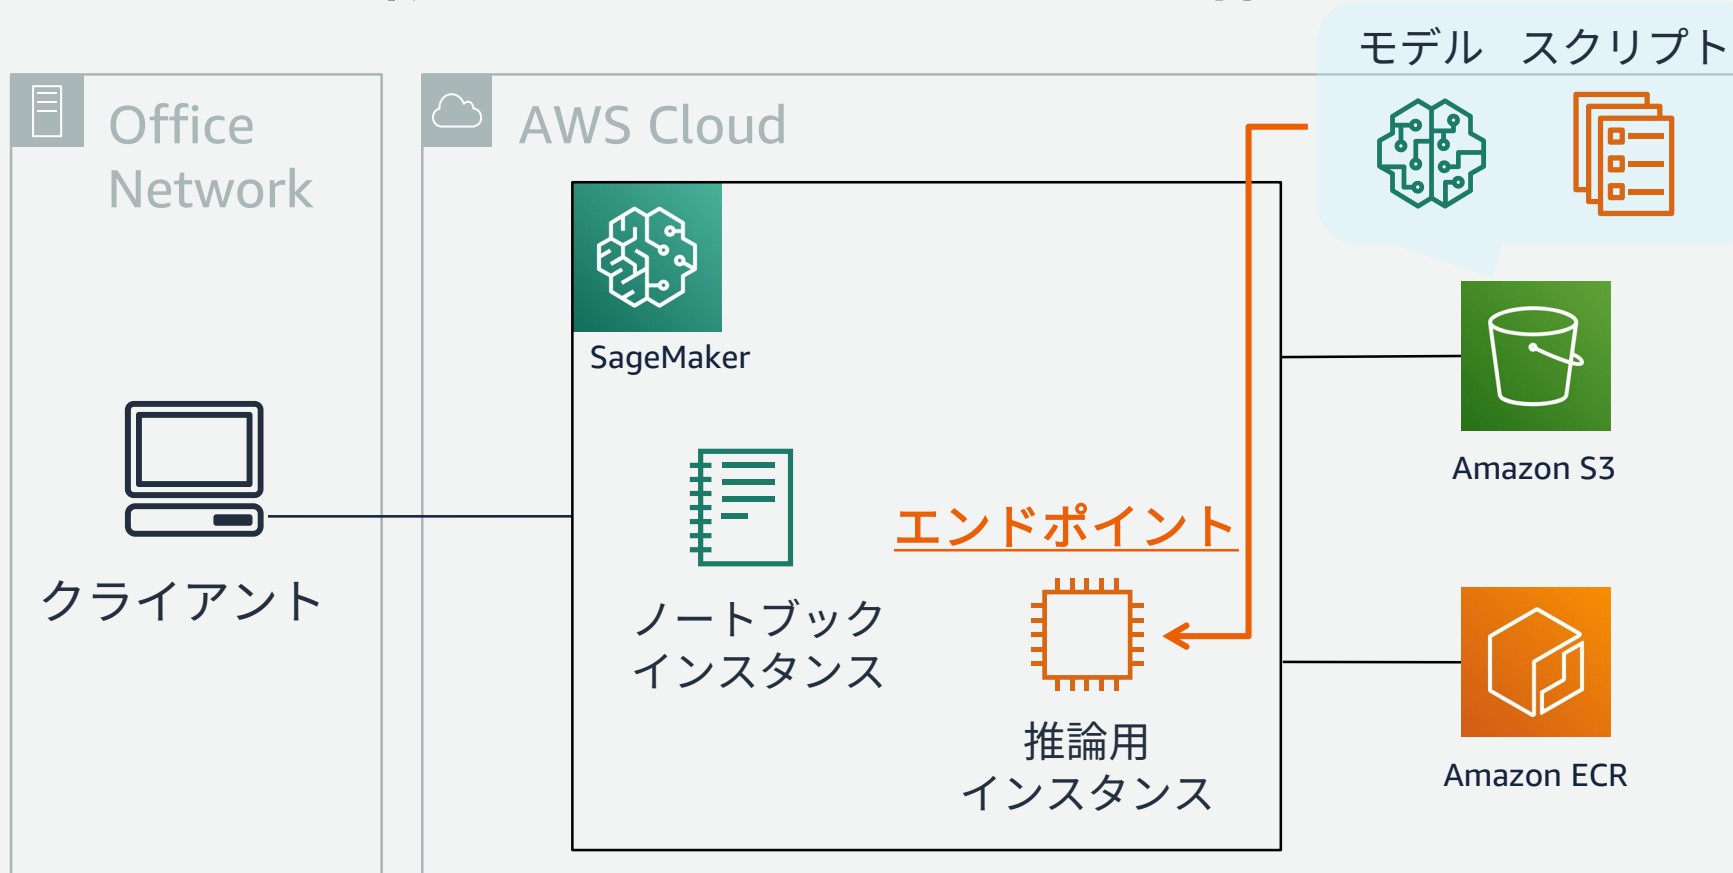
4. 学習が完了すると学習インスタンスは自動削除



5. コンテナから推論用インスタンスを起動



6. モデルを読み込みエンドポイント作成



SageMaker Python SDK による 学習・推論の流れ

```
from sagemaker.chainer.estimator import Chainer
```

```
estimator = Chainer(entry_point='mnist.py',  
                    train_instance_count=1,  
                    train_instance_type='ml.p2.xlarge')
```

```
chainer_estimator.fit({'train': train_input})
```

```
predictor = estimator.deploy(initial_instance_count=1,  
                             instance_type='ml.m4.xlarge')  
response = predictor.predict(image_data)
```

```
transformer = estimator.transformer(instance_count=1,  
                                    instance_type='ml.m4.xlarge')  
transformer.transform(test_data,  
                      content_type='text/csv')
```

