

Kubernetesコミュニティへ提案中の KEP「ロギング強化機能」についての紹介

2021/02/25
富士通株式会社
小林 大介

■ 名前・所属

- 小林大介
- 富士通株式会社

■ やってきたこと・やっていること

- OSSコミュニティで開発者として活動
- 2019年からK8sの開発、CKA取得やコミュニティへのコントリビュート
- ログ強化機能の開発

■ 提案中の機能の概要

- モチベーション・既存の問題点
- 提案している解決策

■ 機能の実装について

- 機能実現に必要な要素
- 機能の実装方針
- 実装に関する現在の課題

■ コミュニティ活動で苦労した点

過去の発表とのつながり

- 前回（Kubefest）の発表資料はこちら
(<https://www.slideshare.net/JinHase/kube-fest-tokyolog>)
- 今回は、前回からどのように変化したか、差分を主に話します
- 前回話した内容は、概要の部分でサマリーを話します

■ 提案中の機能の概要

- モチベーション・既存の問題点
- 提案している解決策

■ 機能の実装について

- 機能実現に必要な要素
- 機能の実装方針
- 実装に関する現在の課題

■ コミュニティ活動で苦労した点

Kubernetesにおけるロギング機能

- K8sでは主に以下の種類のログを記録


ログの種類	概要	主な用途
Podログ	Pod上で動作するアプリの標準出力/ エラー出力	アプリ側のトラブルシューティ ング
イベントログ	K8sクラスタで発生したイベント	K8sクラスタ環境側のトラブ ルシューティング
コンポーネントログ	K8sコンポーネントごとの個別ログ (kubelet、kube-apiserverなど)	イベントログより詳細な内部 動作を追う場合に利用
Auditログ	kube-apiserverとやりとりする HTTPリクエスト/レスポンス	セキュリティ/監査など

- トラブルシューティングで最もよく扱うログはPodログとイベントログ
- この2つのログで原因を絞り込めない場合、コンポーネントログを見る場合あり

Kubernetesのロギング機能の課題

■ コンポーネント間を跨るログ調査が困難

- K8sでは任意の操作(kubectl applyなど)の延長で、複数のコンポーネントが動作する
- このため、クラスタ内部の一連の動作を追う場合は、コンポーネントを跨ったログ解析が必要
- しかし、K8sのコンポーネントログは、**コンポーネントごとに独立して出力**される
- このため、個々のコンポーネントのログから関連するログを抽出し、紐づける作業が必要



コンポーネント間のログの紐づけ方法

■ 既存の手法

- 各コンポーネントのログをリソース名でフィルタリング
(例: Pod作成に関するログを紐づける場合は、Pod作成時の名前で各ログをクエリする)
- 各コンポーネントのログを時系列で並べ、近い時間帯のログを精査して手作業で紐づける

■ 既存手法の課題

- リソース名のないログは抽出不可
- 同じ時間帯に複数のAPIリクエストが投入された場合、仕分けに時間がかかる
- 階層的なリソースに対する複数Controller開発をする場合、ログの抽出や紐づけが大変

- 任意のユーザー操作(kubectl applyなど)の結果として各コンポーネントが出力するログに一意的なID(以降Trace IDと呼ぶ)を付与する
- Trace IDのメリット
 - 一連のK8s内部の動作を追う場合に、各コンポーネントのログをTrace IDでフィルタリングするだけで関連するログを簡単に抽出可能
 - リソース名のないログも対応可能
 - タイムスタンプやログの内容精査などの、関連するログを仕分ける作業も不要
 - 自作のオブジェクトのコントローラーにも導入可能

実際のログ例でのイメージ(2/2)

