

AWS

S U M M I T

# EC2 Innovation at Scale

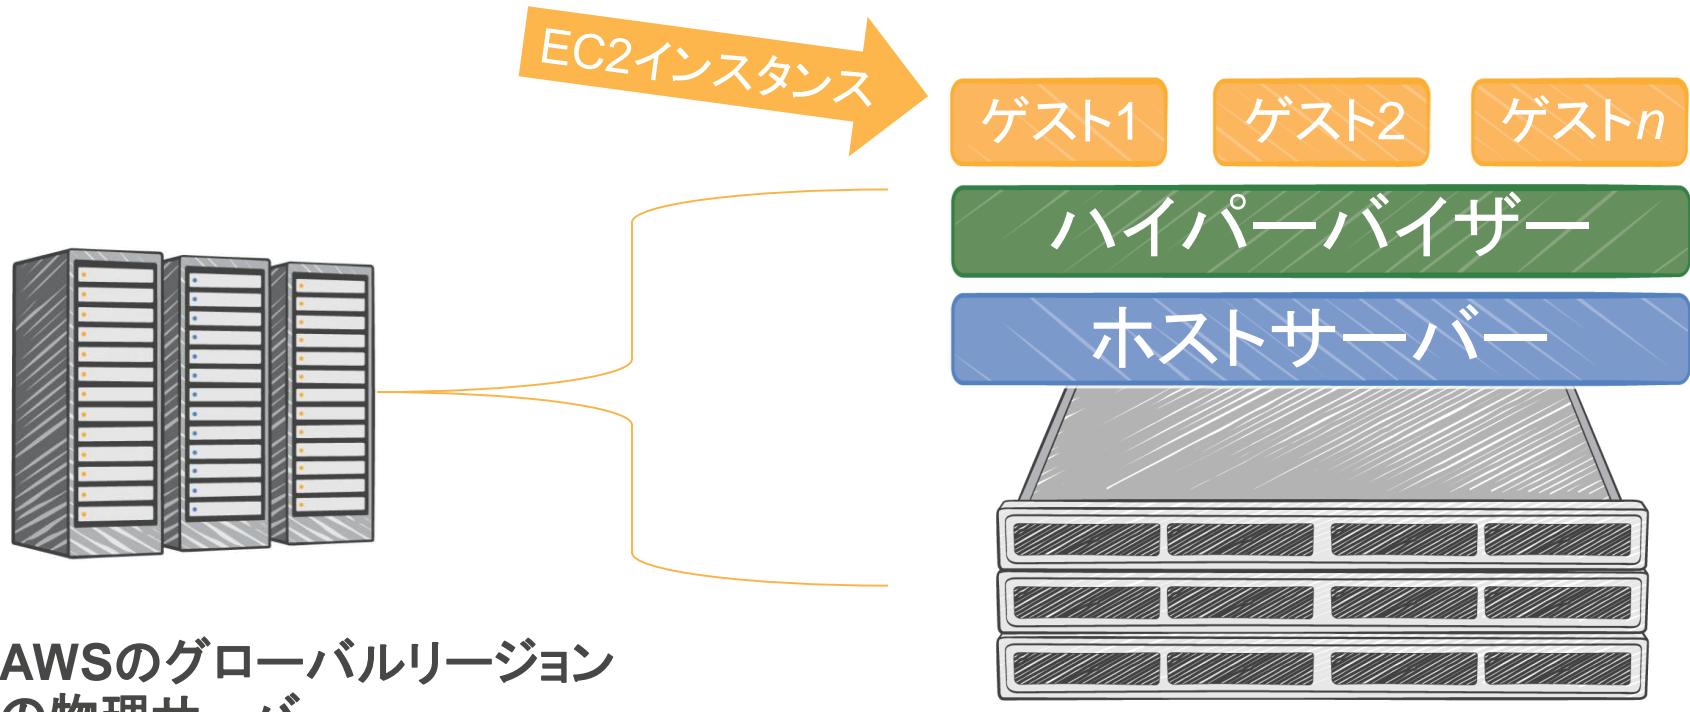
Raj Pai, Director of Product Management, EC2

June 2, 2017



# Amazon Elastic Compute Cloud (EC2) -

クラウドの伸縮自在な**仮想サーバー**



# 10年前のAmazon EC2...

## シングルインスタンスファミリ／サイズ

- m1.small(1個のvCPU、1.7GiBのRAM、160GBのストレージ)

Linuxのみ

オンデマンド料金のみ



# あれから10年

M4は64個のvCPU、256GBのRAM。当初のm1.smallと比べて、vCPUは64倍、RAMは150倍！

それに加えて...