ジョブを実行するためにまず、Estimator クラスのオブジェクトを作成
Chainer の場合は、専用の Estimator が
ある。ローカルにある開発済みのスクリ
プトを指定

`fit()` を実行すると、指定したインスタ
ンスが立ち上がり、用意された Chainer
コンテナを読み込み、S3 データを使って
学習ジョブを実行する


学習が終わったら、`deploy()` メソッドを
叩くと、裏側でエンドポイントが作成さ
れる。`predict()` で実際に推論を実施可
能

バッチ推論は `transformer.transform()`
で実行。S3 から対象データを読み込んで、
推論結果も S3 にファイル出力

アジェンダ

- 機械学習の課題に対するSageMakerのメリット
- SageMakerを利用した機械学習プロセス
- 機械学習の開発・学習・推論を効率化する基本機能
- まとめ

開発・学習・推論を効率化する基本機能



Amazon S3



Amazon SageMaker



Amazon ECR

学習データ




学習スクリプト



DL / ML
実行環境



開発・学習・推論を効率化する基本機能



Amazon S3



Amazon SageMaker



Amazon ECR

学習データ



- 学習データの前処理
- 大容量データの読み込み

学習スクリプト

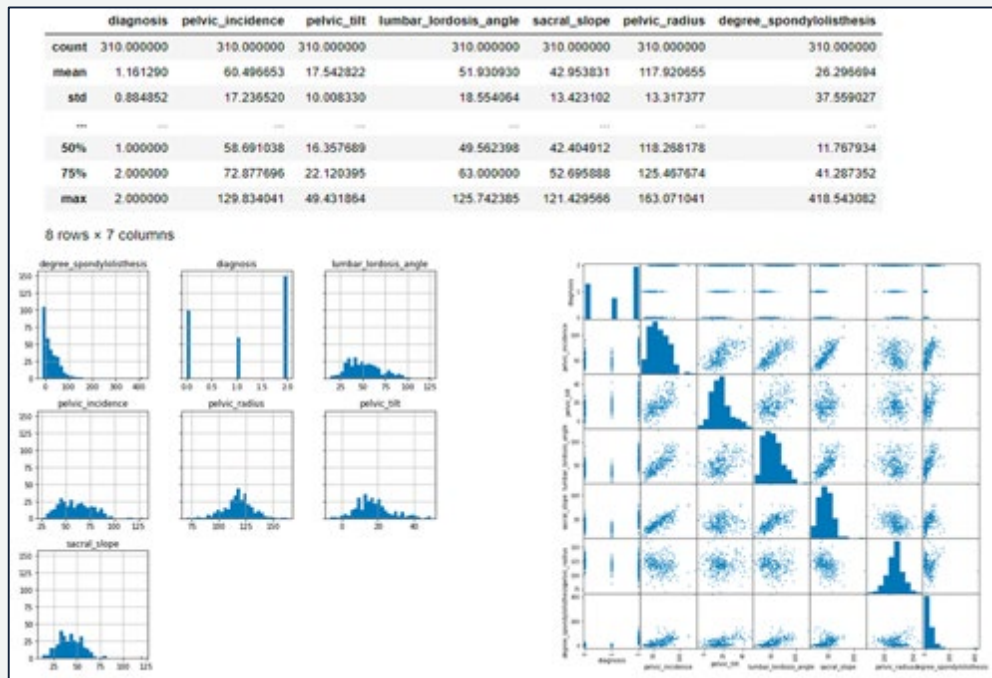


DL / ML
実行環境



ノートブックインスタンスでのデータ前処理

- EBSを16TBまで拡張可能
- 前処理に便利なNumpy, Pandasなどのパッケージがプリインストール済み
- Jupyterで対話的に処理できる
- 前処理用に、EMRといった他のサービス呼び出すことも可能

