

JAPAN | JUNE 21, 2024

aws SUMMIT



DOL-13

Rust で Lambda はどれだけ高速化するのか "Rustacean Lambda"

Yoshitaka Kawaji

Solutions Architect

Amazon Web Services Japan K.K.



本セッションの概要

AWS Lambda に Rust がどのように寄与し、高速化につながるのかについての紹介を行います。

AWS における Rust を利用した高速化の取り組みの紹介。

自己紹介



川路 義隆

X @kawaji_scratch

アマゾン ウェブ サービス ジャパン合同会社
ソリューションアーキテクト

- 小売業のお客様の支援
- サーバーレス導入支援

Agenda

Lambda を高速化する動機

Rust を Lambda 関数で利用する方法

Lambda Extensions

AWS による実験的取り組み

まとめ

Lambda を高速化する動機

Lambda を高速化する動機

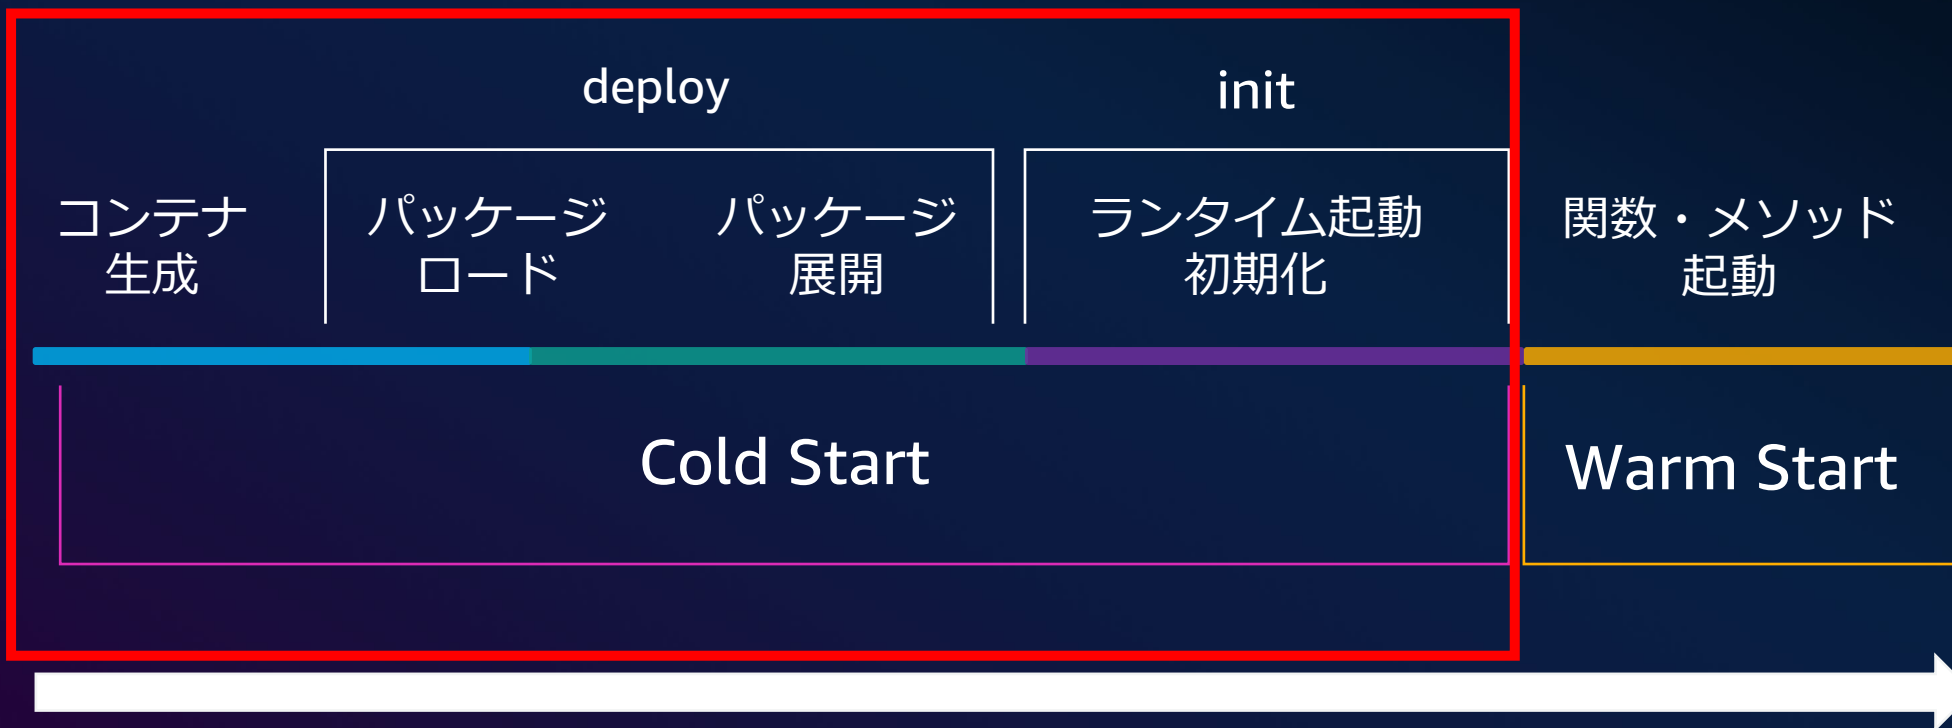
必要な処理を素早く起動し、
迅速に処理を終わらせたい。

可能な限り低コストで利用したい。



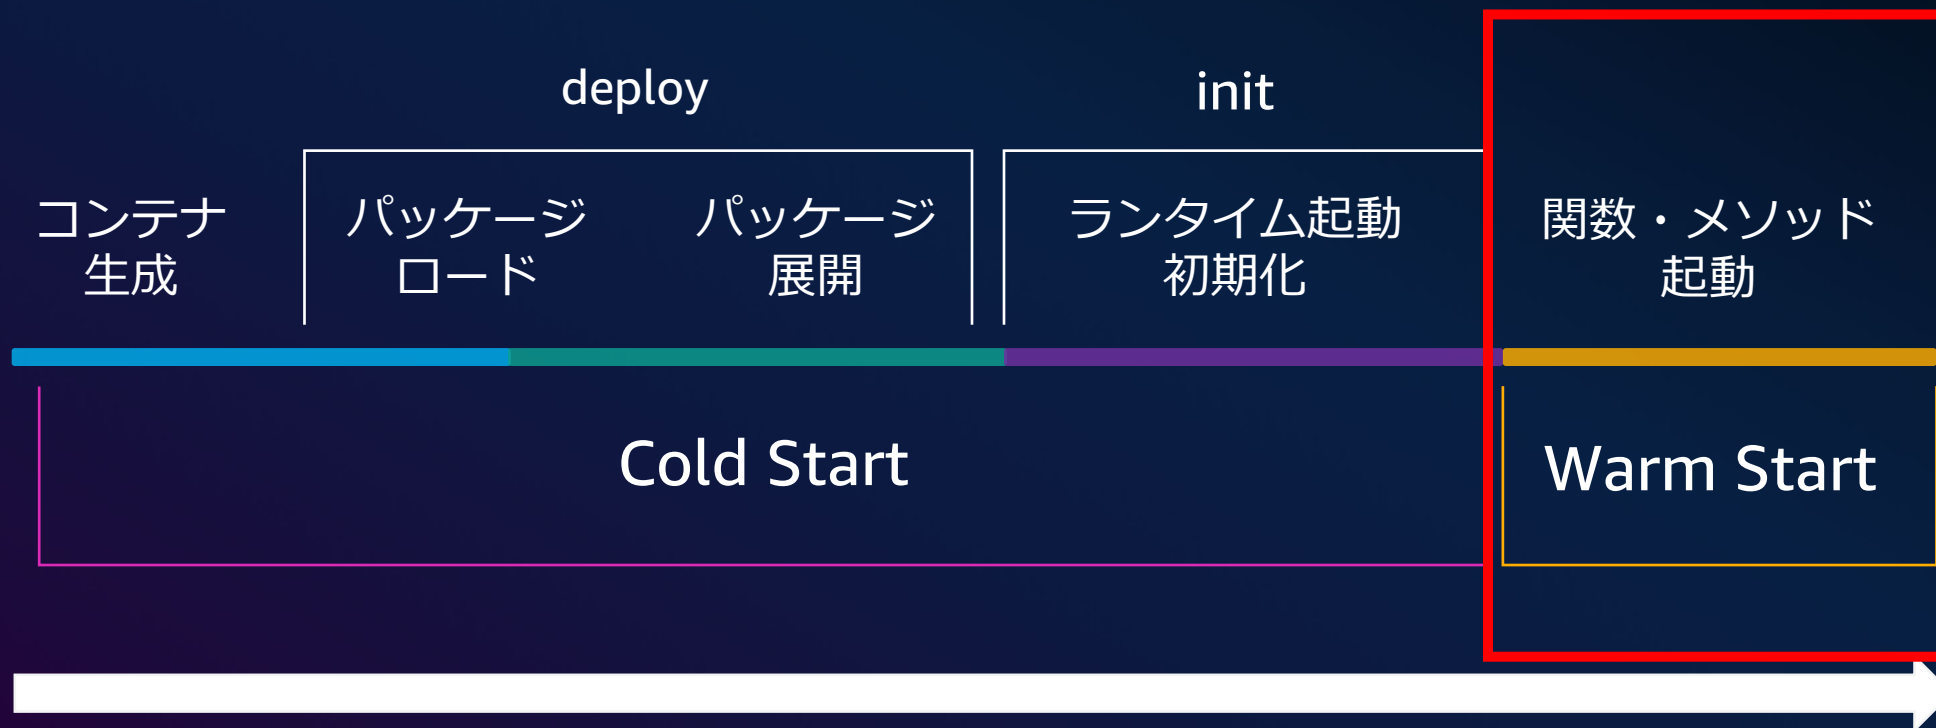
起動時間

Lambda 実行環境は Cold Start することがあり関数実行前に起動時間が発生する。



実行時間

Lambda 関数の実行時間は処理内容の他に言語ランタイムに依存します。



コスト

AWS Lambda の料金は実行時間(ミリ秒)で計算されます

| メモリ (MB) | 1ミリ秒あたりの料金 | メモリ (MB) | 1ミリ秒あたりの料金 |
|----------|-----------------|----------|-----------------|
| 128 | 0.0000000021USD | 1,536 | 0.0000000250USD |
| 512 | 0.0000000083USD | 2,048 | 0.0000000333USD |
| 1,024 | 0.0000000167USD | 3,072 | 0.0000000500USD |

