

kagent と MCP で実現する Kubernetes-native な AIOps

近藤智文 / サイバーエージェント
CODT2026

近藤 智文

- サイバーエージェント24新卒
- プライベートクラウド IaaS 基盤の開発・運用をやっています
- OpenStack/OVS/Kubernetes
/Go/Python



<https://github.com/TOMOFUMI-KONDO/>


https://x.com/tomokon_0314

- kagent (AI Agent Runtime) の基本的な概念や使い方
- kagent を用いた AIOps の一例として、アラート自動応答エージェントシステムの設計パターンや具体的な実装

新リージョンにおける アラート対応の課題

社内ユーザに以下の機能を提供

- IaaS (OpenStackベース)
- PaaS/SaaS
 - Kubernetes as a Service
 - Serverless Computing
 - ML Platform
 - GitHub Actions Self-Hosted Runner
 - DB/Storage, etc.



ハードもソフトもゼロベースで構築

- 最新世代のハードウェアによりリソース効率やパフォーマンスの大幅向上
- 統合されたUI/UX・メンテナンスタイムの削減による利用者の負担削減
- 高いテナント分離性によるセキュリティ向上

新リージョンの立ち上げに伴いアラート対応が増大...

- インスタンスが起動しない
- HV (Hypervisor) のネットワークが全断
- エラーログの急増
- etc.



新リージョンの立ち上げに伴いアラート対応が増大...








- インスタ
- HV (Hy
- エラー
- etc.

人力対応が辛いので、
最近流行りの AI ってやつで
なんとかできないか🤔



AI Agent による アラート対応

LLM / AI Agent の発展




開発だけでなく、運用にも AI Agent を導入するソリューションやユースケースが増えている。

- Datadog Bits AI
- AWS DevOps Agent
- kagent
- etc.



従来のアラート対応



またアラートだ
確認しなきゃ...



AIエージェントを組み込んだ アラート対応



原因は〇〇です。
次のアクションを
提案します。

.....

承認、っと。




今回は、AIOps のソリューションとして kagent に着目


- Datadog Bits AI
- AWS DevOps Agent
- kagent ← ← ←
- etc.




- CNCF Sandbox Project の OSS
- **k8s-native** な AI Agent Runtime
 - 全てのリソースを **k8s リソース**として定義
 - k8s やエコシステムの調査・操作のツールが標準搭載
 - 組み込みの GUI や CLI も搭載
- **A2A / MCP** 連携機能
- 豊富な LLM Provider 対応



アラート自動応答 エージェントシステム



システム設計



アラートの検知



Alertmanager アプリ 3月31日 01:10

[FIRING:4]

Pod kagent-controller-7ccddb48c8-7hw5h container controller in kagent memory usage is 92.92% of limit

Pod neutron-server-0 in stg-openstack02 was OOMKilled

Pod neutron-server-1 in stg-openstack01 restarted 10 times in 1h

Pod neutron-server-0 in stg-openstack02 restarted 10 times in 1h

Slack Bolt ソケットモードでアラート検知



Bolt



DATADOG

1. websocket 接続

2. 待機

3. アラート通知

4. アラートメッセージを送信

Slack Bolt ソケットモードでアラート検知

```
@app.event("message")
def handle_message(event, logger):
    channel = event.get("channel")
    if channel not in CHANNEL_IDS:
        return
    # Ignore thread replies to prevent duplicate triggers
    if event.get("thread_ts"):
        return

    msg_ts = event["ts"]
    msg_body = _extract_message_body(event)
    prompt = f"チャンネル {channel} のタイムスタンプ {msg_ts} のアラートを調査して、結果をスレッドに投稿してください。"
    if msg_body:
        prompt += f"\n\nアラート本文:\n{msg_body}"


    payload = ...
```