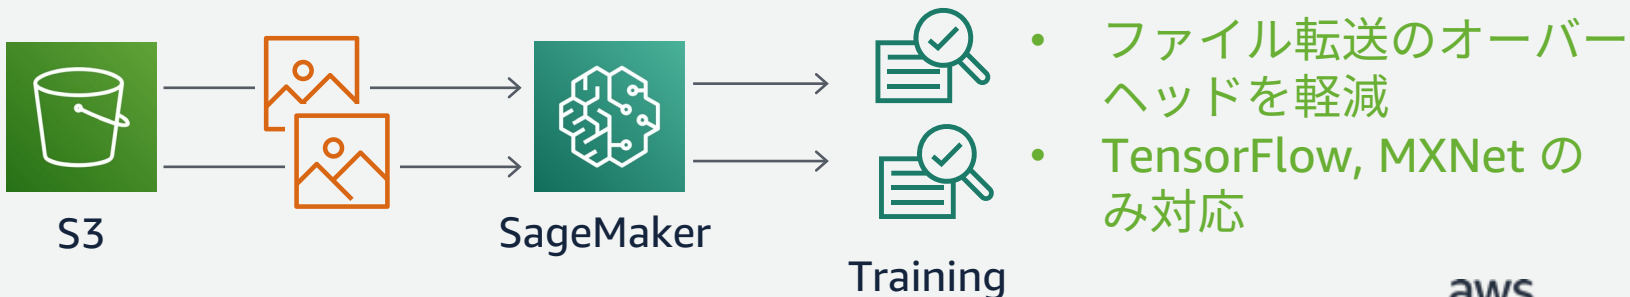


S3からのファイル転送

FILE モード (Default): 全ファイルをダウンロードして学習

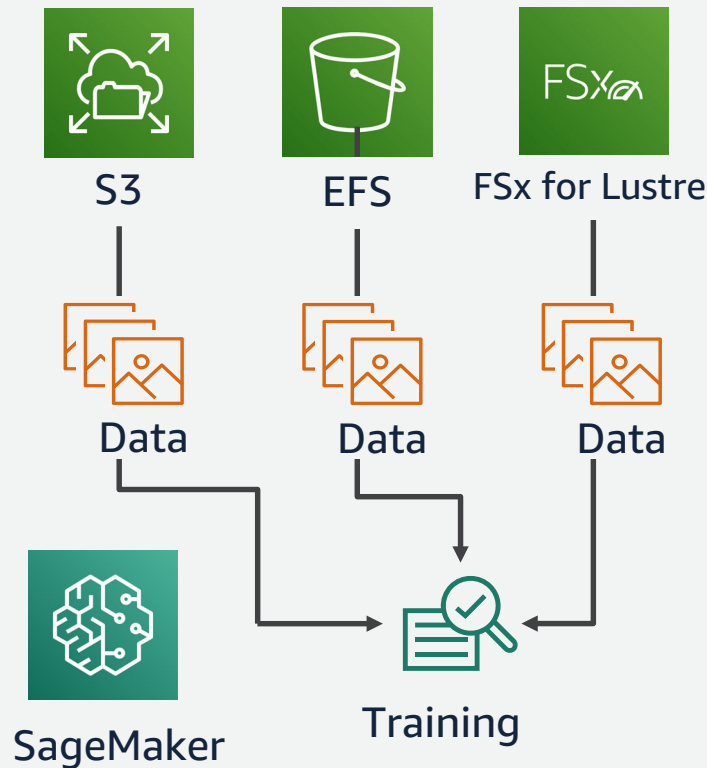


PIPE モード: ダウンロードしながら非同期に学習を実施




学習時のファイルシステムにEFSとFSx Lustreが対応 NEW!

- 学習用のファイルシステムとして、EFS と FSx Lustre を直接指定可能に
- 学習ジョブの開始時に S3から学習インスタンスのEBSへのデータ転送にかかっていたオーバーヘッドが削減される
- 同一ファイルを用いた反復の学習ジョブなどの場合には、高速キャッシュとしてファイルシステムを利用できる



開発・学習・推論を効率化する基本機能



Amazon S3



Amazon SageMaker



Amazon ECR

学習データ



学習スクリプト



DL / ML
実行環境



- ビルトインアルゴリズム
- 自前でスクリプトを書く

SageMaker ビルトインアルゴリズム

～ 機械学習モデル ～

モデル名	教師データ	アルゴリズム説明	利用用途の例
Linear Learner	あり	線形回帰	分類・回帰などの分析
XGBoost	あり	XGBoost, 勾配ブーストツリー (eXtreme Gradient Boosting)	分類・回帰などの分析
PCA	なし	主成分分析 (Principal Component Analysis)	次元削減
k-means	なし	K平均法	クラスタリング
k-NN	あり	K近傍法	クラスタリング
Factorization Machines	あり	行列分解	レコメンド, 回帰, 分類
Random Cut Forest	なし	robust random cut tree	時系列データの異常検知
LDA (Latent Dirichlet Allocation)	あり	生成的統計モデル	トピックモデル

※ LDAのオリジナルは教師なし

<https://docs.aws.amazon.com/sagemaker/latest/dg/algos.html>

SageMaker ビルトインアルゴリズム ~ ディープラーニング モデル ~

	モデル名	教師データ	アルゴリズム	利用用途の例
画像処理	Image classification	あり	ResNet	画像の多値分類
	Object Detection	あり	SSD (Single Shot multibox Detector)	物体の画像内領域をバウンディングボックスで検出
	Semantic Segmentation	あり	FCN, PSP, DeepLabV3 (ResNet50, ResNet101)	ピクセル単位の画像内の物体領域検出
自然言語処理	seq2seq	あり	Deep LSTM	テキスト要約, 音声認識
	Neural Topic Model	なし	NTM, LDA	テキストデータの構造化
	Blazing text	なし	Word2Vec	センチメント分析
		あり	Text Classification	単語のマイニング
	Object2Vec	あり	Word2Vec 一般ベクトル化	分類, レコメンド
時系列	DeepAR Forecasting	あり	Autoregressive RNN	確率的な時系列予測
異常検知	IP Insights	なし	NN (IPとentityの関連付け)	悪意あるIPアドレスの検出

Image Classification

- ILSVRC 2015で優勝したResNet による高精度な画像認識
- AWS が学習済みのモデルを提供しており、ユーザ固有のデータに合わせて追加学習 (転移学習) が可能

dog



cat



https://docs.aws.amazon.com/ja_jp/sagemaker/latest/dg/image-classification.html

ビルトインアルゴリズムを利用した場合のコード

- 使いたいアルゴリズムの **コンテナイメージ** を呼び出す
- S3のデータを呼び出して fit すれば学習が行われる
- インスタンス数を指定するだけで、 **分散学習** がすぐに実行できる

```
from sagemaker.estimator import Estimator

estimator = Estimator(container, アルゴリズムに対応したコンテナ
                        train_instance_count=1,
                        train_instance_type='ml.c4.xlarge')

estimator.fit({ 'train': s3_train_data }) 学習の実行
```