東京リージョン x86料金 より抜粋 <https://aws.amazon.com/jp/lambda/pricing/>

Lambda を高速化するには

Cold Start の**起動時間**を短縮 + **実行時間**の短縮を検討することが必要です。



Rust とは



Rust とは

- パフォーマンス
 - 非常に高速
 - メモリ効率が低い
 - ランタイムやガベージコレクションがない





Rust を利用したことで、実際の運用環境において CPU 使用量が 75% 減少し、メモリ使用量が 95% 減少しました

Alan Ning
Tenable.io



Rust を Lambda 関数 で利用する方法

Lambda 実行環境

実行環境

Function Code

Layer Code

Function Runtime

Extension Code

Extension Runtime

Rust を Lambda 関数 で利用する方法

Rust 実行可能バイナリにネイティブコンパイルするため、専用のランタイムは必要ありません。

provided.al2023 または provided.al2 ランタイムを使用してデプロイするか Container Image を作成する方法があります。

| OS 専用ランタイム | オペレーティングシステム |
|-----------------|-------------------|
| provided.al2023 | Amazon Linux 2023 |
| provided.al2 | Amazon Linux 2 |

Custom Runtime
(bootstrap + Handler)
OR
Container Image

Lambda Extensions



Lambda 実行環境

実行環境

Function Code

Layer Code

Function Runtime

Extension Code

Extension Runtime


Lambda Extensions

Lambda Extensions は、お好みのモニタリング、オブザーバビリティ、セキュリティ、ガバナンス用ツールと Lambda との統合を簡単にする方法。


既存ツールを複雑なインストール、設定、運用のオーバヘッドをなくし、関数コードの削減を実現することが可能。

Extension は Lambda とリソース (CPU, Memory) を共有する

一例



Amazon CloudWatch
Lambda Insights

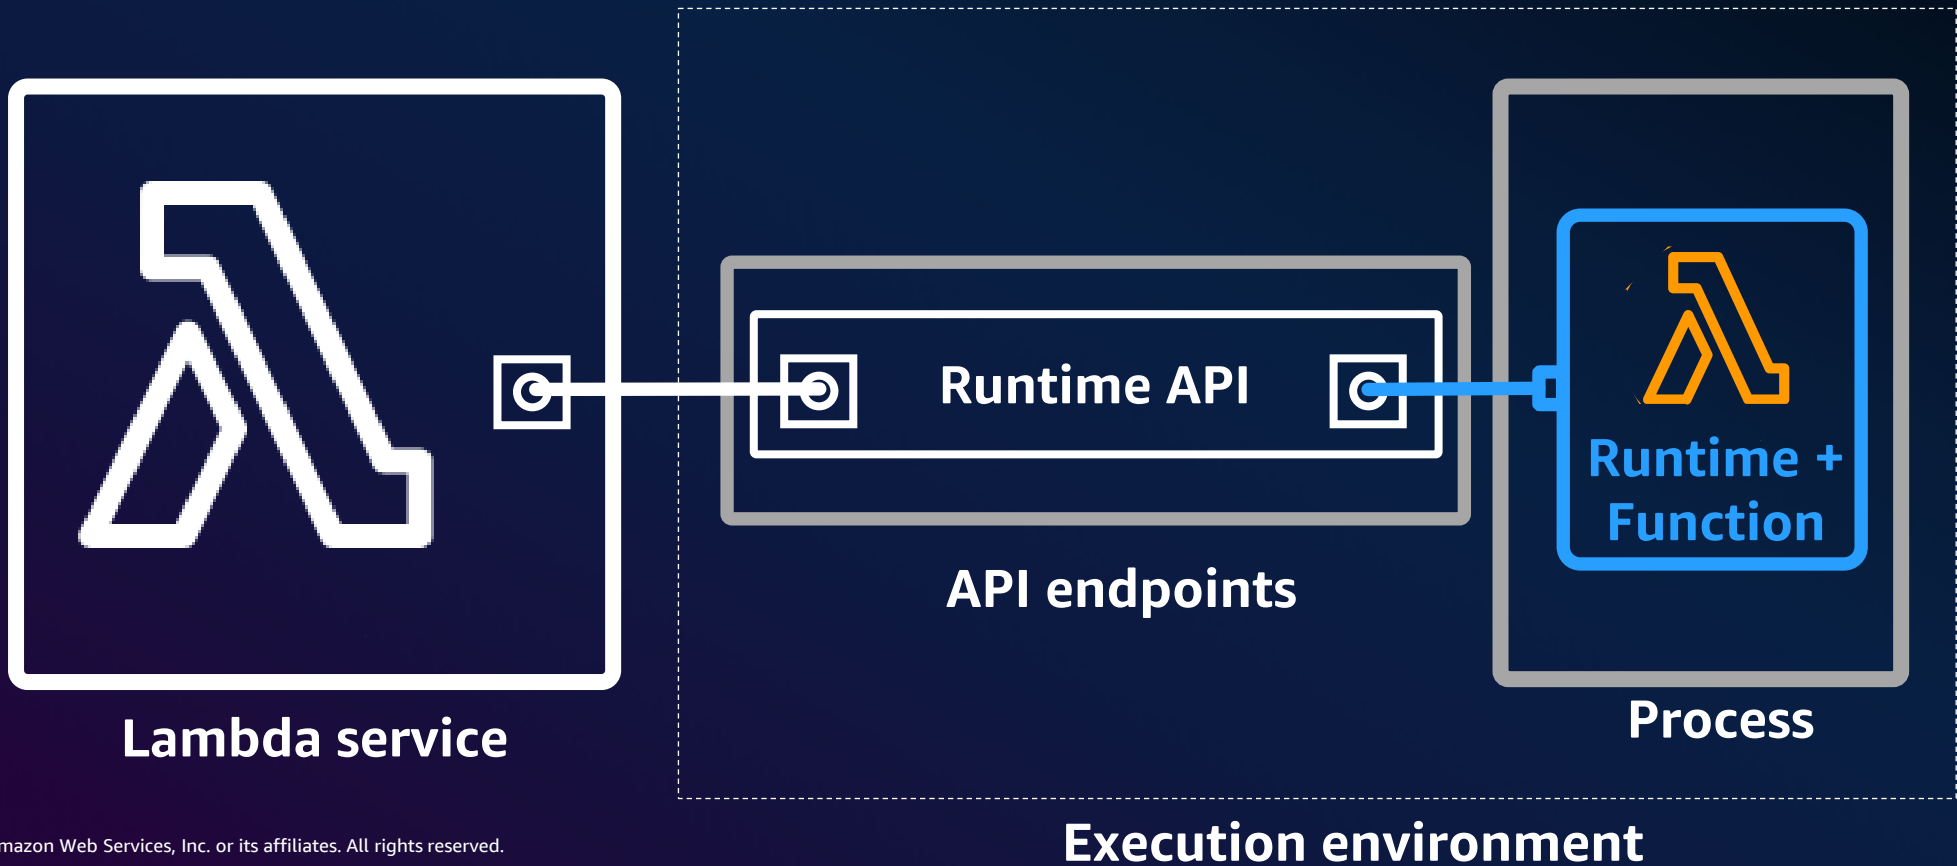


AWS AppConfig

Lambda 実行環境

BEFORE EXTENSIONS

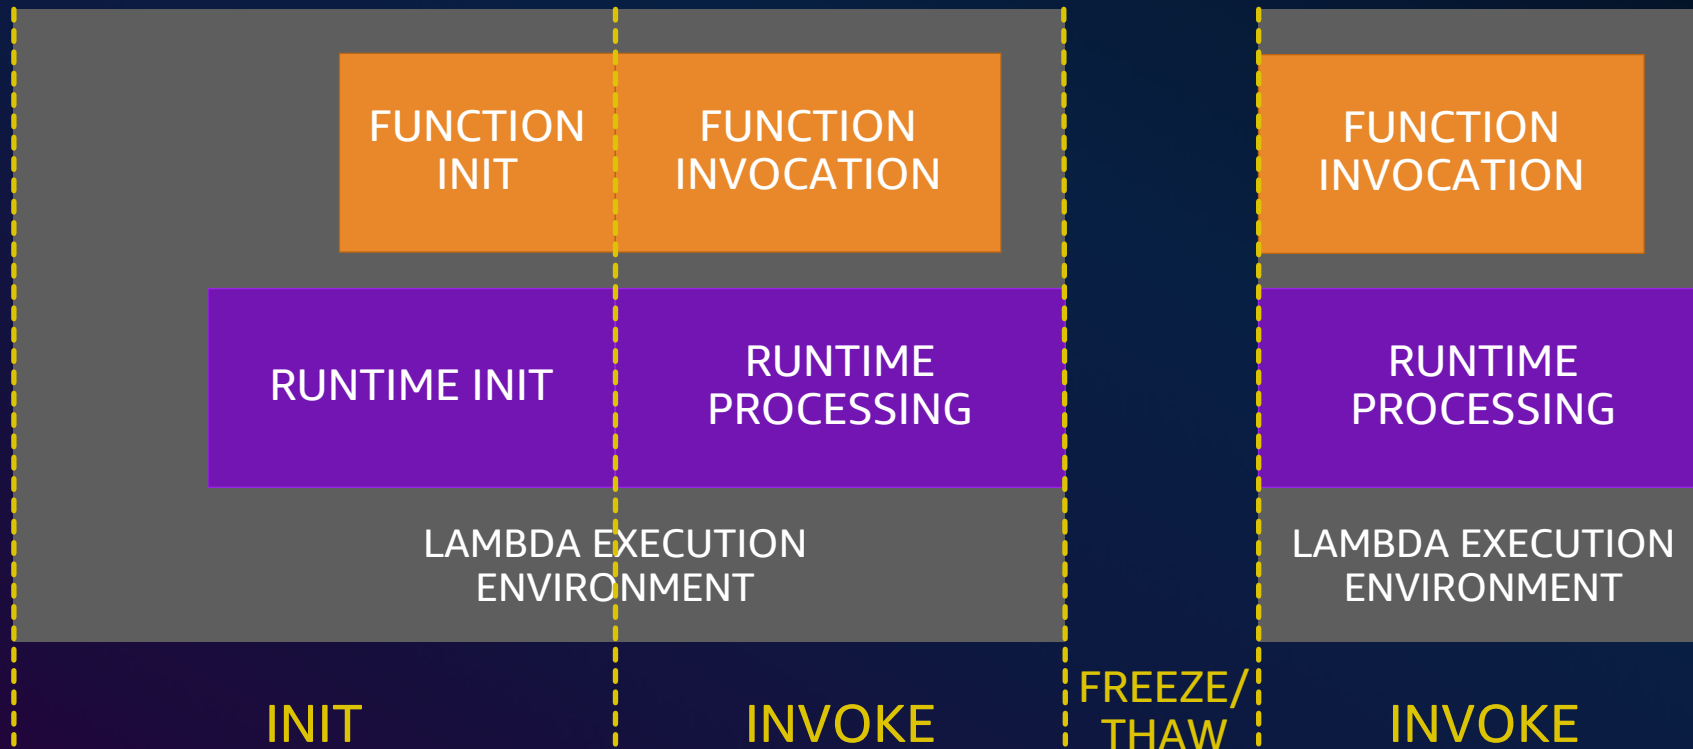
Lambda Runtime API はカスタムランタイムの持ち込みを可能にします



