

分野を超えた視点で異分野エンジニアが NWの異常検知に挑戦

～高精度ネットワーク監視への工夫と課題～

ソフトバンク株式会社

内海、合志、平野

2024/07/03





内海 友輔

出身

- 岩手県一関市

趣味

- フルマラソン（サブ3.5くらい）

担当業務

- Telemetry収集, 検証
- データ分析用の基盤構築/運用
（オンプレ/パブリッククラウド）

経歴

- 2018~2022:
 - プライベートクラウド構築/運用
 - IaC、CI/CD環境構築/運用
- 2022/4~: 現業務



合志 和真

出身

- 熊本県合志市

趣味

- コーディング、読書

担当業務

- Telemetryコレクタの開発
- トラフィックの傾向異常検知導入

経歴

- 2020~2023:
 - 基地局監視システムの保守・運用
- 2023/4~:
 - 現業務



平野 泰平

出身

- 宮城県仙台市

趣味

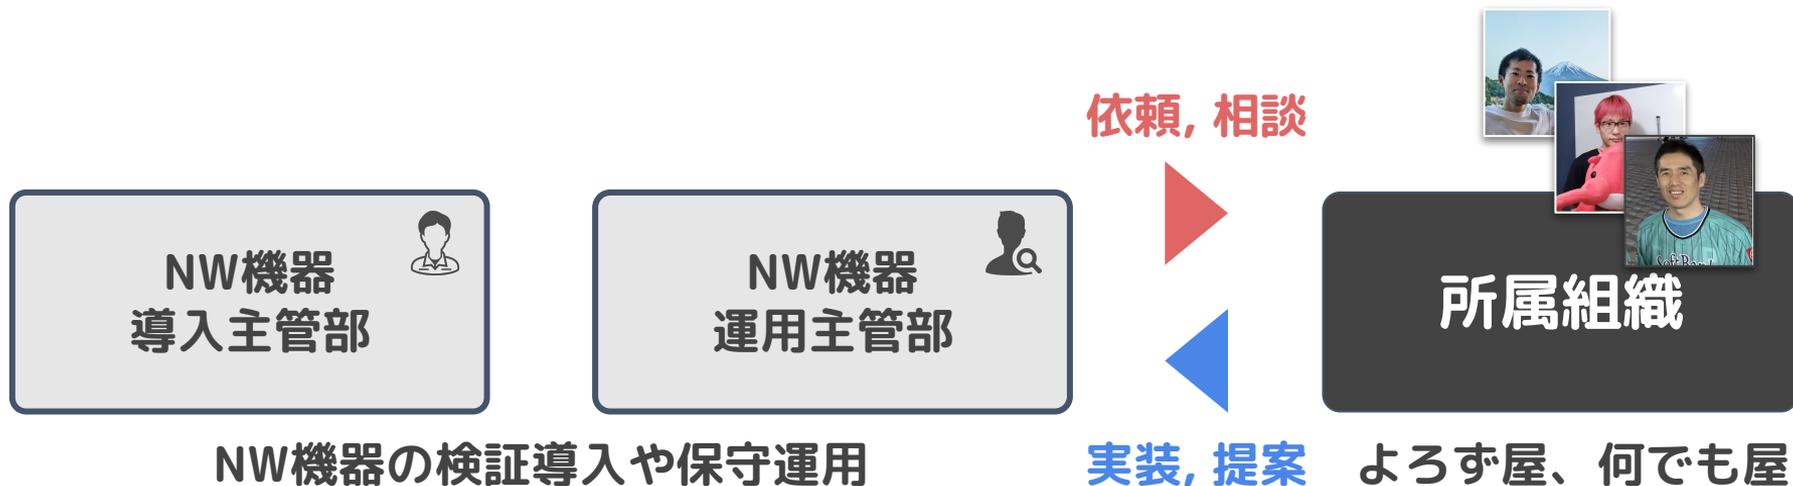
- テニス、スキー（テクニカル 目標）

担当業務

- 異常検知機能開発
- 作業自動化支援機能開発

経歴

- 2001~2020:
 - Slerにてサーバインフラ開発
- 2020/11~:
 - 現職



- NW機器の異常検知、元となるデータ収集、トリガーとなる検知の立て付け、..
 - 様々なデータソースで何が出来るか、NW機器の担当と話したり
- 我々、実はNW経験あまり無い人たちです。お手柔らかに。。