AWS Marketplace から機械学習のモデルを購入する


- AWSマーケットプレイス経由で、SageMaker上で使う機械学習モデルの売買が可能。小売、メディア向けなど200以上のアルゴリズムがすでに公開済み

アルゴリズム購入者：

Amazon SageMaker で学習ジョブおよび、推論エンドポイント（バッチ推論ジョブもok）

アルゴリズム購買者：

モデルの中身を秘匿してモデルの出品が可能



The screenshot displays the AWS Marketplace interface. The top navigation bar includes 'aws marketplace', a search bar, and links for 'Categories', 'Delivery Methods', 'Solutions', 'Migration Mapping Assistant', 'Your Saved List', 'Partners', and 'Sell in AWS'. The main content area is titled 'All Categories (212 results) showing 1 - 10'. On the left, there are filters for 'Categories' (Infrastructure Software (28), Business Software (25), Machine Learning (212), IoT (10)), 'Vendors' (RocketML (23), Perception Health (17), Sensifai (16), Cloudwick (11), Figure Eight (11), Persistent Systems (10), Twinword Inc. (8), Modjoul (8), Amazon Web Services (8), Intel® AI (7), Show more), 'Software Pricing Plans' (Free (67), Hourly (145)), and 'Software Free Trial' (Free Trial (92)). The main list of results includes:

- Cortexica BodyParts Localiser (CPU)**: Detect different body parts within an image. Sold by Cortexica.
- Named Entity Recognition**: Chatbot NER: Named Entity Recognition for chatbots. Sold by Haptik.
- Celebrity Recognition in Videos**: Celebrity and Famous People Recognition in Videos. Sold by Sensifai.
- Botnet Attack Detection**: Detect the type of botnet attack. Sold by Cloudwick.
- Background Noise Classifier (GPU)**: This model is trained to recognize if there is any sort of background noise. Sold by Figure Eight.

MLマーケットプレイス 価格

SageMakerコンソール, SDK, AWS CLIからアクセス可能

価格：モデルパッケージの利用に対し、ソフトウェア使用料とAWSのリソース使用料を利用時間に応じて課金

- アルゴリズム学習
- モデルリアルタイム推論
- モデルバッチ推論

Pricing Information

Use this tool to estimate the software and infrastructure costs based your configuration choices. Your usage and costs might be different from this estimate. They will be reflected on your monthly AWS billing reports.

Estimating your costs

Choose your region and launch option to see the pricing details. Then, modify the estimated price by choosing different instance types.

Region: US East (N. Virginia)

Fulfillment Option: Amazon SageMaker

Software Pricing

Algorithm Training	\$1/hr
running on ml.p3.8xlarge ▶	
Model Realtime Inference	\$2.6/hr
running on ml.p3.2xlarge ▶	
Model Batch Transform	\$2.6/hr
running on ml.p3.8xlarge ▶	

Infrastructure Pricing

SageMaker Algorithm Training	\$17.136/host/hr
running on ml.p3.8xlarge ⓘ	
SageMaker Realtime Inference	\$4.284/host/hr
running on ml.p3.2xlarge ⓘ	
SageMaker Batch Transform	\$17.136/host/hr
running on ml.p3.8xlarge ⓘ	


Algorithm Training

The table shows current software and infrastructure pricing for services hosted in US East (N. Virginia). Additional taxes or fees may apply.

InstanceType	Algorithm/hr	SageMaker/hr	Total/hr
<input type="radio"/> ml.p2.xlarge	\$1	\$1.26	\$1.36
<input type="radio"/> ml.p2.8xlarge	\$7	\$10.08	\$10.78
<input type="radio"/> ml.p2.16xlarge	\$1	\$20.16	\$21.16
<input type="radio"/> ml.p3.2xlarge	\$4	\$4.284	\$4.684
<input checked="" type="radio"/> ml.p3.8xlarge	\$1	\$17.136	\$18.136
<input type="radio"/> ml.p3.16xlarge	\$2	\$34.272	\$36.272

学習・推論モデルは
インスタンスごとに
価格が設定される

開発・学習・推論を効率化する基本機能



Amazon S3



Amazon SageMaker



Amazon ECR

学習データ



学習スクリプト



DL / ML
実行環境



よく使われる機械学習
環境をコンテナで提供

様々なコンテナイメージの提供

- 一般的に利用される機械学習のフレームワークは、コンテナイメージとして提供されており、ユーザは必要なものを選んで利用できる



- フレームワークごとの **Docker** ファイルは全て **github** で公開
- ユーザーは公開された **Docker** を自由にカスタムし，自身のコンテナを **ECR** に上げることでカスタム環境を **SageMaker** で利用できる

ご自身で学習スクリプトを開発される場合

- SageMaker でサポートしているフレームワーク一覧 2019年2月13日時点の情報です

	フレームワーク	SageMaker container サポートバージョン
Deep learning	TensorFlow	Legacy mode: 1.4.1, 1.5.0, 1.6.0, 1.7.0, 1.8.0, 1.9.0, 1.10.0 Script mode: 1.11.0, 1.12.0, 1.13.0
	Chainer	4.0.0, 4.1.0, 5.0.0
	PyTorch	0.4.0, 1.0.0, 1.1.0
	MXNet	0.12.1, 1.0.0, 1.1.0, 1.2.1, 1.3.0, 1.4.0, 1.4.1.
ML	scikit-learn	0.20.0

<https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker>

TensorFlow <https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker/tensorflow>