Lambda 実行環境

BEFORE EXTENSIONS

Lambda Runtime API はカスタムランタイムの持ち込みを可能にします

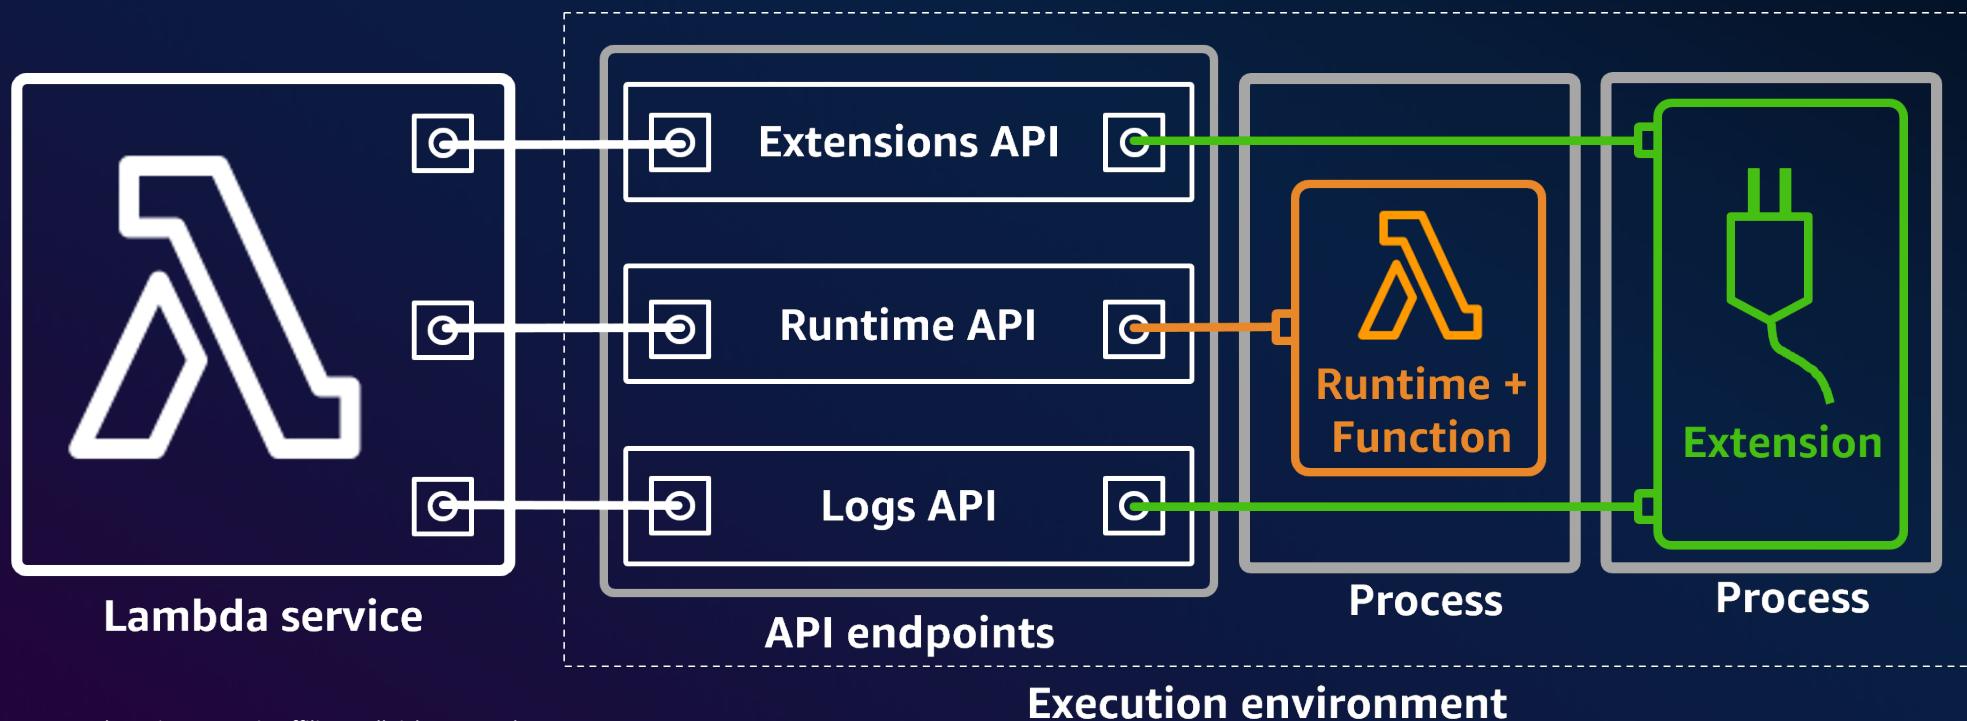


Lambda 実行環境

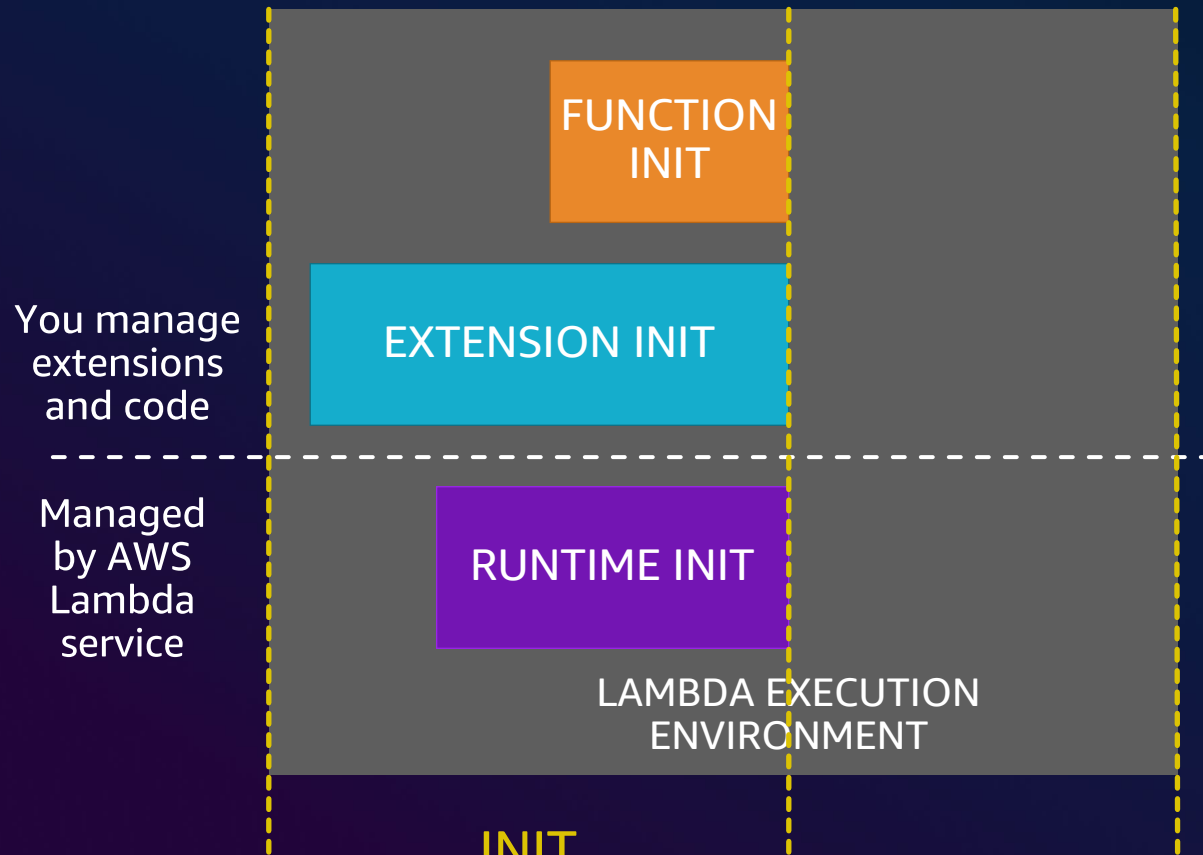
WITH EXTENSIONS

Extensions API は既存の Lambda Runtime API をベースに構築されている
関数を実行環境のライフサイクルイベントに登録できます

Extensions は Logs API と連携し Lambda からの Log を直接受け取ることが可能です

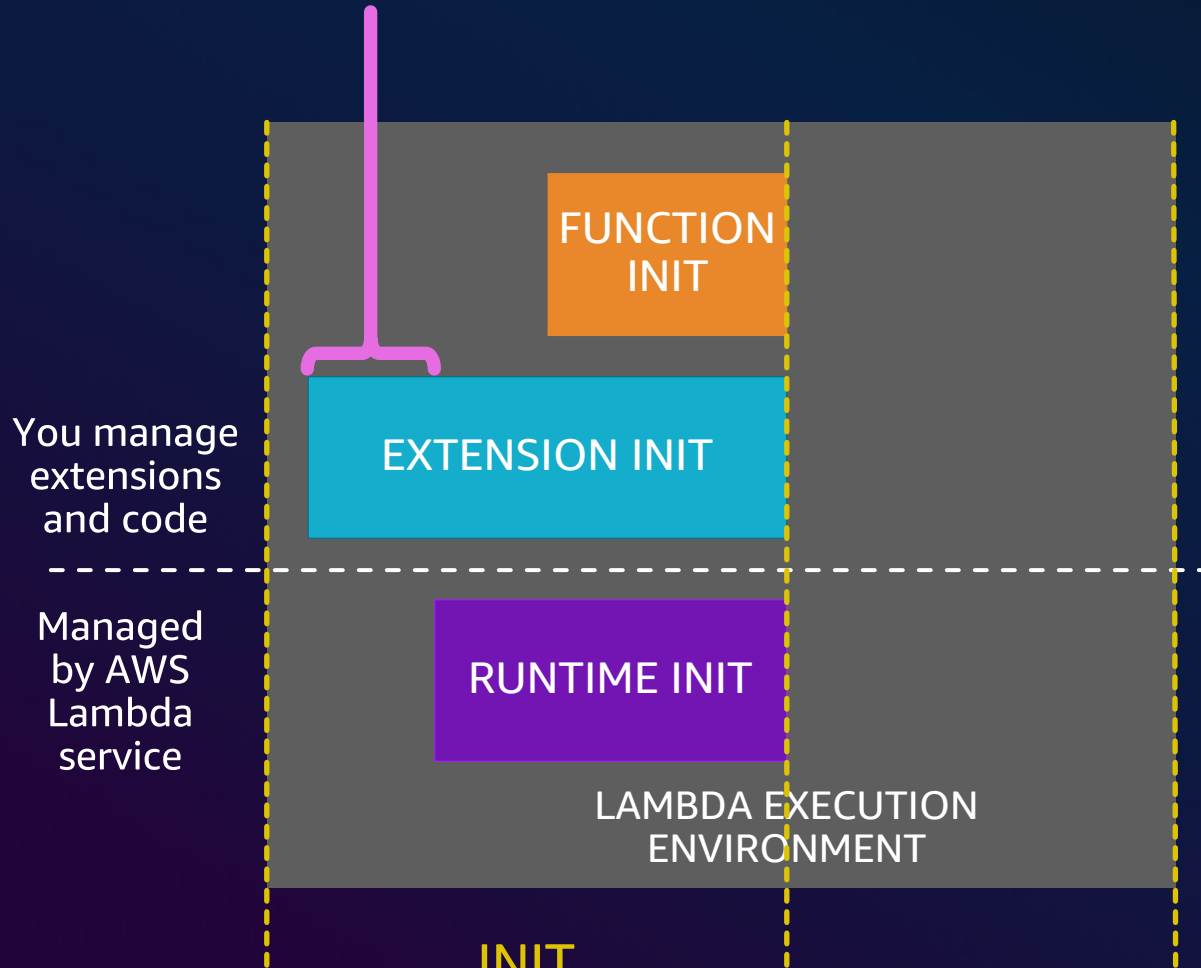


Lambda 関数 と Extension のライフサイクル



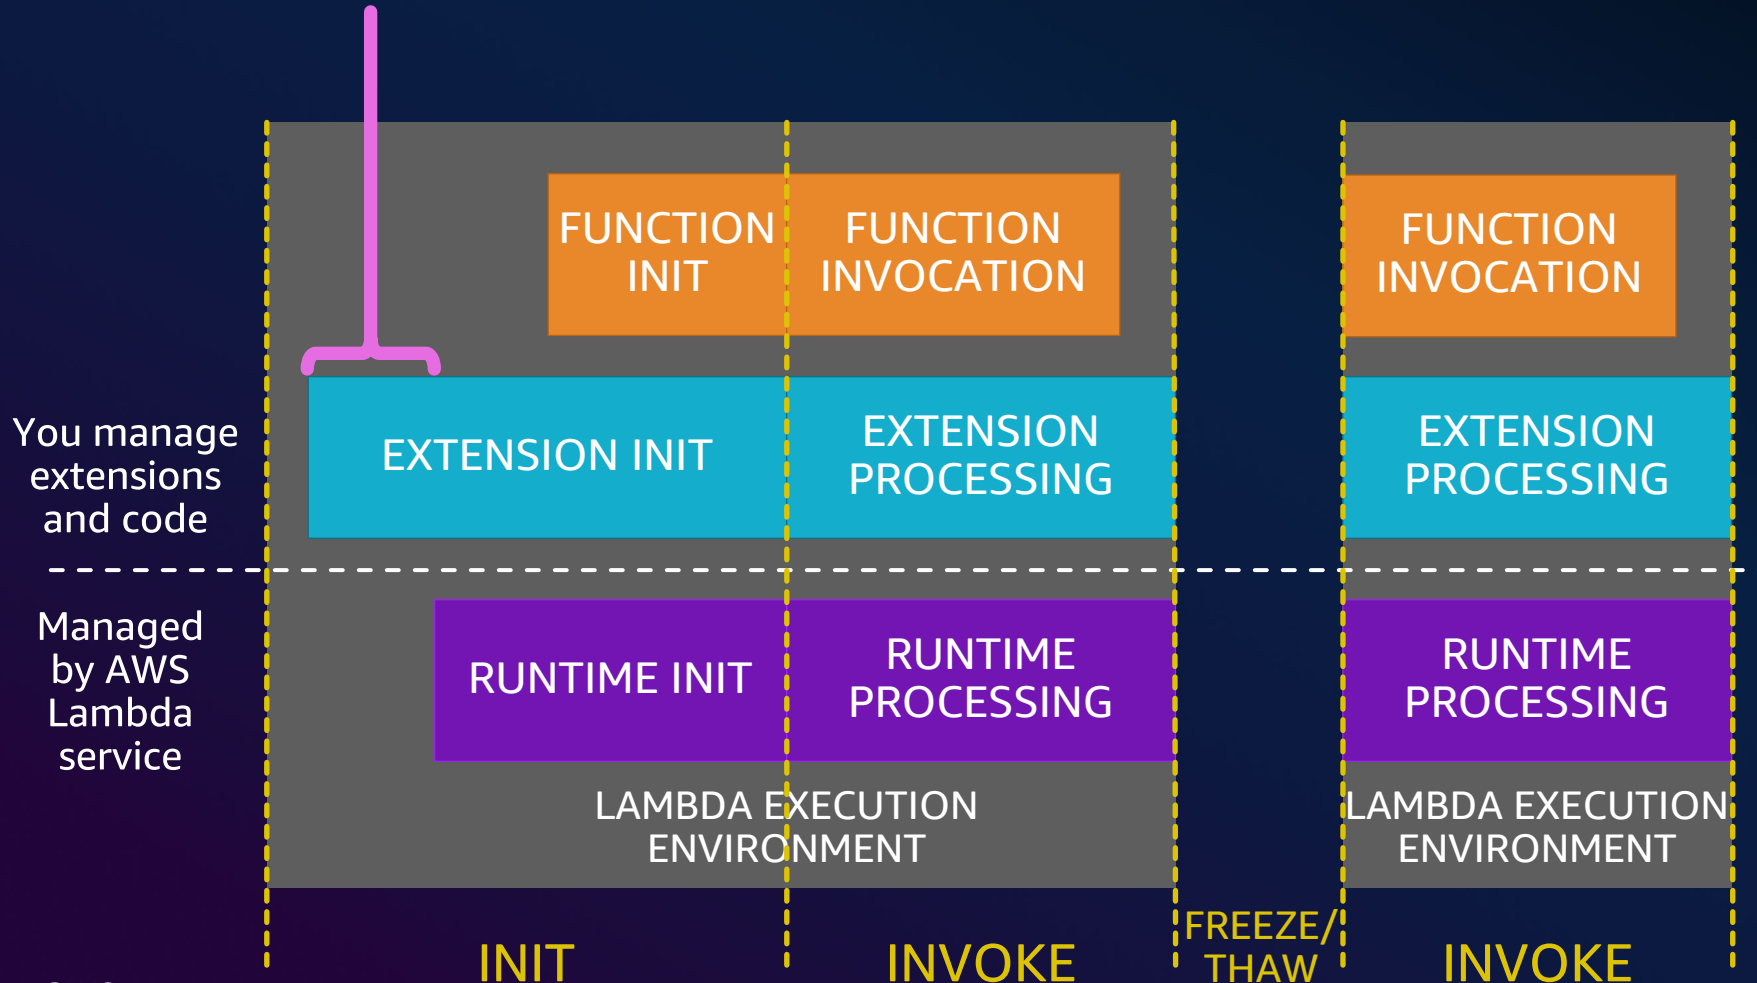
Lambda 関数 と Extension のライフサイクル

Extensions は
ランタイム実行
前に開始される



Lambda 関数 と Extension のライフサイクル