A2A による Agent 呼び出し

A2A (Agent2Agent) Protocol

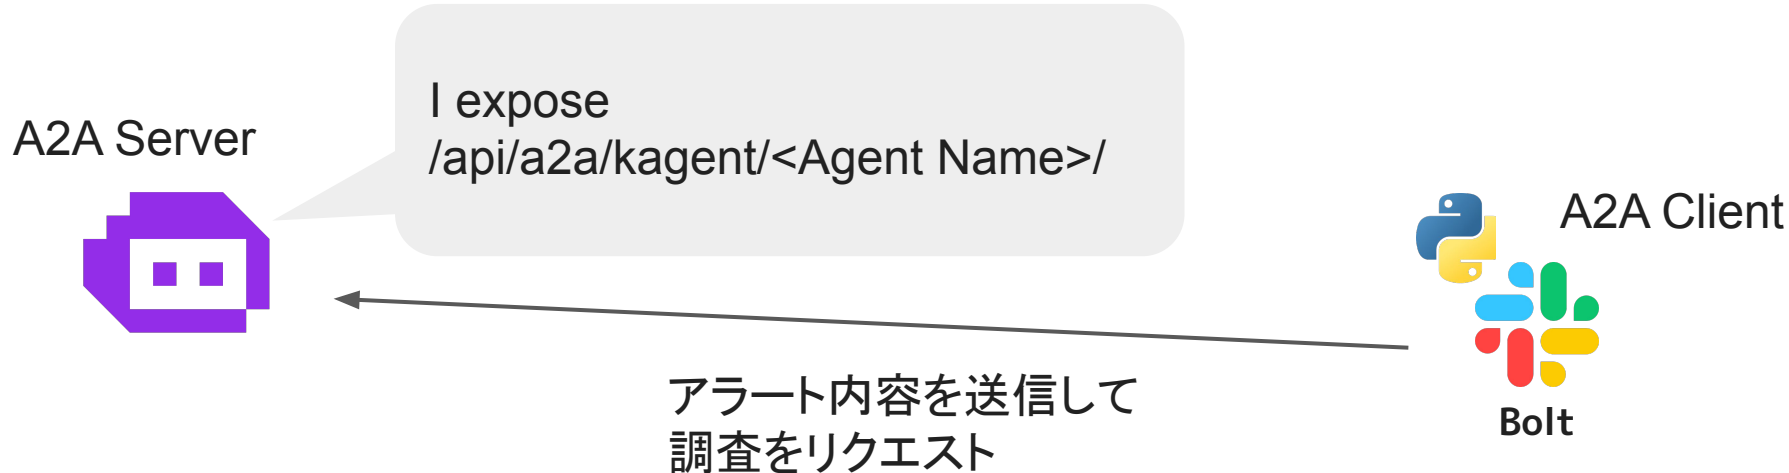
Google が提唱した
オープンスタンダードな
AI Agent 間通信プロトコル

- Agent Discovery
- Invoke another agent
- Auth



<https://developers.googleblog.com/en/a2a-a-new-era-of-agent-interoperability/>

“Agent” リソースを作成するだけで A2A が利用可能




```
payload = json.dumps(  
    {  
        "jsonrpc": "2.0",  
        "id": str(uuid.uuid4()),  
        "method": "message/send",  
        "params": {  
            "message": {  
                "role": "user",  
                "messageId": str(uuid.uuid4()),  
                "parts": [{"kind": "text", "text": prompt}],  
            }  
        },  
    },  
).encode()  
  
req = urllib.request.Request(  
    A2A_ENDPOINT,  
    data=payload,  
    headers={"Content-Type": "application/json"},  
    method="POST",  
)
```



Alertmanager アプリ 3月31日 01:10

[FIRING:4]

Pod kagent-controller-7ccddb48c8-7hw5h container controller in kagent memory usage is 92.92% of limit

Pod neutron-server-0 in stg-openstack02 was OOMKilled

Pod neutron-server-1 in stg-openstack01 restarted 10 times in 1h

Pod neutron-server-0 in stg-openstack02 restarted 10 times in 1h

1 件の返信



Compute Alert Responder アプリ 3月31日 01:10




アラートを確認中です...