Chainer: <https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker/chainer>

PyTorch: <https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker/pytorch>

MXNet: <https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker/mxnet>

Sklearn: <https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker/sklearn>

TensorFlow

Using TensorFlow with SageMaker Python SDK

https://sagemaker.readthedocs.io/en/stable/using_tf.html

TensorFlow SageMaker Estimators and Models

<https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker/tensorflow>

SageMaker TensorFlow containers repositories here:

Training: <https://github.com/aws/sagemaker-tensorflow-container>

Serving: <https://github.com/aws/sagemaker-tensorflow-serving-container>

PyTorch

Using PyTorch with SageMaker Python SDK

https://sagemaker.readthedocs.io/en/stable/using_pytorch.html

PyTorch SageMaker Estimators and Models

<https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker/pytorch>

SageMaker PyTorch containers repositories

<https://github.com/aws/sagemaker-pytorch-container>

SageMaker コンテナによる学習と推論のメリット

学習

- 分散学習を簡単に行うことができる
- ハイパーパラメータ最適化機能を提供，並列実行可能
- コンテナが動く環境であれば手元のPCでも実行可 (ローカルモード)

推論

- リアルタイム推論とバッチ推論を利用可能
- 適切なGPUをアタッチできるElastic Inferenceによる推論高速化
- オートスケーリング, A/Bテスト可能なエンドポイントを簡単に構築

分散学習が簡単に実装できる

インスタンス間の通信など**インフラ部分は実装済**

- 学習用APIへのリクエスト

```
estimator = TensorFlow(entry_point='train.py',  
                        train_instance_type='ml.p3.2xlarge',  
                        train_instance_count=2,  
                        )
```

インスタンスタイプと
インスタンス数を指定

- 学習コード内の実装 (例: TensorFlowでHorovodを利用)

```
opt = tf.train.AdagradOptimizer(0.01 * hvd.size())  
opt = hvd.DistributedOptimizer(opt)
```

コード自体は分散学習
対応で書く必要がある

ハイパーパラメータ最適化

- Deep Learning では、多くのパラメータを調整する必要がある
 - 学習率
 - Dropout率
 - バッチサイズ, ...
- 学習ジョブの並列実行を活用し、最適なパラメータを高速に探索
- デフォルトはベイズ最適化
- ランダム探索も選択可能に **NEW!**
- HPO ウォームスタートも利用可能



ハイパーパラメータ最適化 (HPO) の書き方

1. Chainer estimator 初期化の際に hyperparameter を指定
2. hyperparameter_ranges に探索したいハイパーパラメータを連続値またはリストで範囲指定
3. Tunerジョブを指定, Hyperparameter_rangesや最適化の目的となるメトリクスを定義する
4. .fit() で**ベイズ最適化**によるHPOジョブスタート.

```
from sagemaker.chainer import Chainer
```

```
estimator = Chainer(entry_point="mnist.py",  
                    role=role,  
                    framework_version='5.0.0',  
                    train_instance_count=1,  
                    train_instance_type='ml.m4.xlarge',  
                    ① hyperparameters={'epochs': 30, 'batch-size': 256})
```

```
hyperparameter_ranges = {'lr': ContinuousParameter(0.001, 0.1),  
                          ② 'batch-size': CategoricalParameter([32,64,128,256,512])}
```

```
tuner = HyperparameterTuner(estimator,  
                             ③ objective_metric_name,  
                             hyperparameter_ranges,  
                             metric_definitions,  
                             max_jobs=9,  
                             max_parallel_jobs=3,  
                             objective_type=objective_type)
```

```
tuner.fit({'training': inputs})
```

<https://github.com/aws/sagemaker-python-sdk#sagemaker-automatic-model-tuning>

<https://aws.amazon.com/jp/blogs/news/amazon-sagemaker-automatic-model-tuning-becomes-more-efficient-with-warm-start-of-hyperparameter-tuning-jobs/>



ローカル環境での実行

1. Notebook Instance の上で学習・推論を行う
 - デバッグの際、Dockerから学習・推論インスタンスを立ち上げる時間が勿体無い
 - `train_instance_type='local'` とする，Notebook Instance のインスタンスサイズをデバッグ用途に合わせる
2. オンプレミス環境でSageMakerを動かす
 - Docker, AWS SDK, SageMaker Python SDK をインストール
SageMakerの学習・推論ジョブを実行可能
 - オンプレミスとのハイブリッドなSageMaker環境が作成できる
 - `train_instance_type='local'` でローカルで学習を実行

https://aws.amazon.com/jp/blogs/news/sagemaker_from_onpremises/

SageMaker コンテナによる学習と推論のメリット

学習

- 分散学習を簡単に行うことができる
- 並列実行可能でハイパーパラメータ最適化も可能
- コンテナが動く環境であれば手元のPCでも実行可 (ローカルモード)

推論

- リアルタイム推論とバッチ推論を利用可能
- 適切なGPUをアタッチできるElastic Inferenceによる推論高速化
- オートスケーリング, A/Bテスト可能なエンドポイントを簡単に構築

リアルタイム推論

- `deploy()` を呼ぶだけでエンドポイントを構築でき、APIサーバ構築に関する作業は不要
- Web APIのURLが発行され、URL にリクエストを送ると推論できる
- エンドポイント起動中は料金がかかる

エンドポイント設定

名前

chainer-ssd-2019-[redacted]

URL

https://runtime.sagemaker.us-west-2.amazonaws.com/endpoints/chainer-ssd-2019-[redacted]
[redacted]/invocations