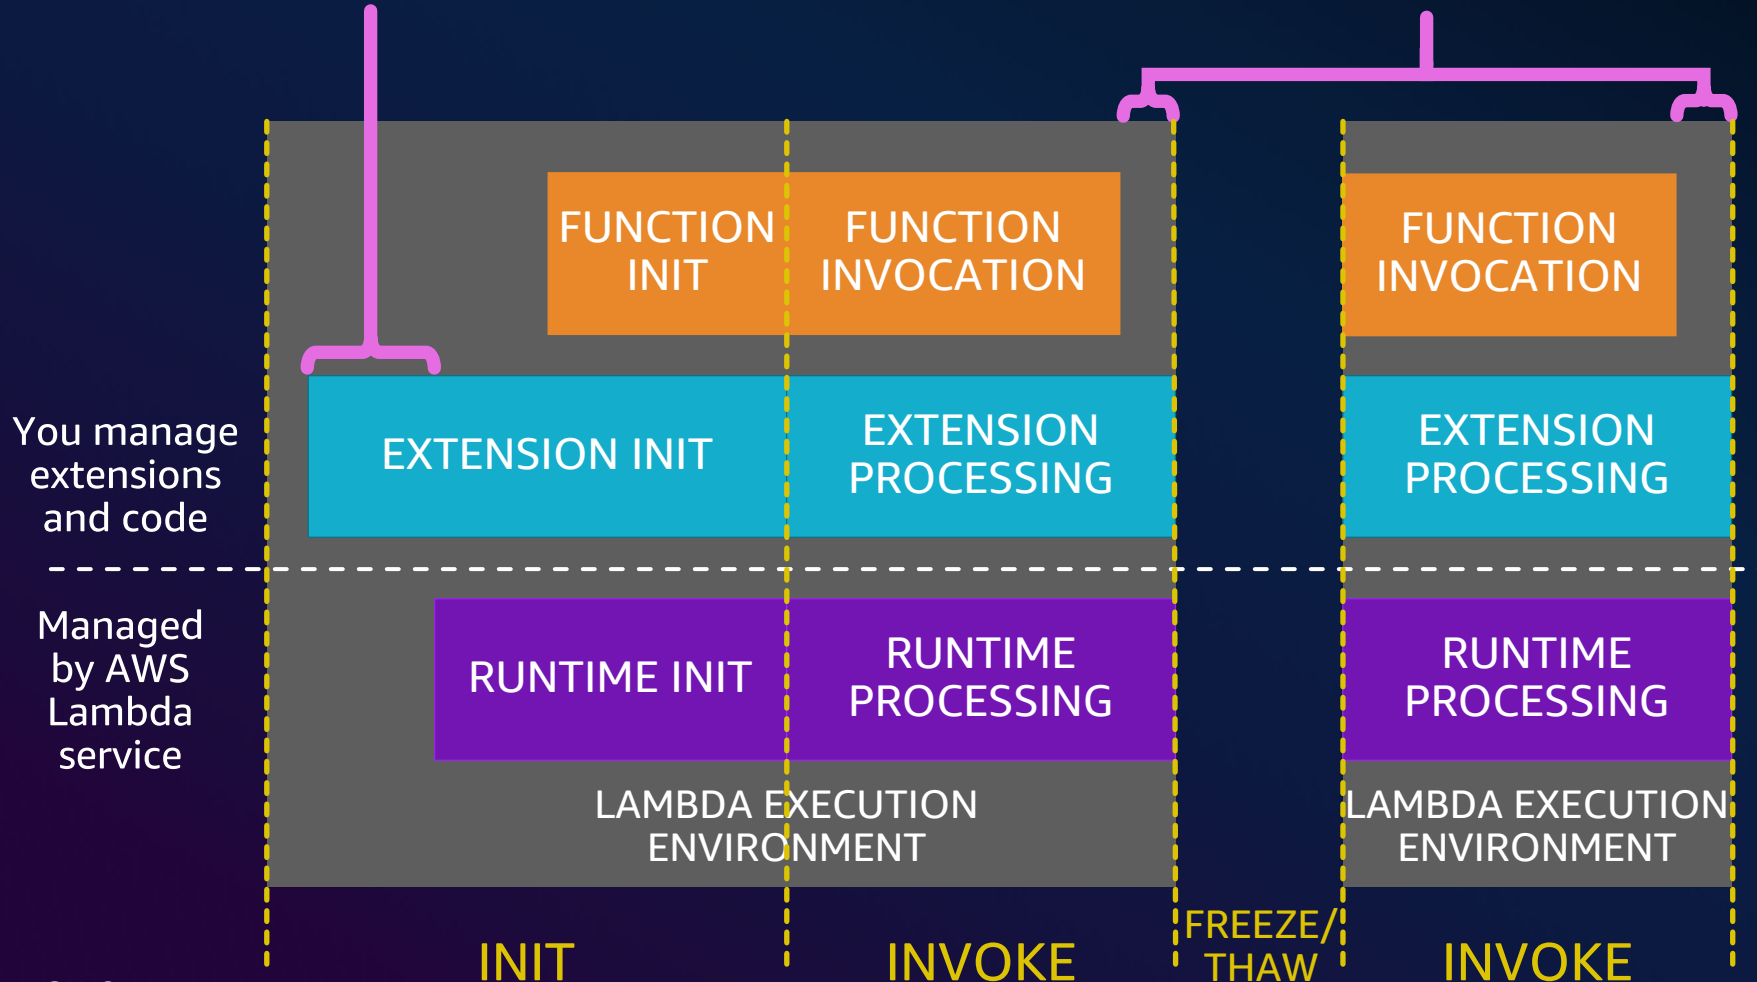
Extensions は
ランタイム実行
前に開始される



Lambda 関数 と Extension のライフサイクル

Extensions は
ランタイム実行
前に開始される

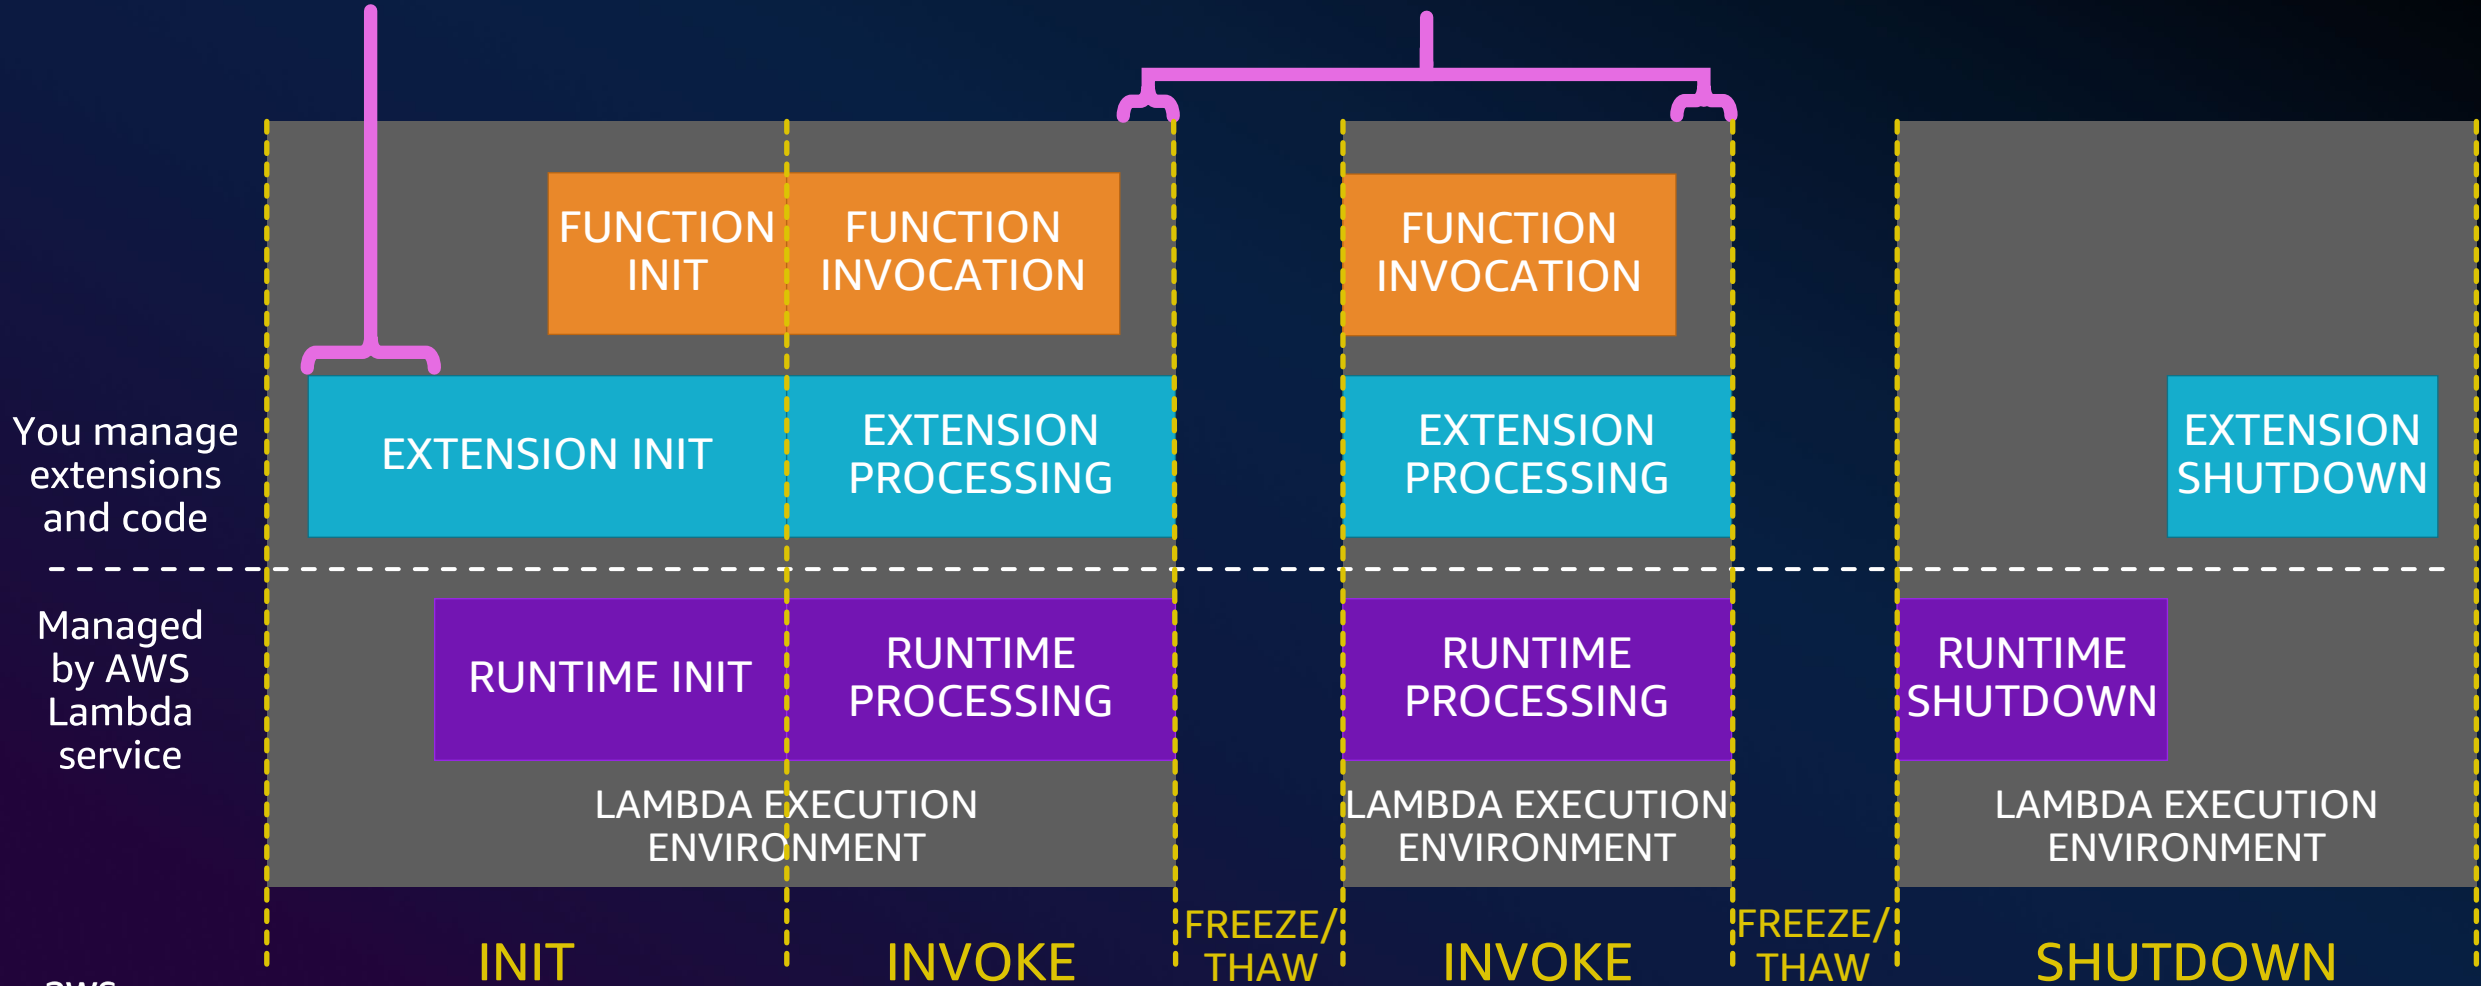
実行に関するテレメトリ
を処理するための実行後
の時間



Lambda 関数 と Extension のライフサイクル

Extensions は
ランタイム実行
前に開始される

実行に関するテレメトリ
を処理するための実行後
の時間

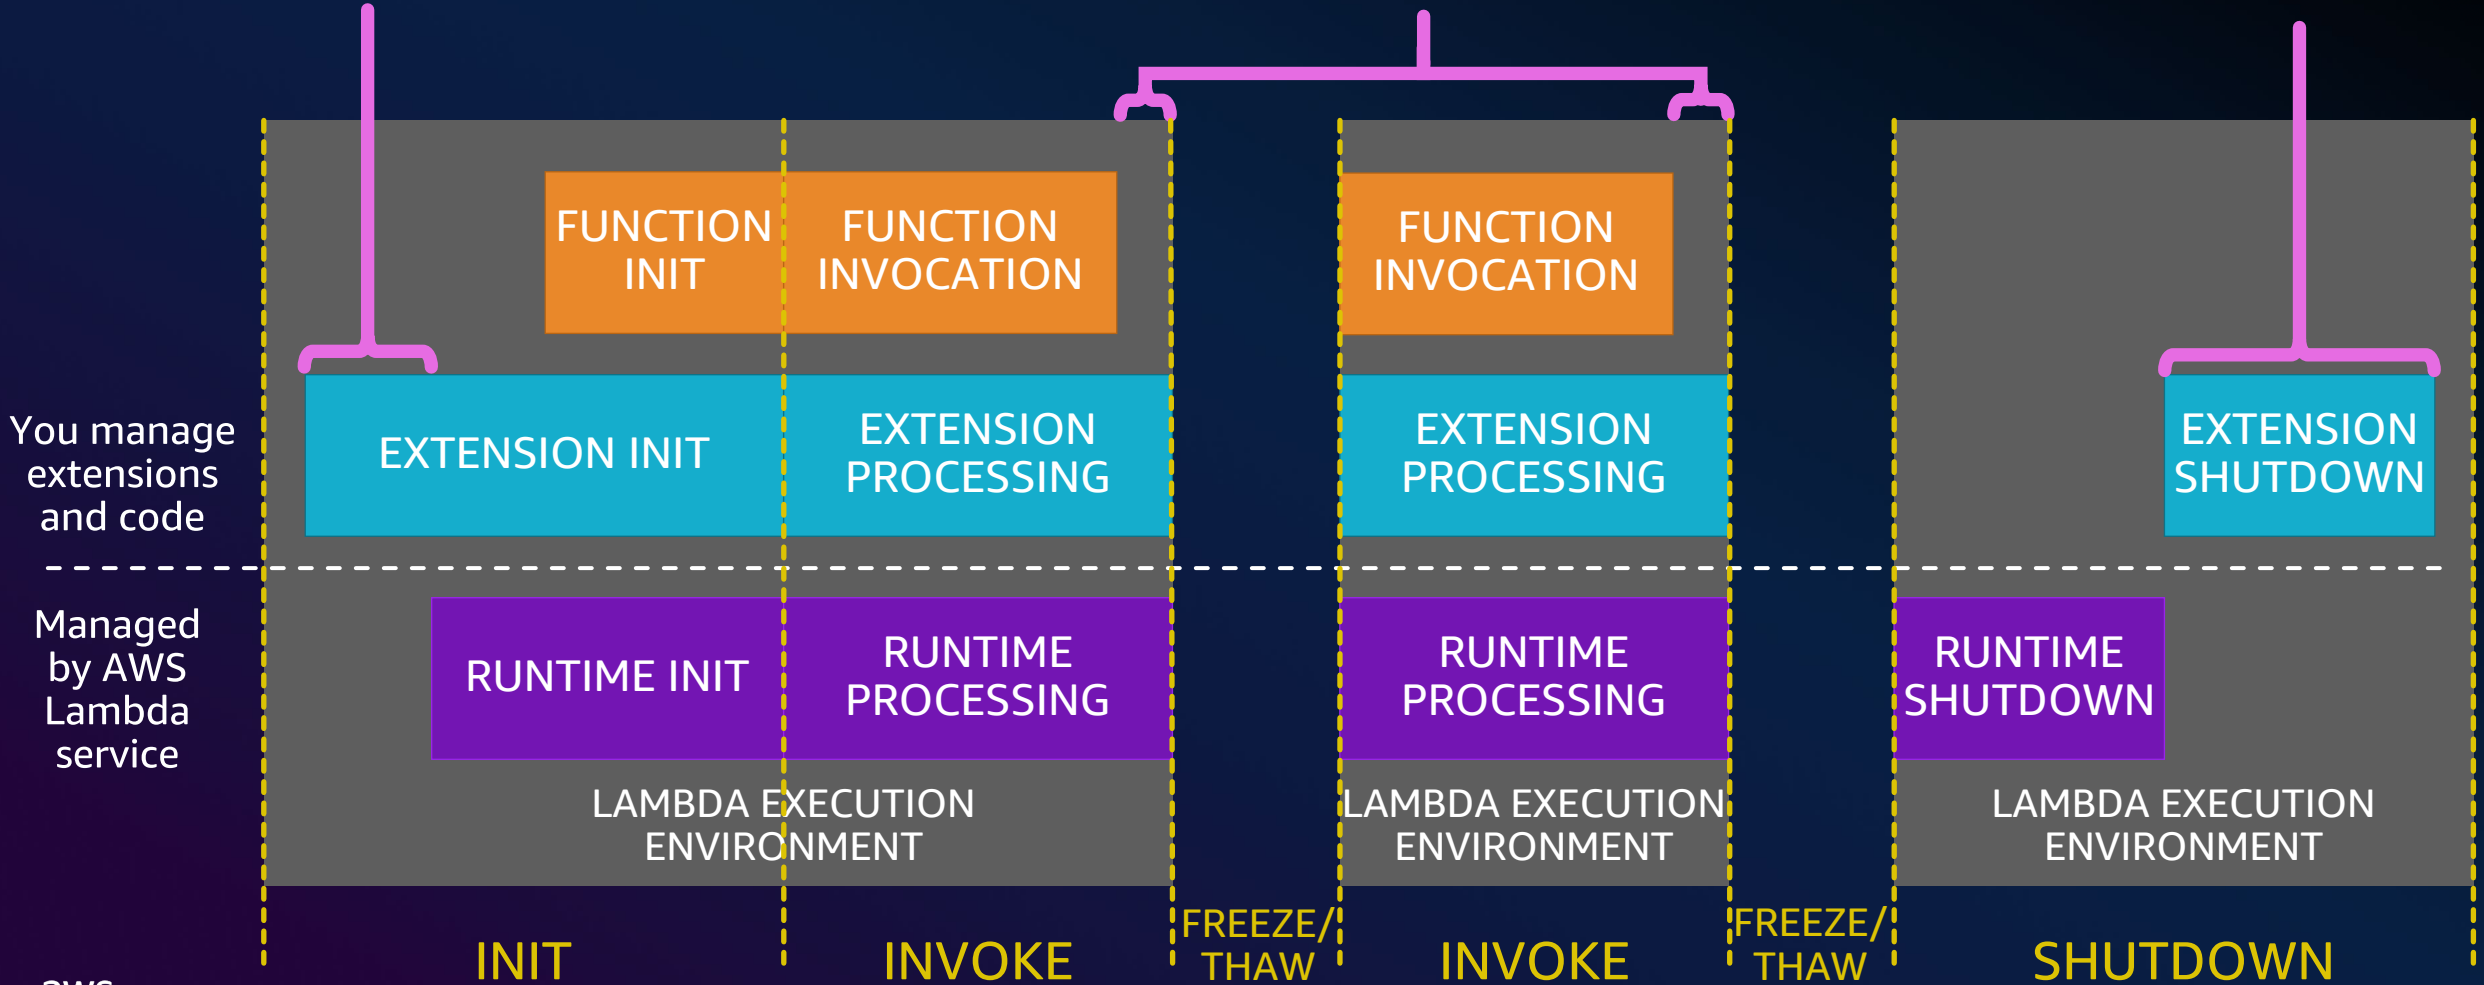


Lambda 関数 と Extension のライフサイクル

Extensions は
ランタイム実行
前に開始される

実行に関するテレメトリ
を処理するための実行後
の時間

ランタイム終了
後の最終タスク
のための時間

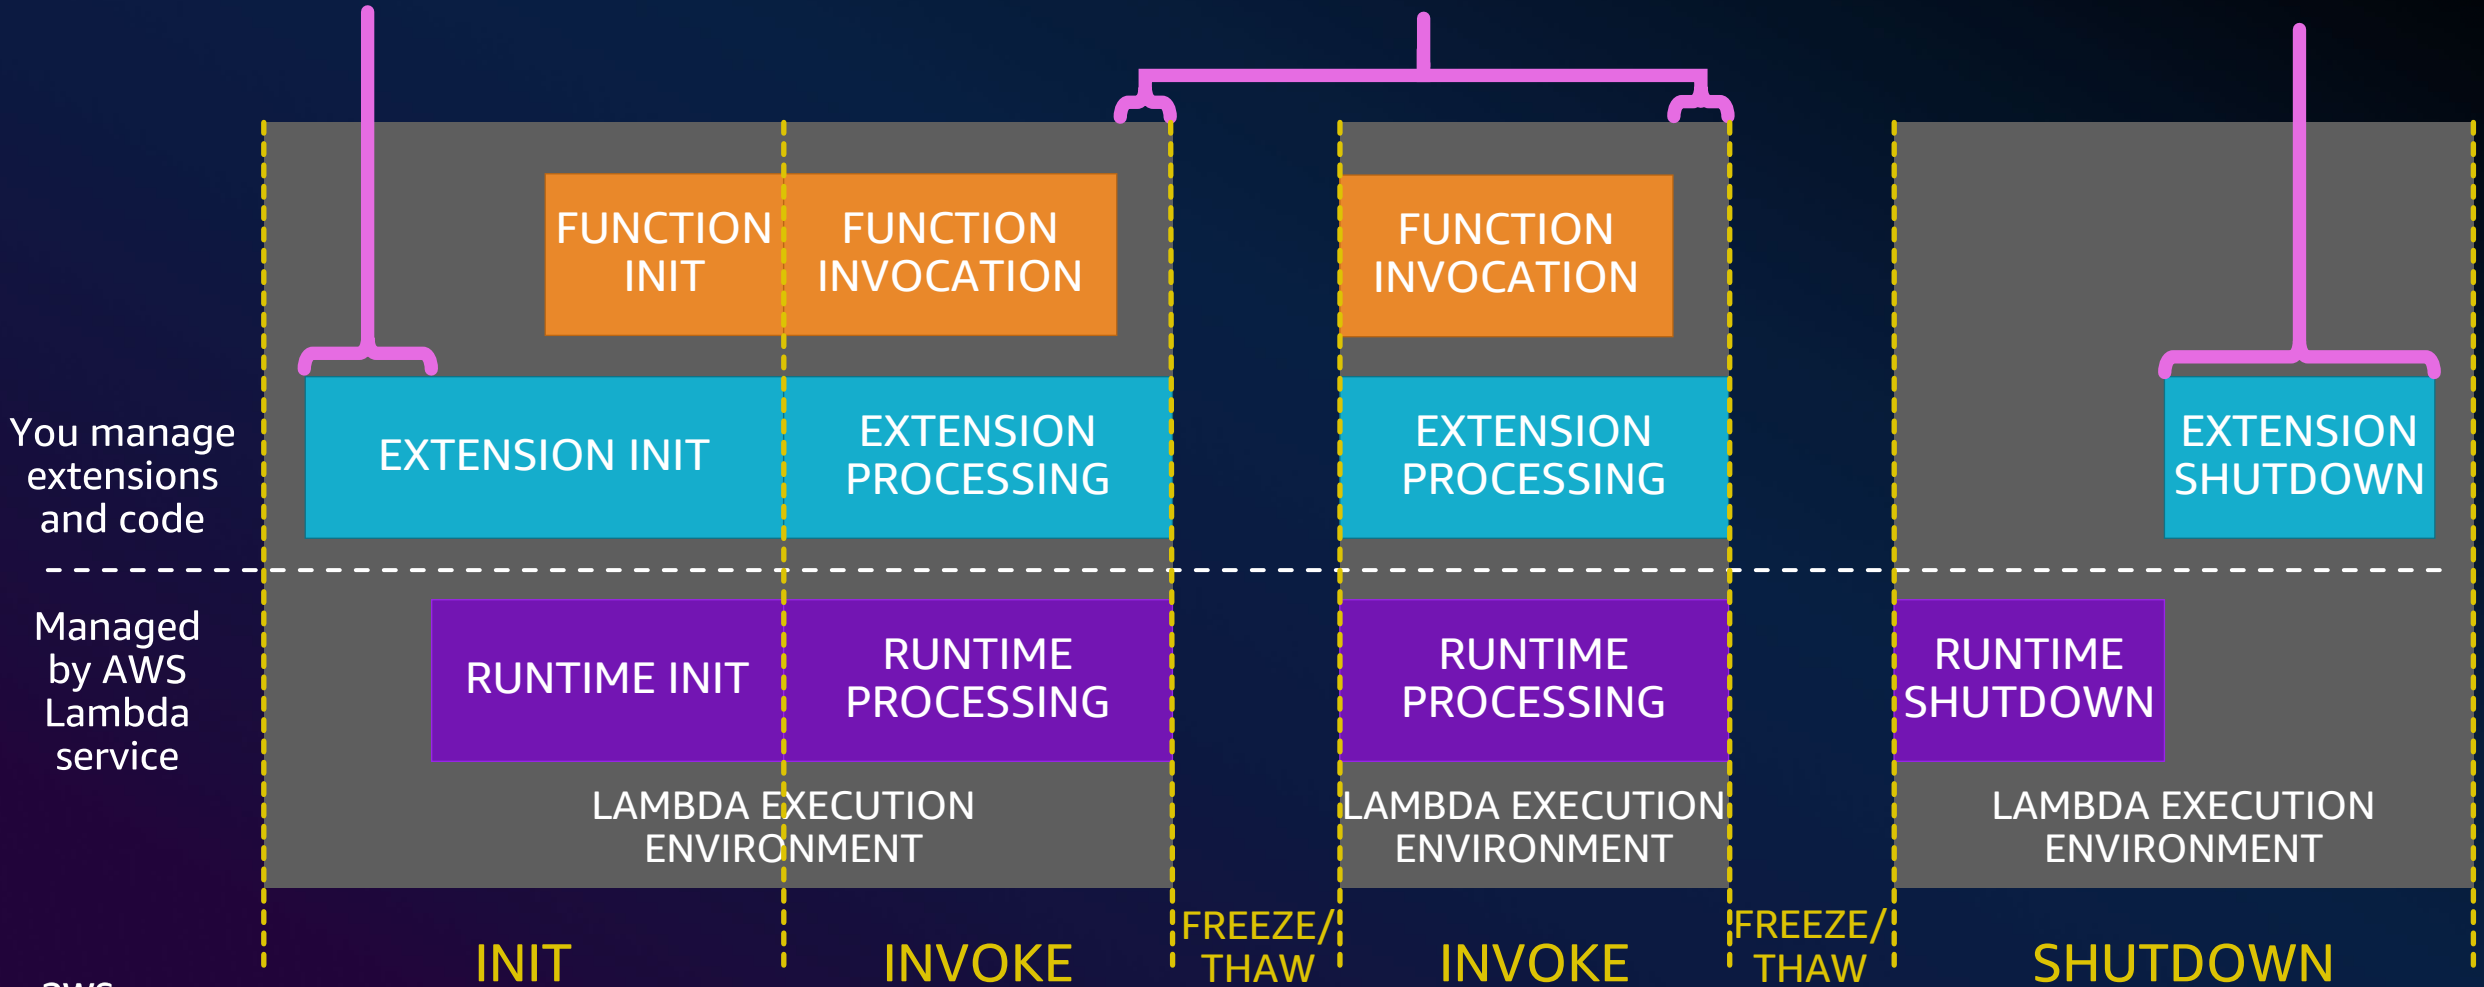


Lambda 関数 と Extension のライフサイクル

起動時間の
オーバーヘッド

実行時間の
オーバーヘッド

終了時間の
オーバーヘッド