インスタンスの選択肢をさらに追加

リザーブドインスタンスとスポットインスタンス

OSとアプリケーションのサポート

Amazon Elastic Block Store (EBS)

Elastic IPアドレス

Amazon VPC

Auto Scaling

Elastic Load Balancing

パフォーマンス、セキュリティ、管理可能性、スケーラビリティの改善

Amazon ECS、Lambda

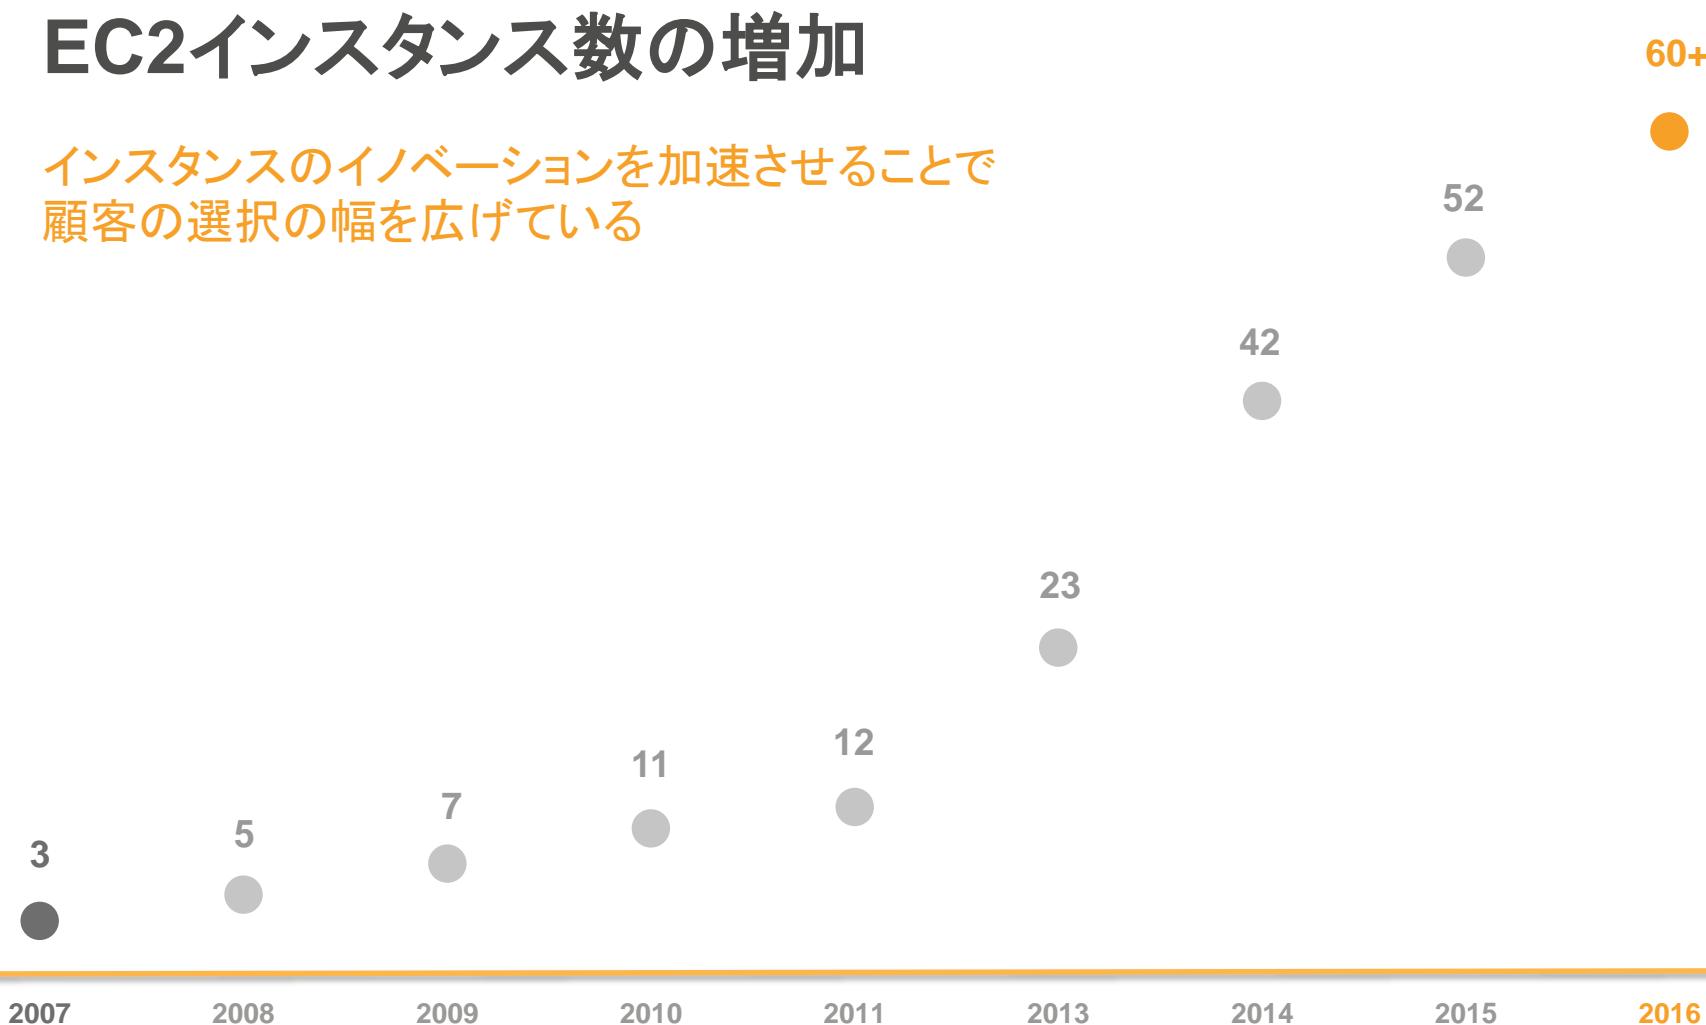
Amazon Machine Learning

他にもいろいろ



# EC2インスタンス数の増加

インスタンスのイノベーションを加速させることで  
顧客の選択の幅を広げている



# 現在のEC2インスタンスの特徴

CPU



メモリ



ストレージ



GPU



拡張

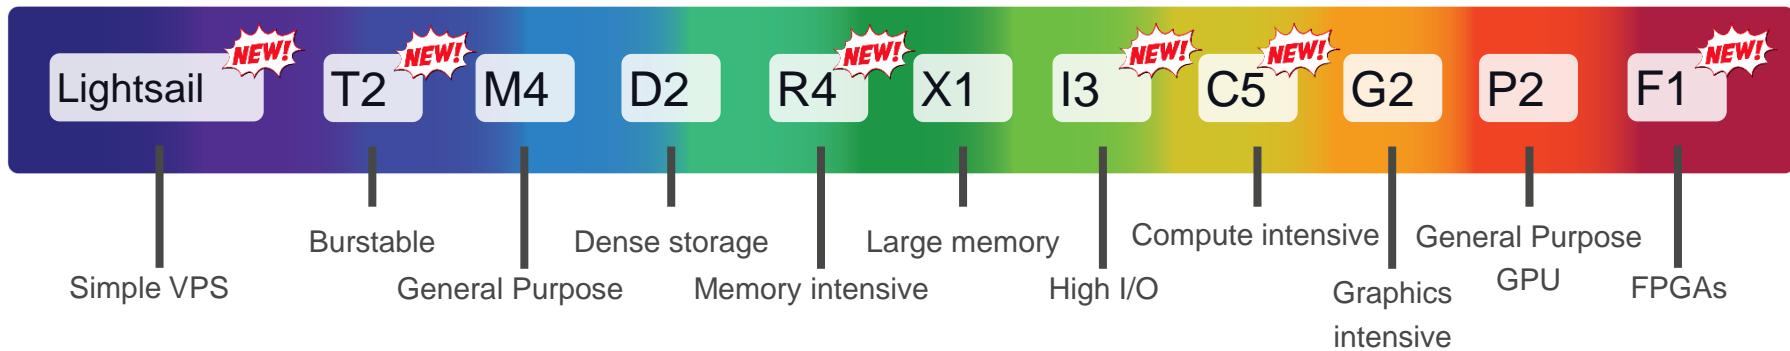


ネットワーキング

# コンピュートイノベーション



## EC2のElastic GPU



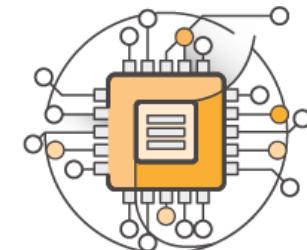
# EC2インスタンスイノベーション:コンピュート最適化

## 大量の演算を行うワークロードに最適

- トラフィック量の多いフロントエンド群、MMOゲーミング、メディア処理、  
トランスコーディング、HPC(High Performance Computing)アプリケーション

## C5 … 次世代のコンピュート最適化インスタンス(まもなく登場！)

- 最新のIntel Skylakeプロセッサ
- 新しい高度なベクトル拡張命令セットであるAVX-512をサポート  
ピークパフォーマンス(AVX2)では、クロックサイクルあたりのFLOPSが最大  
で2倍