1. 取組みの背景

2. NW障害の早期検知

- a. リアルタイム検知 (内海)
- b. 独自コレクタ開発 (合志)
- c. 傾向異常検知 (平野)

3. まとめと議論のポイント

取組みの背景

生成AIが作成してくれた通信インフラの重要性を表すイメージ図

通信インフラの重要性を表すイメージを数枚作成し説明文をつけてください



◆緊急サービス

緊急事態にスマートフォン、インターネット通信ツールを使用して危機へ連携して対応している様子



◆日常生活への影響

自宅で働く人、SNSを利用する人、オンラインショッピングをする人、緊急電話をかける人のシーン



◆経済活動への影響

リモートで行われるビジネス会議、クラウドコンピューティング、オンラインでの国際取引のシーン

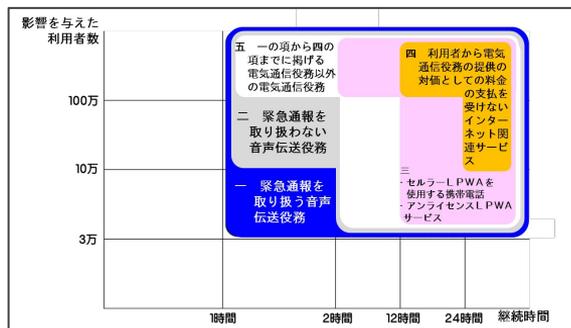
- NWサービスの重要性がますます顕著に。

NW障害発生から初報まで、**30分以内**というガイドラインも制定される。

- 障害復旧はもちろん、HP掲載までの短時間化にも努めている。

良いことではある

→ 障害の**知得・復旧に期待される時間が日に日に短く**なっている。



(2) 障害発生から初報までの時間の目安

対象事故等が発生した、又は発生すると認識した場合、指定公共機関は、やむを得ない場合を除き¹²、事故等が発生した時点から、**原則30分以内に初報の公表を行う¹³**。

それ以外の事業者についても、これに準じて、できる限り早急な初報の公表を行う¹⁴。

また、早急な情報発信を可能とするため、あらかじめ情報発信用フォーマットを策定しておく。

(総務省)

電気通信サービスにおける

障害発生時の周知・広報に関するガイドライン (令和5年3月)

(総務省)

電気通信政策の推進 > 安全・信頼性の向上 > 重大な事故の報告

[1]: https://www.soumu.go.jp/menu_seisaku/ictseisaku/net_anzen/jiko/judai.html

[2]: https://www.soumu.go.jp/main_content/000869357.pdf

総務省の電気通信事故に関する文言の変化



2023年2月

障害事象の検出、被疑箇所の特定制及び復旧措置のそれぞれの迅速化・自動化を推進することで事故の長期化を防止する対策を徹底すること。^[1]

2022年12月

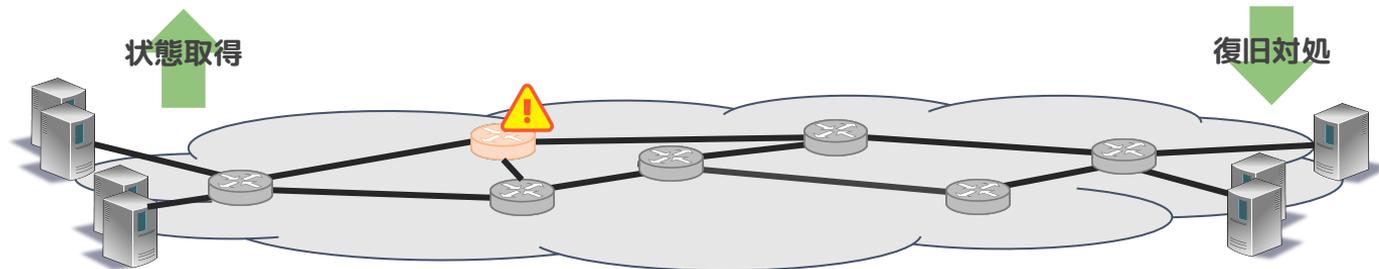
復旧手順の明確化・自動化を行い、事故の長期化の防止のための対策を徹底すること。^[2]