kagent における Agent 設定

Manifest (yaml) で全てを定義

kagent では Agent を含むあらゆるものを Kubernetes の Resource として定義することが可能



```
spec:  
  description: >  
    Slackのアラートチャンネルを監視し、Datadogのログ等を使って  
    自動的にアラートの調査・分析を行い、結果をSlackスレッドに投稿するAgent。  
  declarative:  
    systemMessage: |  
      cyclcloudインフラチームのアラート対応エージェント。  
      Slackのアラートを調査し、Datadogのモニタリングデータで分析を行う。  
      すべての出力は日本語で、敬語を使わず簡潔に書くこと。
```

ワークフロー

Step 0: 対応開始の通知

- 調査を始める前に、元のアラートメッセージのスレッドに対応開始メッセージを投稿する
- メッセージ例: ":hourglass_flowing_sand: アラートを確認中です…"

Step 1: アラートの確認


...

ガイドライン

...

Tips: kagent GUI

自動応答システムにおいて必須ではないが、組み込みの GUI から
Chat 形式で Agent を利用可能




多くの LLM providers をサポートしており、
ModelConfig リソースを作成するだけで利用可能！

- Anthropic
- OpenAI
- Amazon Bedrock
- Google Vertex AI
- Gemini
- Azure OpenAI
- Local LLM (e.g. Ollama)
- etc.

OpenAI 互換の 社内 AI サービス も簡単に利用可能！

```
apiVersion: kagent.dev/v1alpha2
kind: ModelConfig
metadata:
  name: cycloud-genai
spec:
  provider: OpenAI
  model: GLM-4.7-AWQ
  apiKeySecret: kagent-credentials
  apiKeySecretKey: GENAI_API_KEY
  openAI:
    baseUrl: "https://<Cycloud GenAI API の独自ドメイン>/v1"
```




kagent と MCP

AI と外部ツール間のOpen Standard な通信プロトコル

e.g.

- モニタリングデータの取得
- Slack のメッセージ閲覧や送信
- GitHub 上のソースコードやコミットログを取得
- etc.



<https://modelcontextprotocol.io/docs/getting-started/intro>

“RemoteMCPServer” リソースの作成と Agent 側での tools の指定だけで MCP server が利用可能！

```
apiVersion: kagent.dev/v1alpha2
kind: RemoteMCPServer
metadata:
  name: datadog-mcp
spec:
  description: "Datadog official remote MCP
server"
  protocol: STREAMABLE_HTTP
  url: "https://mcp.datadoghq.com/..."
  headersFrom:
    - name: ...
  timeout: 30s
```

```
spec:
  declarative:
    tools:
      - type: McpServer
        mcpServer:
          kind: RemoteMCPServer
          name: datadog-mcp
          toolNames:
            - search_datadog_logs
            - analyze_datadog_logs
            - search_datadog_monitors
            - search_datadog_events
```

柔軟なクエリで Datadog 上の様々なモニタリングデータを閲覧・分析可能！



アラート詳細取得



特定サービスのエラーログ取得



ホスト情報を取得



Datadog MCP 呼び出しの様子

 search_datadog_logs chatcmpl-tool-9933492df5d40c65

 Completed

<> Arguments ^

```
{
  "from": "2026-03-30T15:39:23Z",
  "query": "service:(neutron-server OR kagent-controller) env:stg",
  "telemetry": {
    "intent": "アラート調査のためにneutron-serverとkagent-controllerのstg環境でのログを検索"
  },
  "to": "2026-03-30T16:09:23Z"
}
```