- 最大サイズ。c5.18XLでは、72個のvCPU、144GiBのメモリ、20Gbpsの専用  
ネットワーク帯域幅



# EC2 インスタンス・イノベーション: メモリーの最適化

## R4 – 2017年12月出荷 – GiB と vCPU の比率は8:1

- より大きな新しいインスタンスのサイズ (r4.16XL)、64 vCPU 、RAM 488 GiB
- Intel E5 v4 Broadwell プロセッサ(AVX2) 、TSX
- 改良された高性能メモリ、DDR4 メモリ
- ネットワーク帯域最大 20 Gbps

## X1 – GiBあたりメモリ最大、価格は最安値 – GiB とvCPU の比率は16:1

- 2TB RAM/128 vCPU 、1TB RAM/64 vCPU
- Intel E7 v3 Haswell 4-socket CPU (より高速な QPI 速度)
- SAP HANA インメモリデータベース / アナリティクス、シミュレーション、レンダリング

## 今年後半: X1E インスタンス、4 TB の RAM

2018年までのロードマップ: 8TB と 16TB のメモリインスタンス!

# EC2インスタンスイノベーション:ストレージ最適化インスタンス

## I3 … 2017年2月に登場した次世代のHigh I/Oインスタンス

- Intel E5 v4 Broadwellプロセッサ(AVX2、TSX)
- NVME(Non-Volatile Memory Express)ベースのSSD、ランダムリードは最大330万 IOPS、シーケンシャルリードのトータルスループットは16GB/s
- 1×475GBのNVME SSDを搭載したi3.largeから、8×1.9TBのNVME SSDを搭載したi3.16xlargeまで、サイズは6種類
- トランザクション対応のワークロード、ハイパフォーマンスデータベース、リアルタイム分析、NoSQLデータベースに最適