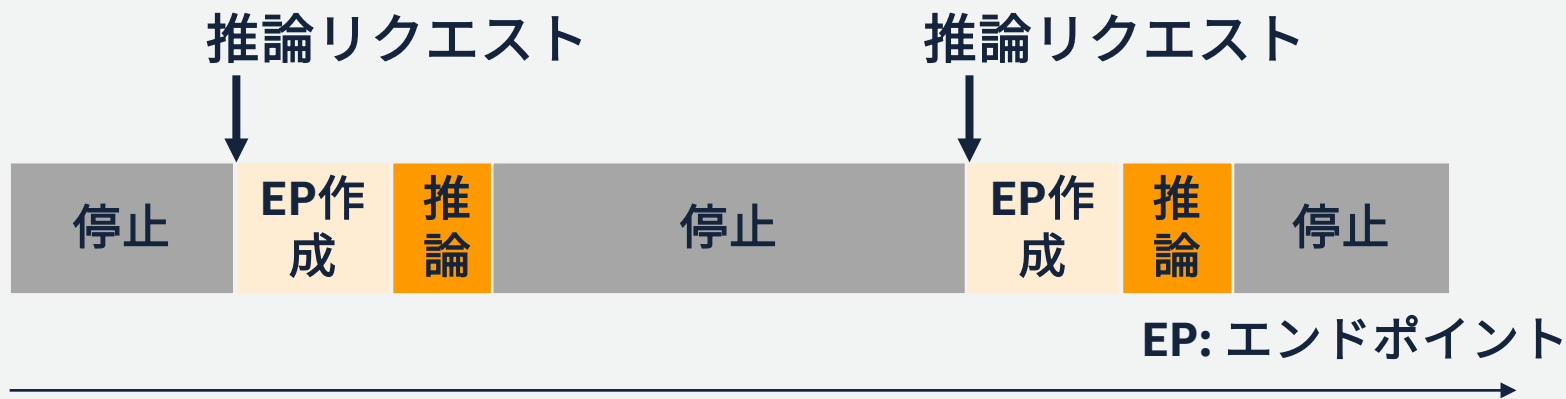
ARN

arn:aws:sagemaker:us-west-2:373011628954:endpoint/chainer-ssd-2019-[redacted]

[APIの詳細](#) 

バッチ変換ジョブ (バッチ推論)

- リアルタイム推論が必要でない場合、推論エンドポイントを維持するとコストがかかる
- バッチ推論では、推論が必要なときに、エンドポイントを作成し、推論後のエンドポイント削除を自動で行う



CPU インスタンスの計算を GPU でアクセラレート

- スタンドアロンのGPU は主に学習に最適化されており、推論には大きすぎる
- 適切なGPU リソースをCPUに関連づけることで、**高速な推論を低コストで実行**



インスタンス	EIA	推論速度 (msec)	価格 (\$/hour)
c5.large	なし	230 msec	\$0.085
c5.large	eia1.medium	46 msec	\$0.22
p2.xlarge	なし	42 msec	\$0.90

価格は 2018/11 時点のバージニア北部のもの

<https://aws.amazon.com/jp/blogs/news/amazon-elastic-inference-gpu-powered-deep-learning-inference-acceleration/>

Amazon Elastic Inference

- 推論に適した低コストのGPU駆動のアクセラレーションを，CPU の EC2 および SageMaker インスタンスに適用． DL 実行コストを最大75%削減
- 利用方法
 - エンドポイントのインスタンスにEIAアタッチして利用
 - ローカルモード推論時は SageMaker Notebook インスタンスにEIAをアタッチ

Accelerator type	TFLOPS FP32 throughput	TFLOPS FP16 throughput	Memory in GB
ml.eia1.medium	1	8	1
ml.eia1.large	2	16	2
ml.eia1.xlarge	4	32	4

<https://docs.aws.amazon.com/sagemaker/latest/dg/ei.html>

機械学習パイプライン全体の支援

- 2018年のre:Inventで、開発・学習・推論に対する基本となる機能に加えて、ラベリングやモデル変換をサポート
- パイプライン全体を管理する機能も追加



ラベリング




開発



学習



モデル変換



推論

機械学習パイプライン全体の支援

- 2018年のre:Inventで、開発・学習・推論に対する基本となる機能に加えて、ラベリングやモデル変換をサポート
- パイプライン全体を管理する機能も追加



ラベリング




開発



学習



モデル変換



推論

Git 統合によりレポジトリからの直接学習が可能に

- SageMaker 上で Git レポジトリを登録しておくことで、ノートブックインスタンス起動時に clone される
- Amazon SageMaker Python SDK で学習/ホスティングする際に Git レポジトリからスクリプトを直接指定可能に

```
git_config = {'repo': 'https://github.com/awslabs/amazon-sagemaker-examples.git',  
              'branch': 'training-scripts'}  
  
estimator = TensorFlow(entry_point='train.py',  
                       source_dir='char-rnn-tensorflow',  
                       git_config=git_config,  
                       train_instance_type=train_instance_type,  
                       train_instance_count=1,  
                       role=sagemaker.get_execution_role(), # このノートブックで使用し  
                       framework_version='1.13',  
                       py_version='py3',  
                       script_mode=True)
```

NEW!

機械学習パイプライン全体の支援

- 2018年のre:Inventで、開発・学習・推論に対する基本となる機能に加えて、ラベリングやモデル変換をサポート
- パイプライン全体を管理する機能も追加



ラベリング




開発



学習



モデル変換



推論

学習ジョブの検索機能

NEW!