自動化に対する否定的な考えはほぼ消滅

- むしろ、「何故やらないのか」という風潮にまでなっている。

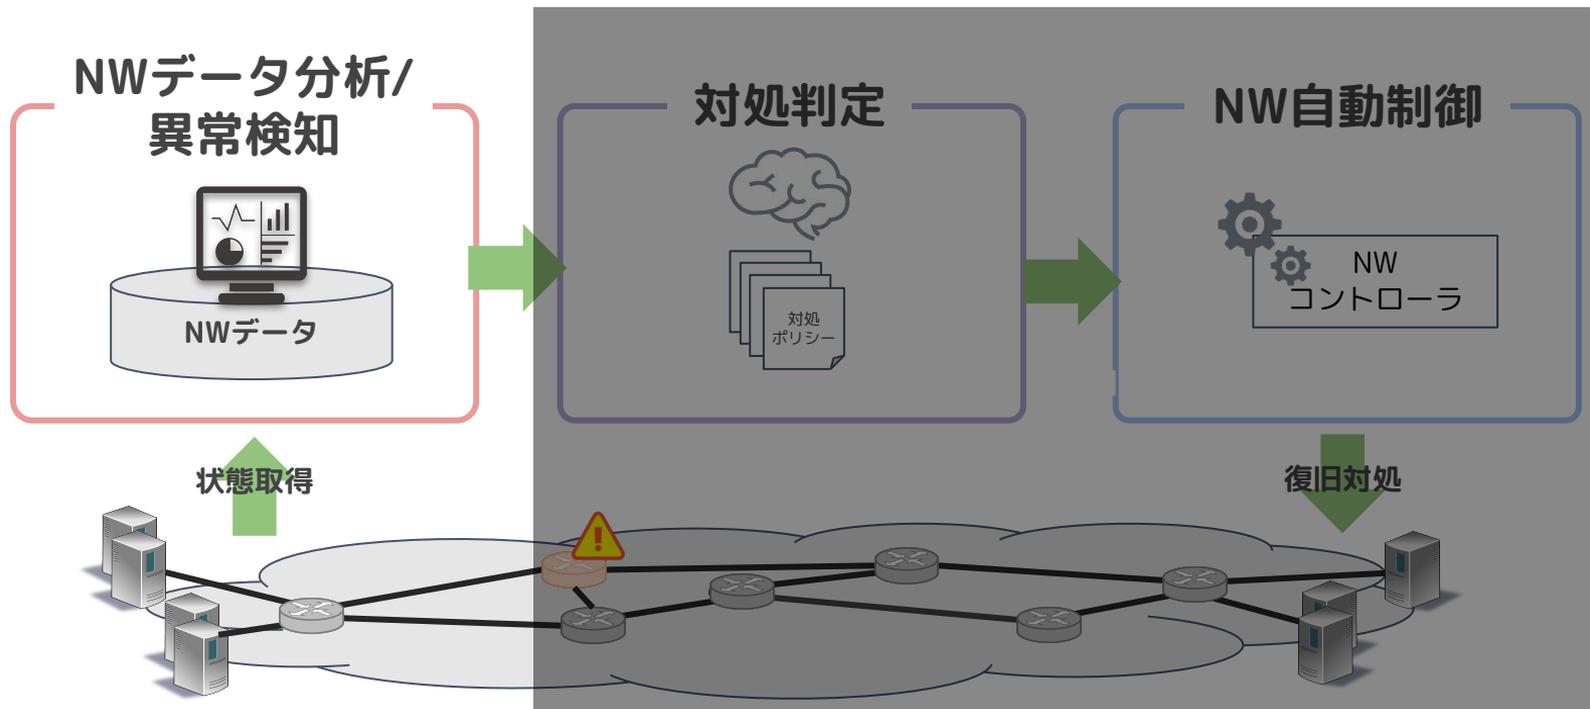
と、思っています

NW障害検知～自動復旧のクローズドループの実現が必要



クローズドループイメージ図

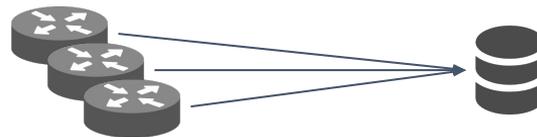
今回発表のスコープ



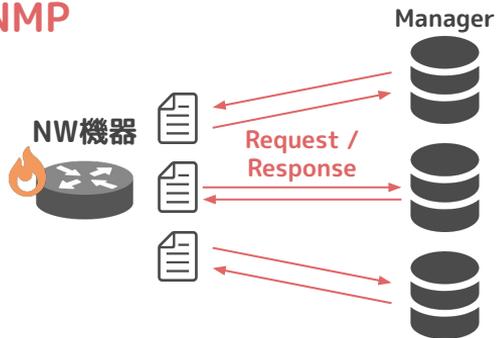
リアルタイム検知

“1分・1秒でも早く”
検知の早期化を考える必要性

高頻度 & 効率的なデータ取得

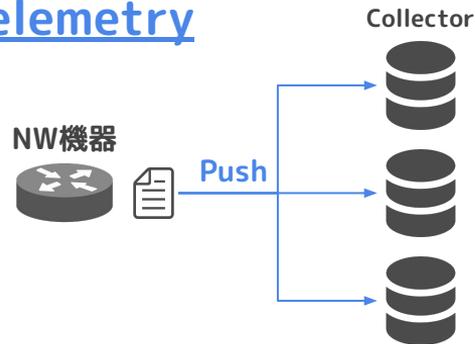


SNMP

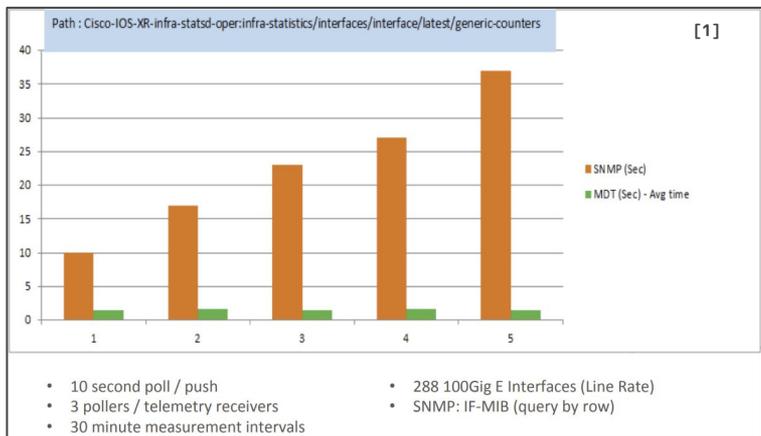


現実的にはおよそ5分間隔

Telemetry



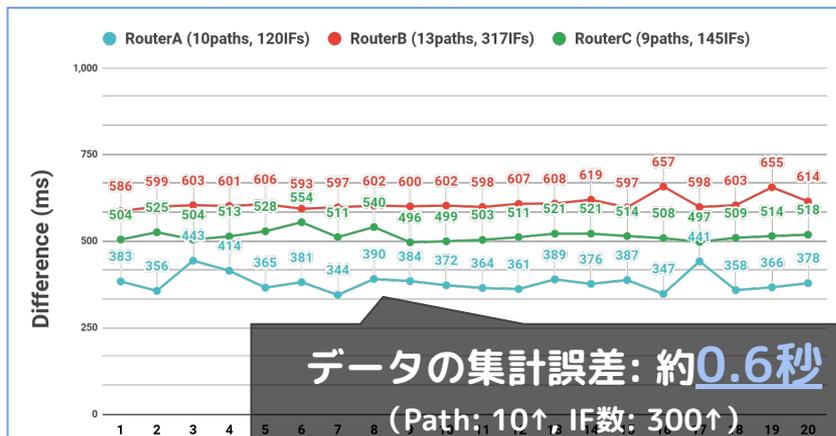
より短期間での収集 (<< 5分)



特徴（期待されること）

- Pub-Sub形式: 効率的なデータ取得
- データ取得の高頻度化
- 多種多様な取得可能データ
他にも・・・

複数データ取得時の集計時間差



多数のデータを取得していても、
集計にほぼ時間差がない

サイレント障害の検知に有用

なんで導入されないのか？

SNMPでも
良いんじゃないか？

現状より良くなる
イメージが無い

データ量増加に伴う
新たな課題