Lambda Web Adapter



Lambda 実行環境

実行環境

Function Code

Layer Code

Function Runtime

Extension Code

Extension Runtime

Lambda Web Adapter (Python + Flask の場合)

- Lambda Event を HTTP Request に変換する Adapter を組み込む

Python + awsgi



- Lambda Web Adapter を利用

Python



Rust



Lambda Web Adapter (Python + Flask の場合)

Python で実装

- Lambda Event を HTTP Request に変換する Adapter を組み込む

Python + awsgi



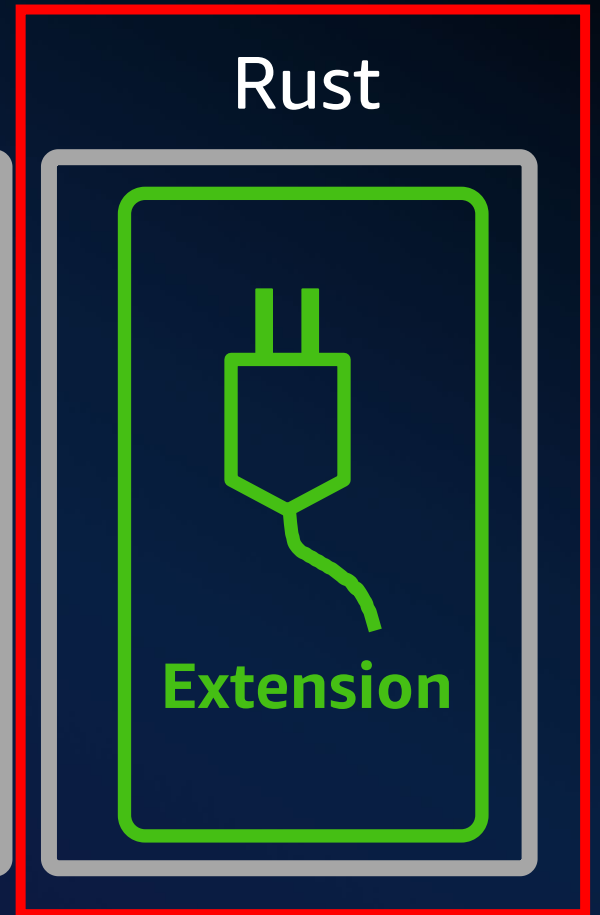
Extension を Rust で実装

- Lambda Web Adapter を利用

Python



Rust



Lambda Web Adapter (Python + Flask の場合)

- 既存コードの再利用性を Extension により実現