- 学習ジョブ名や学習時に指定したタグなどで、過去に実施した学習ジョブを検索できる
- 学習時の精度を正規表現で記録していれば、コンソール上でソートが可能で、最も良い学習結果を後で探ることができる

▼ 検索

プロパティ: tags.Project 演算子: Equals 値: Project_Binary_Classifier 削除

行を追加

検索

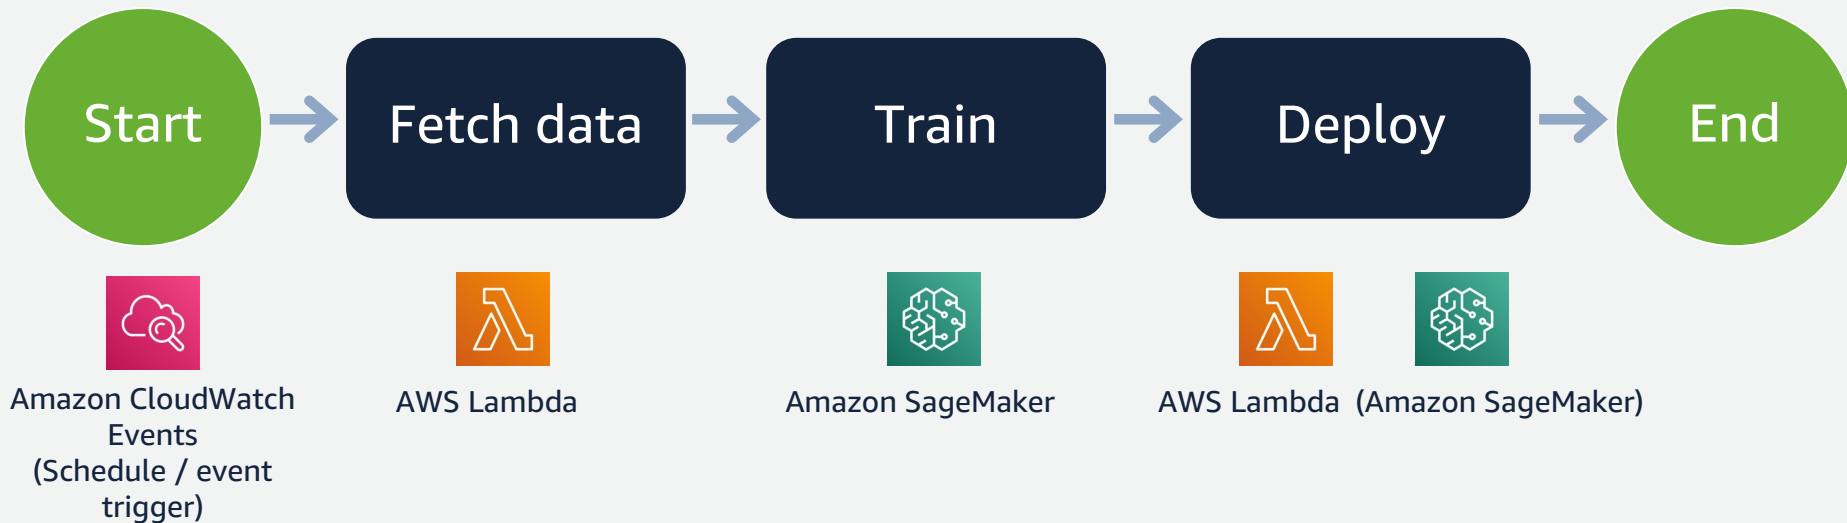
結果: トレーニングジョブ

名前	アルゴリズム	データソース	モデルアーティファクト
features-2019-08-13-05-26-50-246		train: s3://sagemaker-us-east-1- test: s3://sagemaker-us-east-1-	s3://sagemaker-us-east-1- 26-50-246/output/mod...

https://aws.amazon.com/jp/blogs/machine-learning/amazon-sagemaker-now-comes-with-new-capabilities-for-accelerating-machine-learning-experimentation/?nc1=h_ls

AWS Step Functions

- JSON ベースの言語でステートマシンを記述できるマネージドサービス
- AWS Lambdaをはじめとした各サービスに対応
- CloudWatch Event でスケジュール実行やイベントトリガーが可能



Apache Airflow 対応

- Airflow 1.10.1 より SageMaker Operator をサポート
- 既存の Airflow 環境から SageMaker を呼んでパイプラインを構築可能

Airflowサーバでの設定

Airflow の Operator を利用して
DAG でパイプラインを定義

```
train_op =  
    SageMakerTrainingOperator(...)  
transform_op =  
    SageMakerTransformOperator(...)  
  
transform_op.set_upstream(train_op)
```

SageMakerのAPIで
学習・推論の設定作成

```
train_config = training_config(...)  
  
trans_config  
=transform_config_from_estimator(...  
)
```