- TraceIDをキーにログを抽出して時系列順に整理することで、処理の流れを把握可能
- エラーログからの原因調査は、エラーログに付与されているTraceIDをキーとして用いる
- 実際のログの収集や解析はElasticsearchやKibanaなど他OSSの使用を想定

```
10610 11:35:39.936636 23035 httplog.go:90] verb="GET" URI="/openapi/v2?timeout=32s" latency=719.637ms resp=304 UserAgent="kubect/v1.18.2 (linux/amd64) kubernetes/52c56ce" srcIP="127.0.0.1:43628" traceID="111":
10610 11:35:40.154162 23035 httplog.go:90] verb="GET" URI="/api/v1/namespaces/default/services/nginx" latency=2.009283ms resp=404 UserAgent="kubect/v1.18.2 (linux/amd64) kubernetes/52c56ce" srcIP="127.0.0.1:43628" traceID="111":
10610 11:35:40.189286 23035 httplog.go:90] verb="POST" URI="/api/v1/namespaces/default/services" latency=33.947136ms resp=201 UserAgent="kubect/v1.18.2 (linux/amd64) kubernetes/52c56ce" srcIP="127.0.0.1:43628" traceID="111":
10610 11:35:40.199000 23035 httplog.go:90] verb="GET" URI="/apis/apps/v1/namespaces/default/deployments/nginx" latency=8.157038ms resp=404 UserAgent="kubect/v1.18.2 (linux/amd64) kubernetes/52c56ce" srcIP="127.0.0.1:43628" traceID="111":
10610 11:35:40.244534 23452 replica_set.go:362] too few replicas for ReplicaSet default/nginx-97499b967, need 3, creating 3 traceID="111"
10610 11:35:40.245614 23452 event.go:278] Event(v1.ObjectReference{Kind:"Deployment", Namespace:"default", Name:"nginx", UID:"76ef788a-b4c3-4cbe-9961-6c9f552d594c", APIVersion:"apps/v1", ResourceVersion:"717", FieldPath:""}): type: 'Normal' reason: 'ScalingReplicaSet' Scaled up replica set nginx-97499b967 to 3 traceID="111"
10610 11:35:40.273453 23452 event.go:278] Event(v1.ObjectReference{Kind:"ReplicaSet", Namespace:"default", Name:"nginx-97499b967", UID:"cc728714-df1b-465e-aba0-249f8aaf614a", APIVersion:"apps/v1", ResourceVersion:"718", FieldPath:""}): type: 'Normal' reason: 'SuccessfulCreate' Created pod: nginx-97499b967-6ztdx traceID="111"
10610 11:35:40.273856 23452 deployment_controller.go:485] Error syncing deployment default/nginx: Operation cannot be fulfilled on deployments.apps "nginx": the object has been modified; please apply your changes to the latest version and try again traceID="111"
10610 11:35:40.280390 23452 event.go:278] Event(v1.ObjectReference{Kind:"ReplicaSet", Namespace:"default", Name:"nginx-97499b967", UID:"cc728714-df1b-465e-aba0-249f8aaf614a", APIVersion:"apps/v1", ResourceVersion:"718", FieldPath:""}): type: 'Normal' reason: 'SuccessfulCreate' Created pod: nginx-97499b967-xc5n8 traceID="111"
10610 11:35:40.342805 23452 event.go:278] Event(v1.ObjectReference{Kind:"ReplicaSet", Namespace:"default", Name:"nginx-97499b967", UID:"cc728714-df1b-465e-aba0-249f8aaf614a", APIVersion:"apps/v1", ResourceVersion:"718", FieldPath:""}): type: 'Normal' reason: 'SuccessfulCreate' Created pod: nginx-97499b967-sqgq2 traceID="111"
10610 11:35:40.345157 23617 reflector.go:207] Starting reflector *v1.Secret (0s) from object-"default"/"default-token-gfz64" traceID="111"
10610 11:35:40.345228 23617 reflector.go:243] Listing and watching *v1.Secret from object-"default"/"default-token-gfz64" traceID="111"
10610 11:35:40.370523 23617 kubelet.go:1837] SyncLoop (ADD, "api"): "nginx-97499b967-xc5n8_default(0e00848d-902d-45b2-b5ab-1a4116b6bbd4)" traceID="111"
10610 11:35:40.370595 23617 topology_manager.go:233] [topologymanager] Topology Admit Handler
10610 11:35:40.370713 23617 kubelet_pods.go:1363] Generating status for "nginx-97499b967-6ztdx_default(f7c403c0-5cca-4bf6-a789-3656738c1e96)" traceID="111"
10610 11:35:40.387846 23617 volume_manager.go:372] Waiting for volumes to attach and mount for pod "nginx-97499b967-6ztdx_default(f7c403c0-5cca-4bf6-a789-3656738c1e96)" traceID="111"
```