(インフラ面など)

マルチベンダ環境では
センサパスが共通ではない

Telemetry Working Group 最終報告 (JANOG 43)

ミーティングの総括④

- システム複雑化への懸念
 - 取得した**膨大なデータへのケア** (Storage, DB管理が追加)
 - 圧縮やサマライズ機能等、Tool検討時に要考慮
 - ベンダー毎のCollector** (現状)
 - OpenConfigによるデータモデル共通化と同じく、Transportの統一も期待したい - gNMIに期待

Network視点だけでは無く**インフラ全体**で見る必要がある、
このような視点から、運用の**Game Changing**も期待

- サンプリング間隔毎のバーストラフィック検出
- NWの視点だけではなく、インフラ全体の考慮が必要

gNMIcを活用したマルチベンダー環境でのテレメトリ技術の実践 (JANOG 52)

Q: リアルタイム性は本当に欲しい？

- 我々としては欲しい。
- 対処や人間の判断を含め、フロー全体で考えると検知にはあまり猶予が無いと思っている。

In-band Telemetry -データプレーン遅延時間観測 (JANOG49)

テレメトリで出来ている事

- インターフェースカウンターの可視化
- エラーパケットなどの可視化
- Queueの輻輳や廃棄状態の可視化
- プローブによるパケット到達性遅延の可視化
- ネットワーク機器を通るフローの可視化
- テレメトリデータを使った予兆検知/外部連携