学習



推論



SageMaker

機械学習パイプライン全体の支援

- 2018年のre:Inventで、開発・学習・推論に対する基本となる機能に加えて、ラベリングやモデル変換をサポート
- パイプライン全体を管理する機能も追加



ラベリング




開発



学習



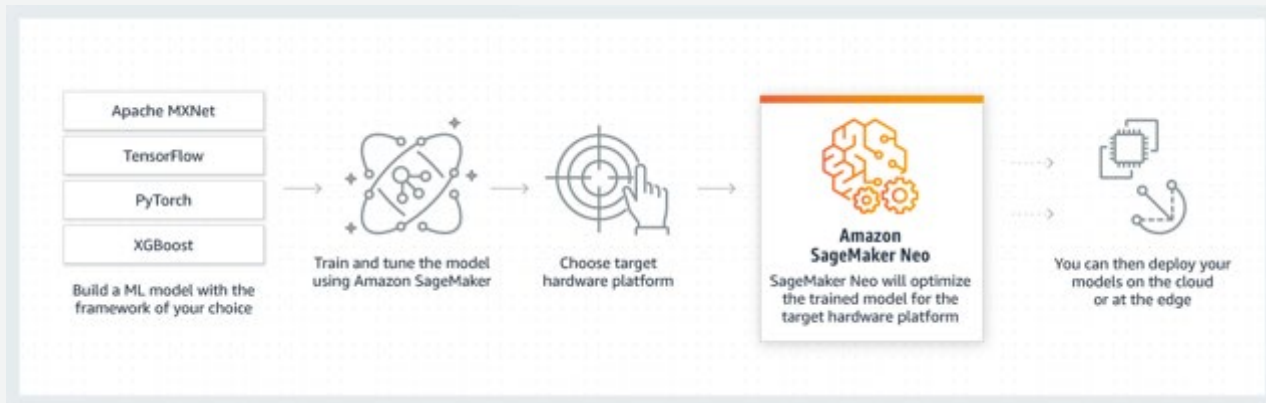
モデル変換



推論

Amazon SageMaker Neo

- Tensorflow や PyTorch などのモデルを、EC2 インスタンスや Greengrass デバイス上で高速に動作するように変換するサービス
- 従来のDeep Learning フレームワークが 500MB-1GB 程度であるのに対し、Amazon SageMaker Neo Runtime は 1MB 程度
- Apache Software License で OSS として提供予定



SageMaker Python SDK による Neo 利用の流れ

学習

```
mnist_estimator = TensorFlow(  
    entry_point='mnist.py', role=role, framework_version='1.11.0',  
    training_steps=1000, evaluation_steps=100,  
    train_instance_count=2, train_instance_type='ml.c4.xlarge')
```

```
mnist_estimator.fit(inputs)
```

C5向けに最適化

```
optimized_estimator = mnist_estimator.compile_model(  
    target_instance_family='ml_c5', input_shape={'data':[1, 784]},  
    output_path=output_path, framework='tensorflow',  
    framework_version='1.11.0')
```

C5にデプロイ

```
optimized_predictor = optimized_estimator.deploy(  
    initial_instance_count = 1, instance_type = 'ml.c5.4xlarge')
```

SageMaker Python SDK による Neo 利用の流れ

学習

```
mnist_estimator = TensorFlow(  
    entry_point='mnist.py', role=role, framework_version='1.11.0',  
    training_steps=1000, evaluation_steps=100,  
    train_instance_count=2, train_instance_type='ml.c4.xlarge')
```

```
mnist_estimator.fit(inputs)
```

C5向けに最適化

```
optimized_estimator = mnist_estimator.compile_model(  
    target_instance_family='ml_c5', input_shape={'data':[1, 784]},  
    output_path=output_path, framework='tensorflow',  
    framework_version='1.11.0')
```

C5にデプロイ

```
optimized_predictor = optimized_estimator.deploy(  
    initial_instance_count = 1, instance_type = 'ml.c5.4xlarge')
```

セキュリティ: 暗号化とコンプライアンス

- 学習と推論のジョブにおいてサーバ側の暗号化 (SSE-KMS) を利用可能
- 以下のものをすべて暗号化可能
 - 学習時の入出力データ
 - 学習用インスタンス、エンドポイントインスタンスのストレージ
 - バッチ推論時の入出力データ
- Cloudtrail に対応済み
- PCI DSS および HIPPAに対応済み

セキュリティ: 閉域網での通信

- SageMaker と S3 のデータ通信はすべて S3 VPC エンドポイント経由で行うことが可能
 - 学習ジョブの入出力における S3 アクセス
 - 学習済モデルをデプロイする際の S3 アクセス
- SageMaker の API はすべて PrivateLink 経由で行うことが可能
 - SageMaker Notebook Endpoint
 - SageMaker Service API
 - SageMaker Runtime API

アジェンダ

- 機械学習の課題に対するSageMakerのメリット
- SageMakerを利用した機械学習プロセス
- 機械学習の開発・学習・推論を効率化する基本機能
- まとめ

まとめ

- 機械学習のマネージドサービス Amazon SageMaker を使うことで、インフラ構築を気にせず、すぐに機械学習をはじめることができる
- DLフレームワークやライブラリの定常的なアップデートを気にすることなく、モデル開発に集中できる
- 全体のワークフローの管理や、コスト最適のための新サービスなど、便利な機能が日々アップデート

Reference

SageMaker Example Notebooks

<https://github.com/aws-labs/amazon-sagemaker-examples>

SageMaker SDK

<https://github.com/aws/sagemaker-python-sdk>

(Docはこちら: <https://readthedocs.org/projects/sagemaker/>)

SageMaker 公式ドキュメント

https://docs.aws.amazon.com/ja_jp/sagemaker/latest/dg/whatis.html

Reference

Amazon SageMaker PyTorch container

<https://github.com/aws/sagemaker-pytorch-container>

Amazon SageMaker PyTorch estimator

<https://github.com/aws/sagemaker-python-sdk/tree/master/src/sagemaker/pytorch>

Using PyTorch with the SageMaker Python SDK

https://sagemaker.readthedocs.io/en/stable/using_pytorch.html



ご静聴ありがとうございました！