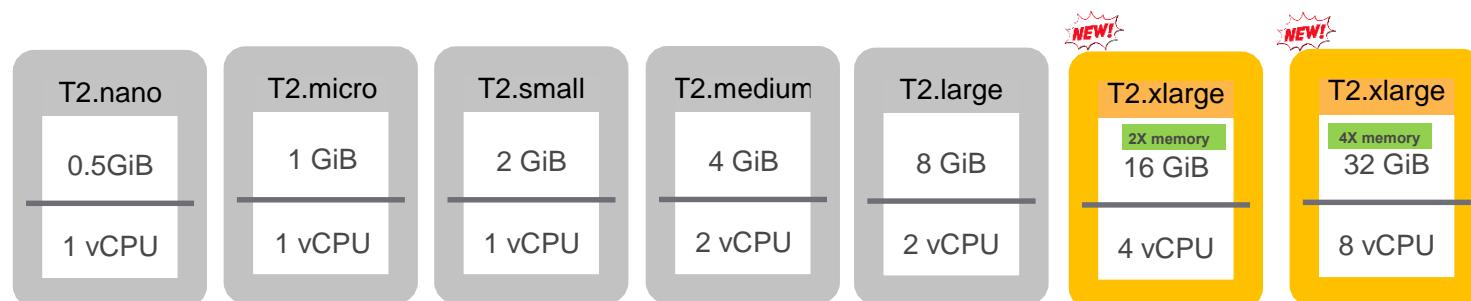
I2に比べて、IOPSが9倍、ストレージが2.3倍、メモリが2倍、vCPUが2倍！

# EC2インスタンスイノベーション: バースタブルインスタンス

T2バースタブルパフォーマンスインスタンスは、ベースラインレベルのCPUパフォーマンスを提供する一方で、ベースラインを超える需要にも対応できる機能を提供

t2.xlargeとt2.2xlargeは2016年12月から提供開始

- 最大8個のvCPUと32GiBのメモリ
- 開発環境、データベース、アプリケーションサーバー、Webサーバーに最適



# 大量の演算を実行するワークロード

- CPUでのスケーリング
  - バッチジョブ: スポットインスタンス
- もつとうまく行うことは可能?
  - ワークロードによっては、事実上、CPUだけで実行することは不可能 - 数週間かかる
  - 実行時の遅延の削減
  - パフォーマンスとコスト最適化

# ハードウェアアクセラレーションとは何か？

- 一部の機能をCPUで実行されるソフトウェアよりも効率よく実行するための特別なハードウェア(ハードウェアアクセラレータ)を使用



# ハードウェアアクセラレーションとは何か？

CPUがスイスアーミーナイフのよう  
なものだとすれば...



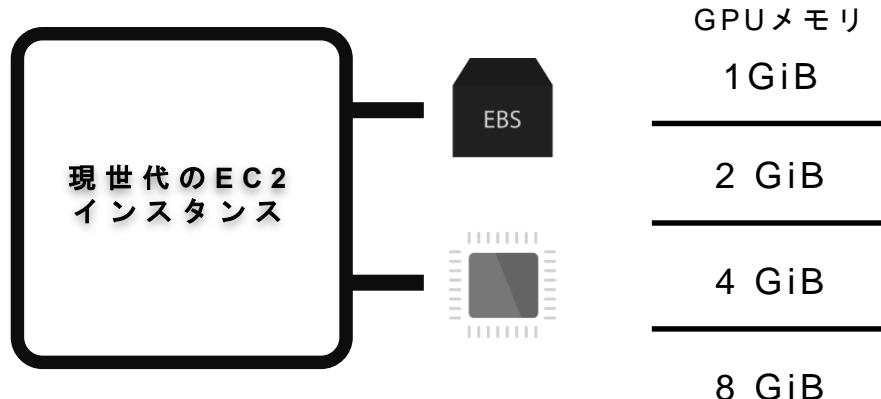
ハードウェアアクセラレータはエッグ  
スライサーのようなもの



# グラフィックアクセラレーション

## Elastic GPU - プレビュー

- Amazon EC2インスタンスに安価なグラフィックアクセラレーションをネットワーク経由で追加することが可能
- 幅広いサイズ展開。GPUをさまざまなEC2インスタンスにアタッチすることで、最適なパフォーマンスを実現
- どのようなグラフィックスアプリケーションでも実行できる自信につながるOpenGLへの準拠



# GPUによる高速コンピューティング

- ユビキタス
- 高度なデータ並列処理
- 浮動小数点演算の割合が高い
- 一貫性の高い優れたAPIドキュメント(CUDA、OpenGL)
- 幅広いISVとオープンソースフレームワークによるサポート

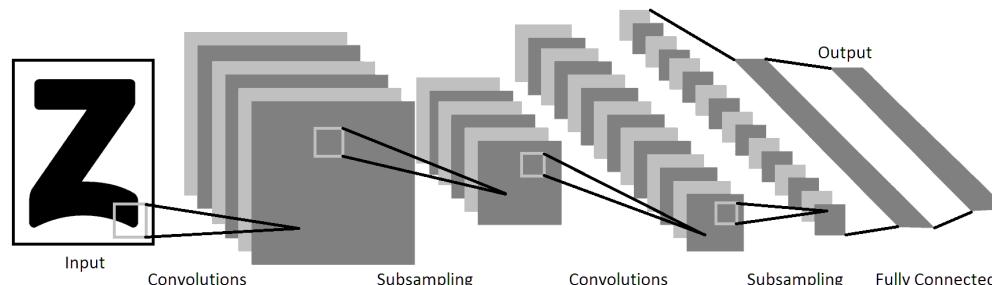
# GPUコンピュートインスタンス

## P2 … GPGPUインスタンスとDeep Learning AMI - 9月から提供

- 16個のNVIDIA Tesla K80 GPUと192GBのGPUメモリ
- 完全なGPUDirect P2P機能
- 40,000個のCUDAコア、70TFLOPSの単精度浮動小数点演算性能、23TFLOPSを超える倍精度浮動小数点演算性能
- 機械学習、数値流体力学、金融工学、地震解析、分子モデル構築、ゲノミクス、レンダリングのための並列処理を実現