Telemetryのユースケース例

- IFカウンタの可視化
- エラーパケット等の可視化

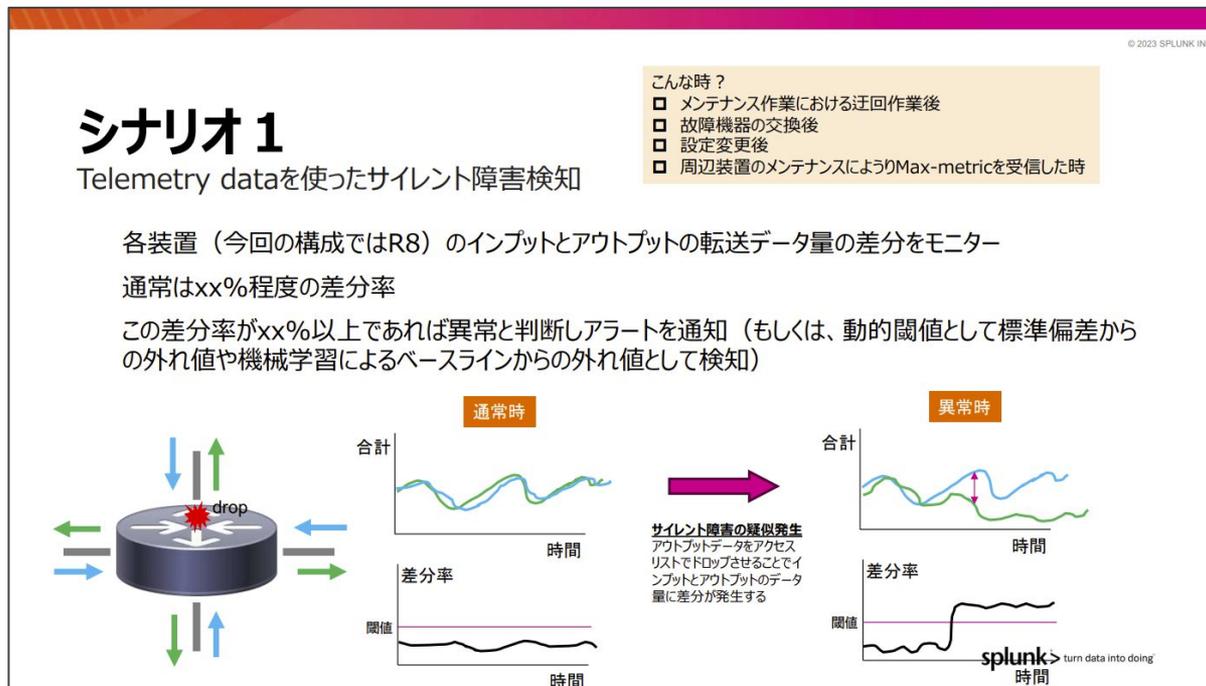
Telemetryを商用監視に適用して、**実際に直面した課題**についてお話ししたい

[6]: <https://www.janog.gr.jp/meeting/janog43/program/telew/>

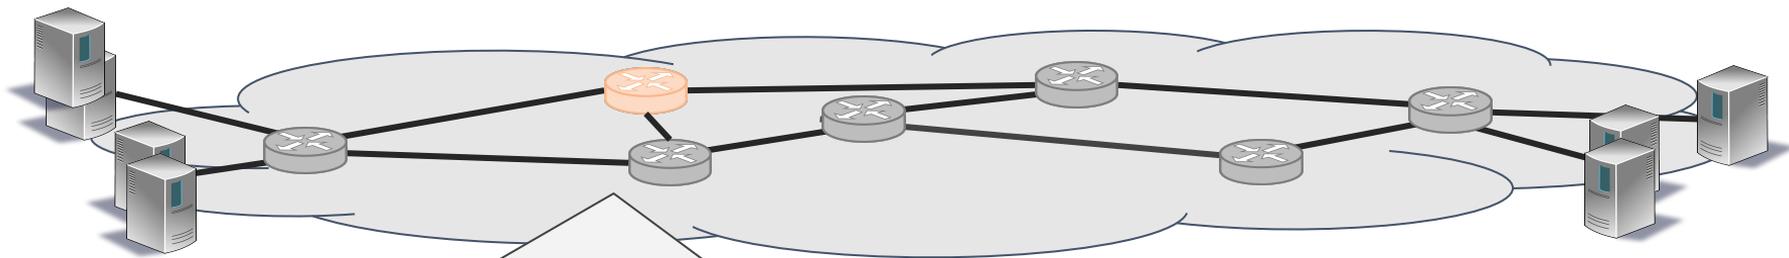
[7]: <https://www.janog.gr.jp/meeting/janog49/intele/>