■ 提案中の機能の概要

- モチベーション・既存の問題点
- 提案している解決策

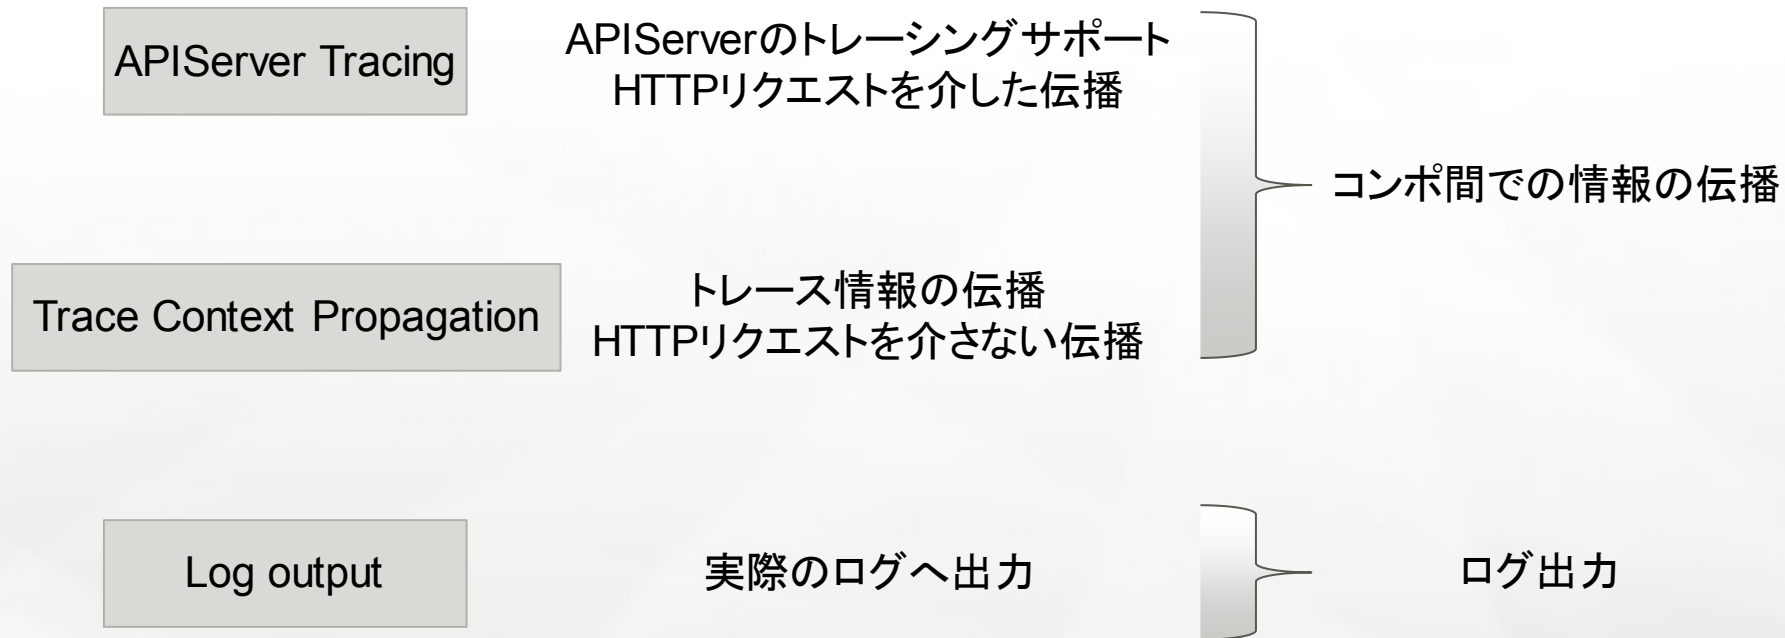
■ 機能の実装について

- 機能実現に必要な要素
- 機能の実装方針
- 実装に関する現在の課題

■ コミュニティ活動で苦勞した点

機能実現に必要な要素

■ ログ強化の機能は、主に以下の要素から実現される



■ どのような要素か？

- APIServerが受け取ったリクエストのトレーシングが可能になる
- トレース情報の生成とエクスポートを行う
- 他KEPで進行中
(<https://github.com/kubernetes/enhancements/tree/master/keps/sig-instrumentation/647-apiserver-tracing>)

■ 用語の定義


- スパン：開始と終了の時刻を持ったトレースの最小要素
- トレース：一つの処理に関するスパンを集めたもの
- トレースコンテキスト：トレース情報への参照

- **OpenTelemetry**を使用し、**APIServerのトレーシングを可能に**
 - incoming/outgoing requestのスパンを生成し、エクスポート
 - トレースコンテキストをincoming requestからoutgoing requestに伝播
- **OpenTelemetry** : <https://opentelemetry.io/>
 - CNCFがホストするobservabilityのフレームワーク
 - メトリクス・ログ・トレースの計測・生成・収集・エクスポートを行う