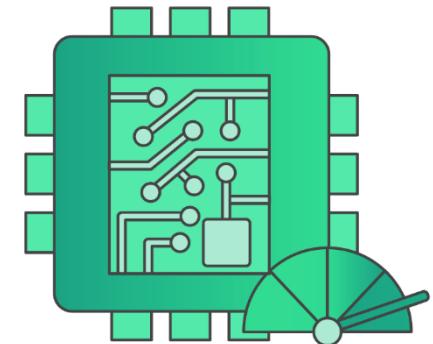
## 次世代のGPGPUインスタンス

- NVIDIAとAWSはクラウドでのGPUアクセラレーションを最適化するために数年前から緊密な共同作業を行っており、NVIDIA Volta GPUのローンチパートナーになることをとても楽しみにしている
- NVIDIAとAWSの次のGPGPUインスタンスファミリは、今年後半にVoltaの提供が開始された時点で、Voltaベースとなる



# FPGAによる高速コンピューティング

- 特別なアルゴリズムのためのカスタムハードウェア
- 標準以外のデータ構造のサポート
- フィールドリプログラマビリティに基づくより容易なメンテナンス
- データフロープログラミング
- スレッド間の依存性が高いアプリケーション向き
- 大きなローカルメモリと高いメモリ帯域幅を提供
- コスト効率



# Amazon FPGA ImageとF1インスタンス

F1は顧客によるプログラミングが可能なアプリケーションアクセラレーションのためのFPGAハードウェアを初めて搭載したコンピュートインスタンス

## FPGAイノベーションの開発とデプロイを容易にするAmazon FPGA Image

- F1インスタンスから高性能なFPGAへの専用アクセスにより、最大30倍までアプリケーションを高速化
- HDK (Hardware Developer Kit) と開発者AMIにより、開発時間を大幅に短縮
- AWS Marketplaceとの統合により、100万人以上の顧客にFPGAイノベーションを提供
- トランスコーディング、金融リスクモデリング、ゲノム解析、ビッグデータ処理、大規模なシミュレーションを含め、パイプライン段数が多いデータフローアプリケーションに最適



コードの開発、シミュレーション、  
デバッグ、コンパイル

FPGAイメージとして  
パッケージ化

F1インスタンス  
カスタムロジックをFPGAで  
実行

# インスタンスの拡張機能: ネットワーク機能

Elastic Network Adapter(ENA) … X1と新世代のインスタンスで提供

- スケーラビリティの改善、高いスループットとpps(packet per second)パフォーマンス、一貫した低遅延を目的として、Amazonによって構築されたカスタムネットワークドライバ

ネットワークパフォーマンスの改善

- より大きなインスタンスでのスループット … X1、P2、M4、R4、I3、C5では20Gbps
- より小さなインスタンスでのスループット … より小さなインスタンス(R4、I3、C5、および他のインスタンス)でのピーク帯域幅は10Gbps

IPv6

- PCIにIPv6 CIDRブロックを関連付けることで、VPCのEC2インスタンスでIPv6アドレスを使用することが可能



# インスタンスの拡張機能:EBSストレージ

## 新しいスループット最適化HDDボリューム

- ST1 … 最大スループットは500MB/s、ベースラインは40MB/s(\$0.045/GB)
- SC1 … 最大スループットは250MB/s、ベースラインは12MB/s(\$0.025/GB)