[8]: <https://www.janog.gr.jp/meeting/janog52/gnmi/>

- 前回のJANOGでもサイレント障害の知得に関する議論がなされていた。
- 今回は現場レベルでの取組みについて、この場で共有したい。



例) 中継区間のNW機器におけるルーティングテーブルの欠落



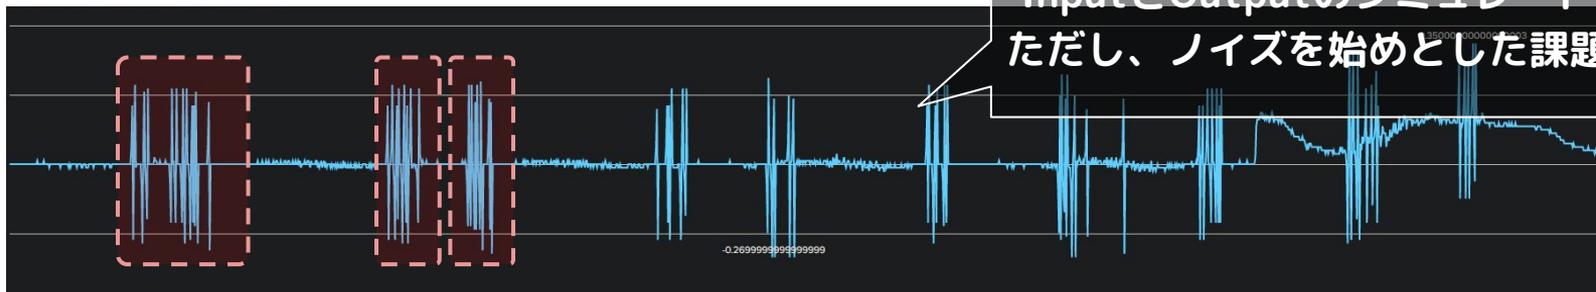
この障害想定パターンに限っては、
ルーティングテーブルの経路数を監視する等..