≡ Results ▾

 search_datadog_events chatcmpl-tool-8b0b62a126757ccb

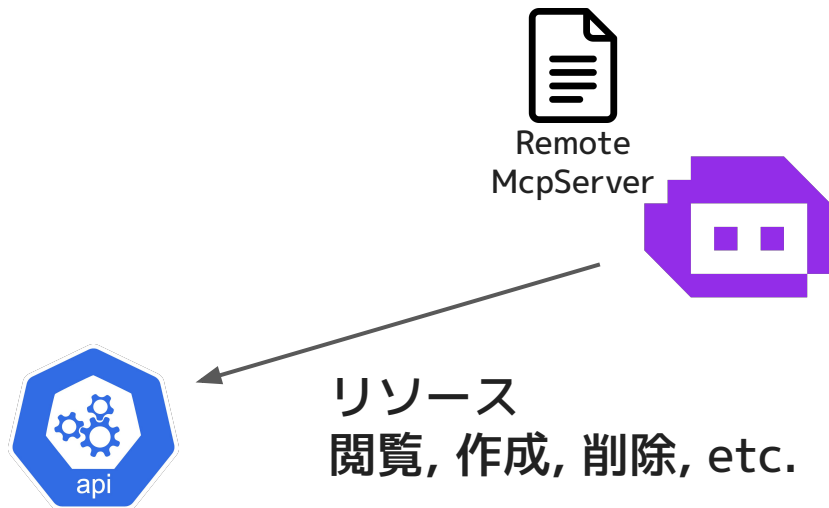
 Completed

<> Arguments ^

```
{
  "from": "2026-03-30T15:45:00Z",
  "query": "env:stg (kube_name:neutron-server OR kube_name:kagent)",
  "telemetry": {
    "intent": "最新のKubernetesイベントを確認"
  },
  "to": "now"
}
```

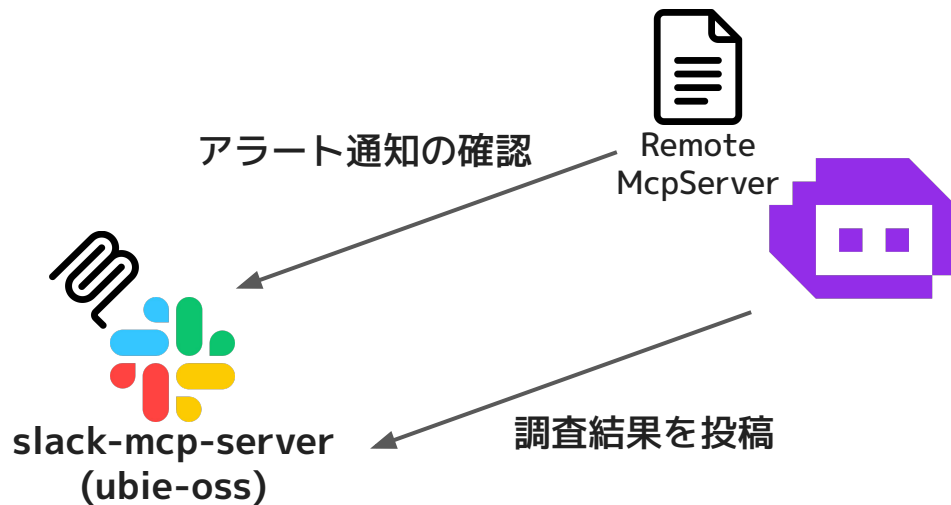
≡ Results ▾

組み込みの Kubernetes tools が用意されており、
標準セットアップで Agent から Cluster を操作可能



```
spec:
  declarative:
    tools:
      - mcpServer:
          apiGroup: kagent.dev
          kind: RemoteMCPServer
          name: kagent-tool-server
          toolNames:
            - k8s_check_service_connectivity
            - k8s_patch_resource
            - k8s_remove_annotation
            - k8s_annotate_resource
            ...
          type: McpServer
```