APIServer Tracing


■ OpenTelemetryを使用し、APIServerのトレーシングを可能に

- incoming/outgoing requestのスパンを生成し、エクスポート
- トレースコンテキストをincoming requestからoutgoing requestに伝播



■ OpenTelemetryを使用し、APIServerのトレーシングを可能に


- incoming/outgoing requestのスパンを生成し、エクスポート
- トレースコンテキストをincoming requestからoutgoing requestに伝播



Trace Context Propagation


■ どのような要素か？

- オブジェクトへのトレースコンテキストの保存
- コントローラーへのトレースコンテキストの伝播



■ Mutating Admission Webhookを導入

- Admission Webhookは、リソースの作成や更新をトリガーとして、validationやmutationを行うことができる
- リクエストからTrace Contextを抽出し、オブジェクトへ埋め込む



- **トレースコンテキストをオブジェクトアノテーションとして伝播**
- **ユーティリティ関数を導入して伝播の仕組みを整える**
 - オブジェクトからTrace Contextを取り出すなどの処理を行う関数群
 - 実行された作業を、同じアクション（user request）に属するものとして、コンポーネントを跨ってリンクするには、プロセスの境界を越えてトレースコンテキストを渡す必要がある
 - 従来の分散システムでは、このコンテキストはRPCメタデータまたはHTTPヘッダーを介して受け渡される
 - ただし、Kubernetesはウォッチベースのため、トレースコンテキストをターゲットオブジェクトに直接アタッチする必要がある。

■ どのような要素か？

- トレースコンテキストをログに出力することで、ログの紐づけが可能になる
- Trace IDにより、任意のユーザーアクションに関連したログを一括で抽出できる

■ Structured logging

(<https://github.com/kubernetes/enhancements/tree/master/keps/sig-instrumentation/1602-structured-logging>)

- 構造化されたログ出力を実現するKEP
- この機能を利用して、構造化形式でのログ出力を予定している

- これまで提案していた内容は、深い議論が必要な部分が二つ存在する
 - Contextをオブジェクト間で伝播する
 - Trace id をログに出力する
- このままでは承認が難しいという指摘
 - 議論が二つ立ち上がる
 - 承認が必要なSIGが増える などの理由
- 二つの部分を分割して提案することにより
 - KEPではコンテキストのコントローラーへの伝播をメインスコープに
 - ログの部分は、issueを起こしてそこで実装する予定

■ コミュニティ状況

- KEP状況 (<https://github.com/kubernetes/enhancements/pull/2312>)
- Trace context propagationの機能のαを1.22に実現が目標

■ 提案中の主要機能：

- Trace context をオブジェクトアノテーションに付与して伝播
- Trace context から必要な情報をログに出力

■ 分割後の状況

- Trace context propagationと Log output の二つに分割
- 現在はまずTrace context propagationの実現に向けて活動中
- Log output はKEPで提案がissueで提案して実現を目指す

■ 提案中の機能の概要

- モチベーション・既存の問題点
- 提案している解決策

■ 機能の実装について

- 機能実現に必要な要素
- 機能の実装方針
- 実装に関する現在の課題

■ コミュニティ活動で苦労した点

■ なぜ分割という話に？

- 最初は一人のTech leadの人にレビューをもらいながら進めていた
- 締め切りが近くなると、ほかのレビュアーからもコメントをもらえるように
- KEPが複雑になりすぎている、承認が必要なSIGが増えるといった指摘
- Trace Context伝播部とログ出力部を分割することにした
- とはいえ、承認が簡単になったわけではなく、各部分へ集中するための分割


■ 実際に起こったこと

- 他のKEPやOSSの影響でスケジュールがどんどん後ろ倒しに
- Production Readiness Review Questionnaireの書き方が大きく変わり、KEPを書き直した
- SIG-Instrumentationだけの範囲で済むように調整していたが、ほかのSIG (SIG-Architecture) の承認も必要になった
- “ほかのSIG”がSIG-API-machineryに変わった

- ログ機能の強化のためのKEPを提案しています
 - Trace Context Propagation
 - Log output

- 1.22でαが導入できるように活動しています

- コミュニティとのやりとりはいろいろと大変ですが、勉強になることも面白いことも多いです



shaping tomorrow with you