じゃあxxlは？

yyは考えた？

パターン網羅は非現実的
かつ 後追いで監視実装

▶ そこで、SNMPでのサイレント障害の知得を試みたものの。

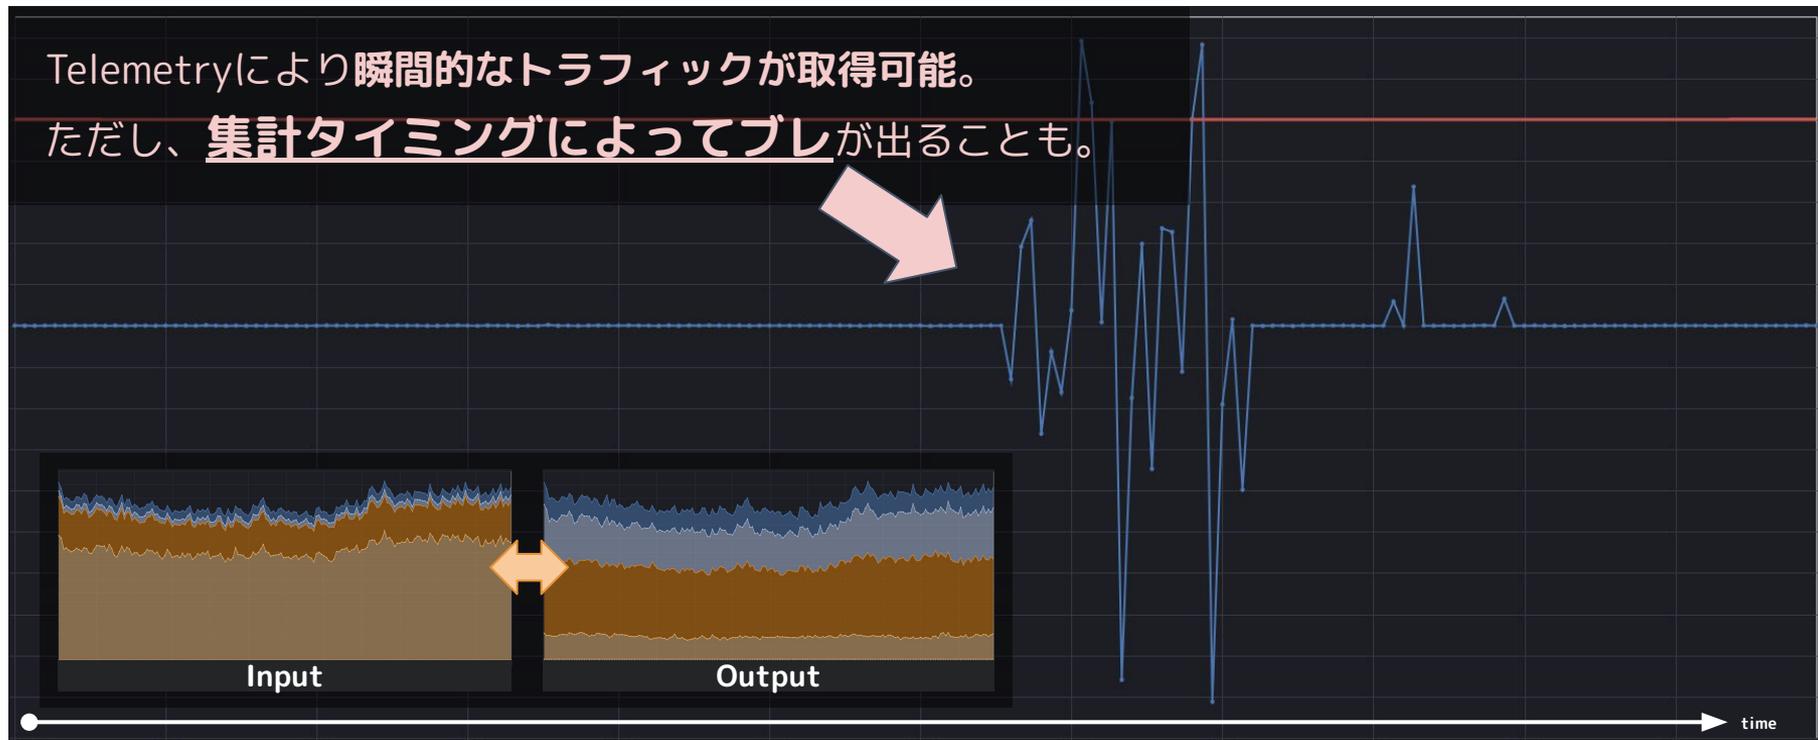


◦ InputとOutputのシミュレート実施。
ただし、ノイズを始めとした課題に直面

ただし、Telemetryをそのまま導入するだけでは駄目だった。

Telemetryにより瞬間的なトラフィックが取得可能。