Agent から Slack のメッセージを閲覧・投稿



```
spec:
  declarative:
    tools:
      - type: McpServer
        mcpServer:
          kind: RemoteMCPServer
          name: slack-mcp
          toolNames:
            - slack_get_channel_history
            - slack_get_thread_replies
            - slack_reply_to_thread
```

slack-mcp-server を用いた調査結果の報告



Alertmanager アプリ 3月31日 00:55

[FIRING:4]

Pod kagent-controller-7ccddb48c8-7hw5h container controller in kagent memory usage is 92.07% of limit

Pod neutron-server-0 in stg-openstack02 was OOMKilled

Pod neutron-server-1 in stg-openstack01 restarted 10 times in 1h

Pod neutron-server-0 in stg-openstack02 restarted 11 times in 1h

2 件の返信



Compute Alert Responder アプリ 3月31日 00:55

アラートを確認します...

🔍 アラート分析

サービス: kagent-controller, neutron-server

環境: stg

調査期間: 2026-03-30T14:54:23Z - 2026-03-30T15:54:23Z

概要:

neutron-serverが継続的にメモリ不足で再起動しており、クラスタ全体の空きメモリが枯渇している。kagent-controllerはメモリリミットの92.07%使用だが安定稼働中。

原因分析: (確度: 高)

neutron-serverのコンテナがメモリ制限を超過してOOMKilledされ、KubernetesスケジューラはInsufficient memoryエラーでPodの再配置に失敗している。clusterのノードごとに複数のworkerがメモリ不足になっているため、クラスター全体の空きメモリが枯渇。

根拠:

- `Task ran out of memory` イベントが過去1時間に20件以上発生 (neutron-server-0, neutron-server-1)
- ノード stg-k8snode003 で `FailedScheduling` のエラーが継続: `0/4 nodes are available: 1 node(s) had untolerated taint {node-role.kubernetes.io/control-plane: }, 3 Insufficient memory`
- 最も新しいOOMイベント: `2026-03-30T15:54:23Z` - neutron-server-0 in stg-openstack02

推奨アクション:

1. クラスタのノードのメモリ使用状況を確認する (kubectl top node)
2. neutron-serverのmemory limitを引き上げる、またはメモリリークの原因調査
3. kagent-controllerのメモリリミットを引き上げる (現状92%使用)

課題と今後の展望

- 原因の推定とネクストアクションの提示にしか至っておらず、実際の解決のためのアクションは人間が行う必要がある
 - 適切なシステムプロンプトと tools を渡せば Agent によるアクション実行は可能だが、内容によっては人間の承認を挟みたい
 - 適切な HITL (Human In The Loop) のフローを導入することで **Agent の信頼性を確保**することが求められる

- Kubernetes Cluster 情報 と Datadog の log は取れているが、Agent の精度を上げるために他にも様々なデータソースを取り入れ、活用したい
 - Metrics (grafana-mcp)
 - GitHub 上のソースコードやコミットログ
 - etc.



- 各チームでそれぞれ AI Agent Platform を構築している状態なので、それらを連携することで更なる効果が期待できる
 - VM の上で動いているマネージドサービスの障害時に、マネージドサービス側の Agent から IaaS 基盤側の Agent を経由して状態を取得するなど

まとめ

- kagent により Agent や MCP 等あらゆるリソースを Kubernetes リソースとして定義し、宣言的な設定で手軽に AI Agent Platform を構築する手法
- kagent による AIOps の一例として、アラート自動応答システムの設計パターン

kagent ぜひ使ってみてください！

We are hiring!



一緒に働く仲間を大募集しています！

- プライベートクラウドの開発・運用に興味がある方
- AI Agent Platform の構築や AIOps による業務効率化に取り組んでみたい方

お気軽にお声がけください 🖐️

<https://it.cyberagent.group/team/ciu/>

<https://www.cyberagent.co.jp/way/list/detail/id=31427>

<https://www.cyberagent.co.jp/way/list/detail/id=31367>

<https://www.cyberagent.co.jp/way/list/detail/id=29497>