## パフォーマンスの改善

- PIOPS … IOPSとGBの比率を30:1から50:1に改善

## EBSの暗号化とカスタムキー

- AWSのリージョンおよびアカウントの間で暗号化されたスナップショットをコピー
- 暗号化されたブートボリューム

# EC2のコストを最適化

# Amazon EC2の購入オプション

## オンデマンド

コンピュートキャパシティを  
時間単位で支払い、  
長期契約なし

スペイキーなワークロードに、  
またはニーズを定義するために



## リザーブド

契約期間は1年または3年、  
オンデマンドと比べて  
大幅な割引

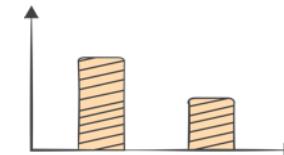
確定済みのワークロードに、  
またはベースラインでの使用に



## スポット

未使用のコンピュートキャパシティ  
に対して市場価格で支払い、  
オンデマンドと比べてかなり割引

フォールトトレラントなワークロード、  
時間的に余裕のあるワークロード、  
または一過性のワークロードに



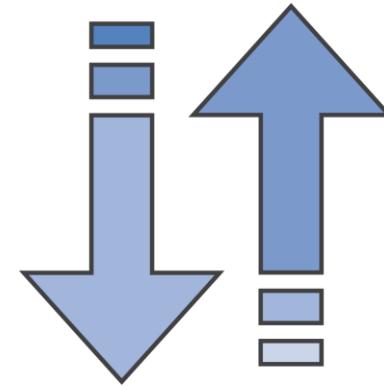
# EC2オンデマンドインスタンスの料金



低成本で柔軟



開発とテスト

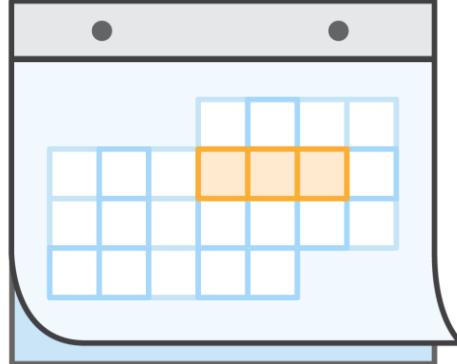


短期間、スパイキー、  
予測不能

# EC2リザーブドインスタンスの料金



定常的



必要に応じてキャパシティを  
予約



前払いによる  
コスト削減

# リザーブドインスタンスの概要

ニーズに最適なRIオプションを決定

節約の可能性

## スタンダード

最大75%

なし

1年または3年

あり

前払いなし  
一部前払い  
全額前払い

あり

インスタンスファミリー、  
OS、  
テナントの変更

リース期間

AZ、  
インスタンスサイズ(Linux)、  
ネットワークタイプの変更

支払い

リージョンに関する特典

## コンバーティブル

最大66%

あり

3年のみ

あり

前払いなし  
一部前払い  
全額前払い

あり

# コンバーティブルリザーブドインスタンス(RI)

コンバーティブルリザーブドインスタンスでは以下が可能:

新しいインスタンスファミリに交換: R3→C3→T2→M4など

新しいインスタンス料金に交換: AWSがインスタンスの定価を値下げした場合

新しいOSに交換: WindowsからLinuxへの交換など

新しいインスタンスサイズに交換

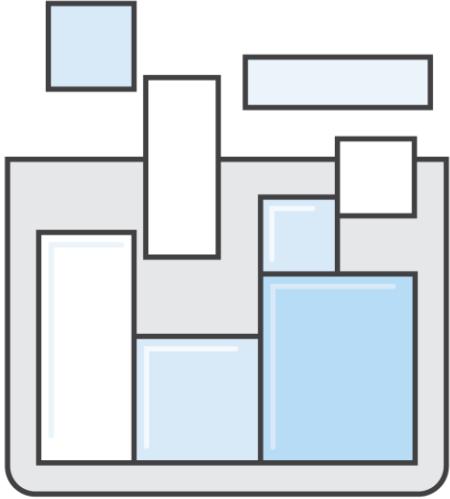
テナントを交換: ハードウェア占有(dedicated)インスタンスからデフォルトへの交換など

別の支払いオプションに交換: 「前払いなし」から「一部前払い」への交換など

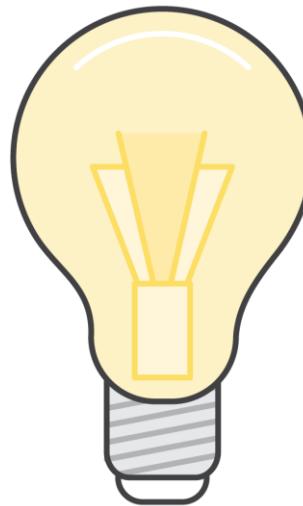
# リージョンに関する特典の概要

	キャパシティ予約 の特典？	AZ間の 自動的な割引？	インスタンスサイズ間の 自動的な割引？	RI Marketplace での販売？
ゾーナル	あり	なし	なし	あり
リージョナル	なし	あり	あり	なし

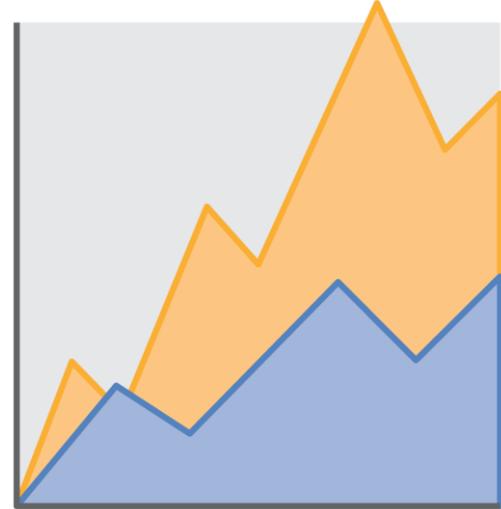
# EC2スポットインスタンスの料金



時間または  
インスタンスが柔軟



コスト重視のビジネスを  
実験または構築



緊急性の高いコンピューティング  
ニーズを持つ、または追加の  
キャパシティを大量に必要として  
いるユーザー

# スポットインスタンスの詳細

**90%節約!\***

## オプション

- インスタンスの可用性を維持するための  
スポットフリート
- 繙続的に実行しなければならない  
ワークロードに対するスポットブロックの  
継続期間(1~6時間)