- Extension のオーバーヘッドを Rust 実装により軽減

Python

コード変更なし



Rust



Extension

LLRT(Low Latency Runtime)

AWS による実験的取り組み

Lambda 実行環境

実行環境

Function Code

Layer Code

Function Runtime

Extension Code

Extension Runtime

AWS による実験的取り組み

LLRT (Low Latency Runtime) は、**Rust** で構築された軽量 JavaScript ランタイムです。(JIT を取り除いている為 Rust だけの軽量化ではない)

Cold starts: 100.00% (64/64)

| (index) | p0 | p25 | p50 | p75 | p90 | p95 | p99 | p100 |
|---------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| λ | '1457.93' | '1492.26' | '1511.93' | '1530.59' | '1563.80' | '1599.94' | '1660.68' | '1678.28' |
| HTTP | '1575.16' | '1687.36' | '1719.00' | '1740.46' | '1756.37' | '1844.19' | '2463.06' | '3072.96' |

Warm starts: 100.00% (20000/20000)

| (index) | p0 | p25 | p50 | p75 | p90 | p95 | p99 | p100 |
|---------|---------|---------|---------|---------|----------|----------|----------|----------|
| λ | '6.10' | '21.37' | '33.20' | '51.27' | '74.44' | '106.60' | '193.63' | '599.87' |
| HTTP | '27.12' | '51.17' | '62.08' | '79.97' | '105.44' | '137.67' | '225.06' | '627.71' |

Node.js 20

Cold starts: 100.00% (64/64)