## コミットレベル

- なし

\* 特定のEC2インスタンスタイプ、リージョン、AZに基づくオンデマンド価格との比較

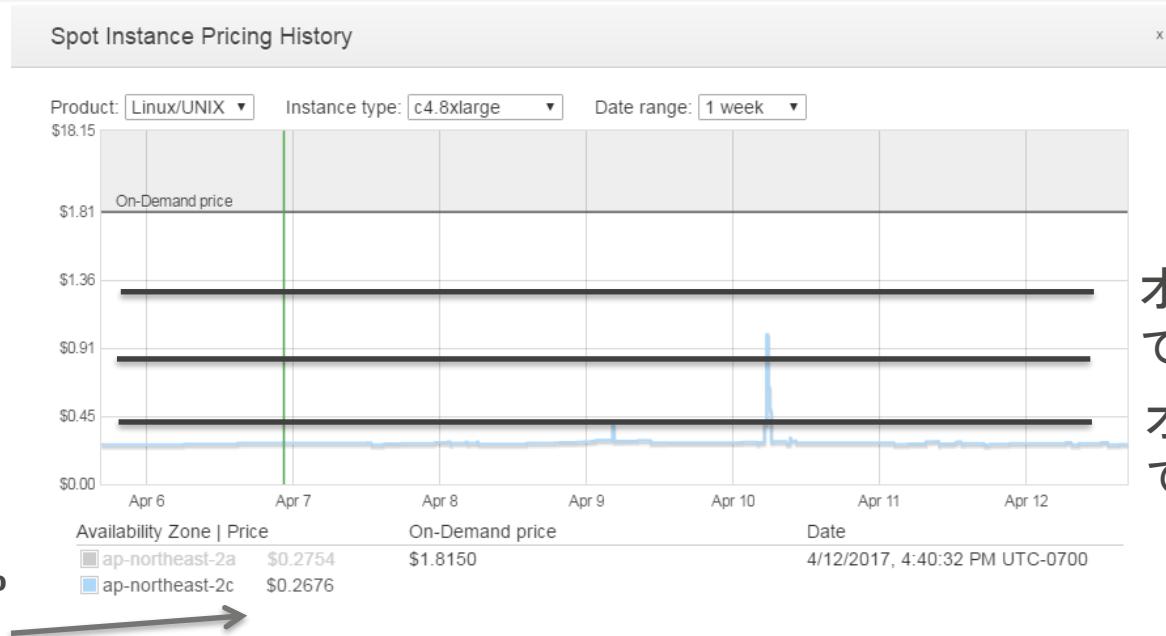
# スポットインスタンスのルール



コンピュートの市場価格は需要と供給に基づいて変動



入札価格を超える支払いは発生しない



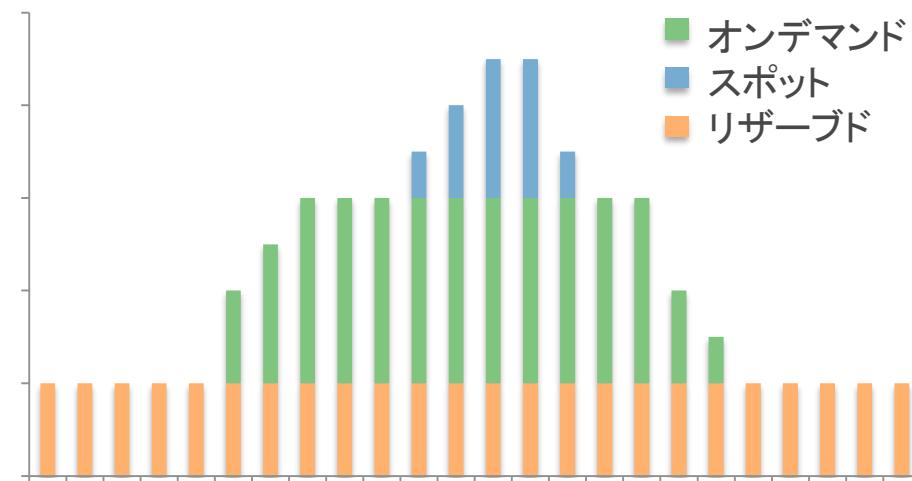
オンデマンドの  
50%で入札

オンデマンドの75%  
で入札  
オンデマンドの25%  
で入札

市場価格の85%  
割引で支払い！

# 購入モデルを組み合わせて使用

1. 既知の定常的なワークロードにはリザーブドインスタンスを使用
2. 複数のAuto Scalingグループをセットアップ
3. スポット、オンデマンド、または両方を使ってスケーリング



# 単純なワークフローの要件はたいてい単純



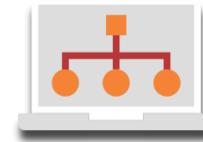
Webサイト



ブログ



開発環境



プロトタイピング



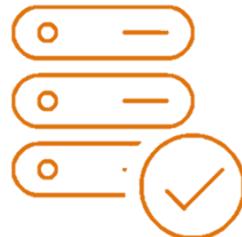
ビルドサーバー



# Amazon **Lightsail** : AWSでの取り組み を開始するための最も簡単な方法



VPS (Virtual Private Server)



永続ストレージ



ネットワーキング

# 事前に設定されたインスタンスイメージを選択

オペレーティング  
システム



アプリケーション



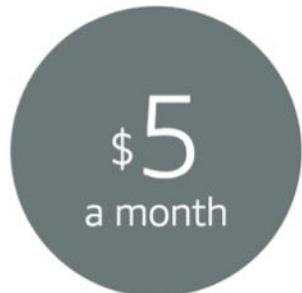
開発スタック



# VPSインスタンスをワンクリックで起動



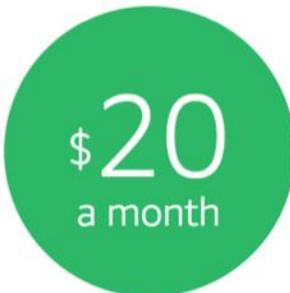
# 必要なものをどれでも予測可能な低価格で



512MB Memory  
1 Core Processor  
20GB SSD Disk  
1TB Transfer



1GB Memory  
1 Core Processor  
30GB SSD Disk  
2TB Transfer



2GB Memory  
1 Core Processor  
40GB SSD Disk  
3TB Transfer

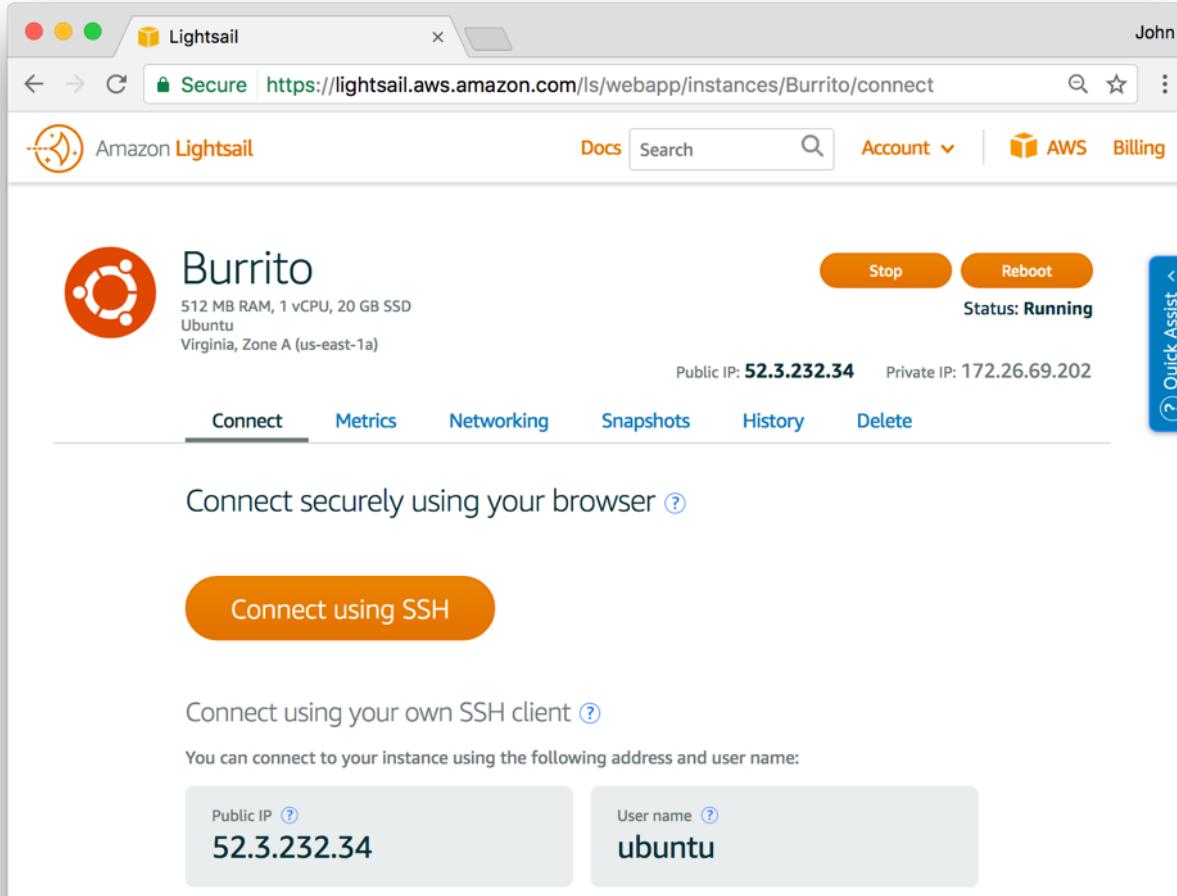


4GB Memory  
2 Core Processor  
60GB SSD Disk  
4TB Transfer



8GB Memory  
2 Core Processor  
80GB SSD Disk  
5TB Transfer

# 使いやすいインターフェイス



The screenshot shows the AWS Lightsail interface for a running Ubuntu instance named 'Burrito'. The instance details are as follows:

- Image:** Ubuntu
- RAM:** 512 MB
- Processor:** 1 vCPU
- Storage:** 20 GB SSD
- Location:** Virginia, Zone A (us-east-1a)

The instance is currently **Running** with a **Public IP: 52.3.232.34** and a **Private IP: 172.26.69.202**. The interface includes tabs for **Connect**, **Metrics**, **Networking**, **Snapshots**, **History**, and **Delete**. A large orange button labeled **Connect using SSH** is prominently displayed. Below it, another section for connecting using an SSH client provides the public IP (52.3.232.34) and user name (ubuntu). A sidebar on the right offers a **Quick Assist** feature.

# 世界中をライトセイリング！



# まとめ

AWSのインスタンスロードマップを決定するのは顧客

- AWSは実行すべき顧客のジョブとパフォーマンスの定義を理解している
- この作業をより効果的に行うために新しいハードウェアとソフトウェアを調査している
- パフォーマンスの改善を可能にする次世代のインスタンスと、顧客の新しいニーズを解決するための新しいインスタンスファミリとインスタンス機能を提供する

AWSでは、新しいインスタンス、機能、コンピュートモデルを使ってすべてのワークロードをカバーするために、コンピュートサービスのイノベーションに取り組んでいる

# AWS SUMMIT