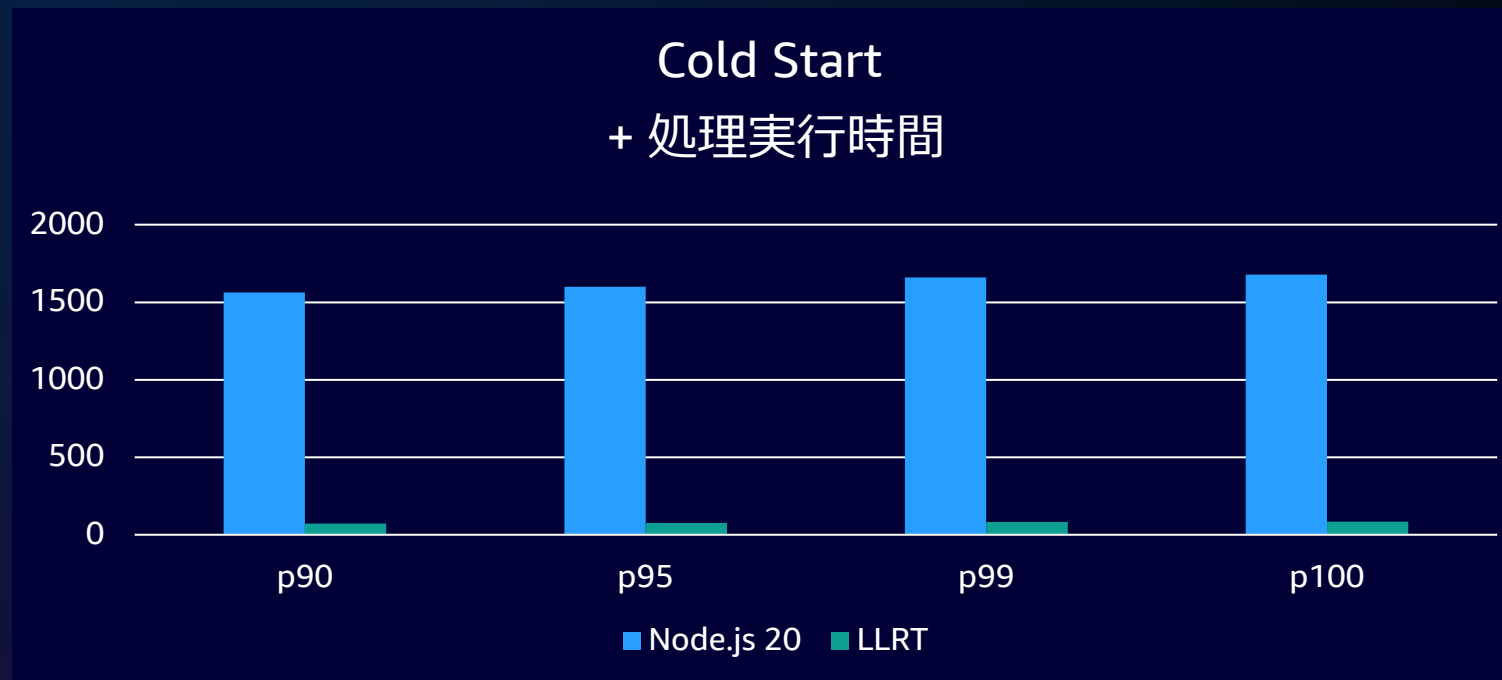
| (index) | p0 | p25 | p50 | p75 | p90 | p95 | p99 | p100 |
|---------|----------|----------|----------|----------|----------|----------|----------|----------|
| λ | '48.54' | '58.08' | '64.16' | '69.98' | '72.62' | '76.33' | '83.17' | '85.61' |
| HTTP | '155.37' | '201.67' | '235.61' | '247.57' | '253.87' | '261.37' | '285.32' | '304.57' |

Warm starts: 100.00% (20000/20000)

| (index) | p0 | p25 | p50 | p75 | p90 | p95 | p99 | p100 |
|---------|---------|---------|---------|---------|---------|---------|---------|----------|
| λ | '5.03' | '9.94' | '14.94' | '20.81' | '31.50' | '33.40' | '35.79' | '236.86' |
| HTTP | '27.14' | '39.04' | '43.72' | '54.67' | '60.48' | '62.47' | '68.61' | '272.19' |

LLRT

最大 10 倍以上の高速起動 & 最大 2 倍のコスト削減

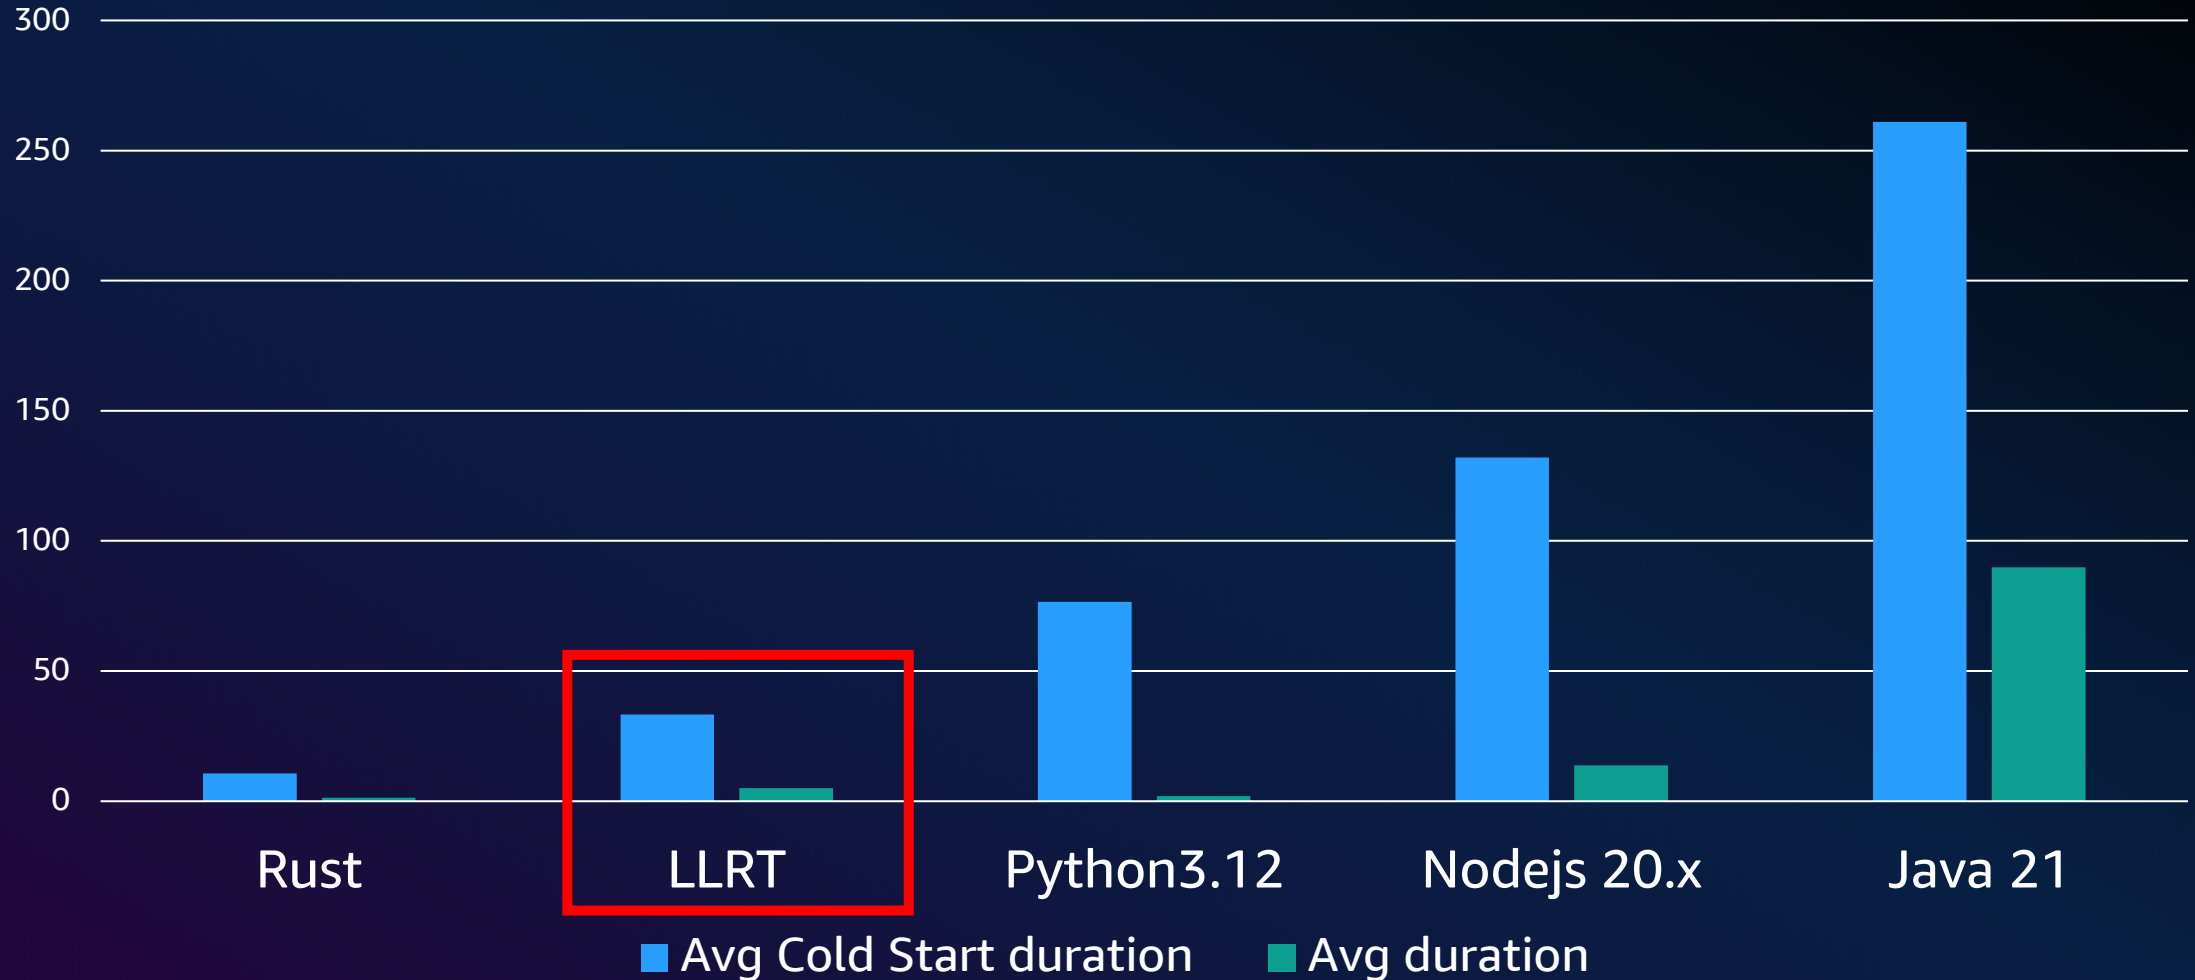


こちらで公開されているコードをカスタマイズ利用 <https://maxday.github.io/lambda-perf/>



計測結果

Lambda Cold Starts benchmark



作業者の環境で計測した結果であり公式の値ではありません



まとめ

- Lambda を高速化するメリットは 実行時間を短くするコスト削減以外に **Cold Start の起動時間**を短縮することでユーザー体験を良くすることができる
- Extension の利用によりハンドラーとは別言語 **Rust** を利用が可能になり高速化することが可能
- 言語ランタイムを **Rust** で実装する **LLRT** の高速化アプローチの紹介

Thank you!