ただし、集計タイミングによってブレが出ることも。



異常と判断する基準、閾値の定め方

過去実績から
定める
(静的)

機械学習で
定める
(動的)

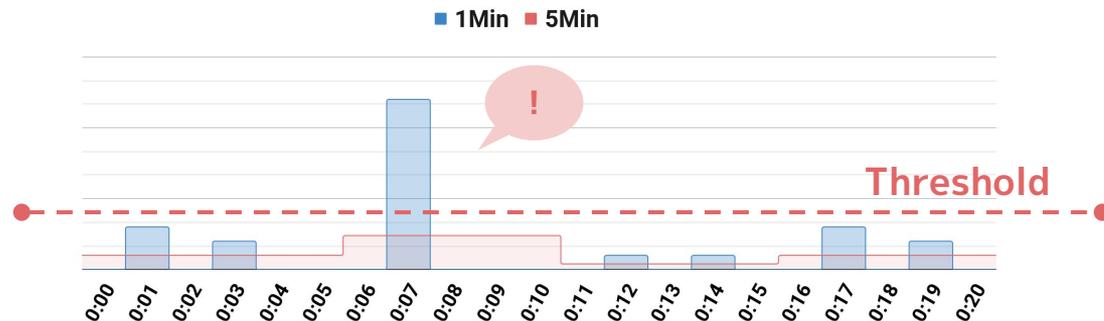
...



※ NWが常に安定しているわけではない。
実際は作業等でNW傾向が随時変動する。



- 長いスパンでの収集ではErrorの値が平滑化され、検知が遅くなってしまう



- Errorを細かい粒度で取得できる（解像度が上がった）ため、対処が短時間化

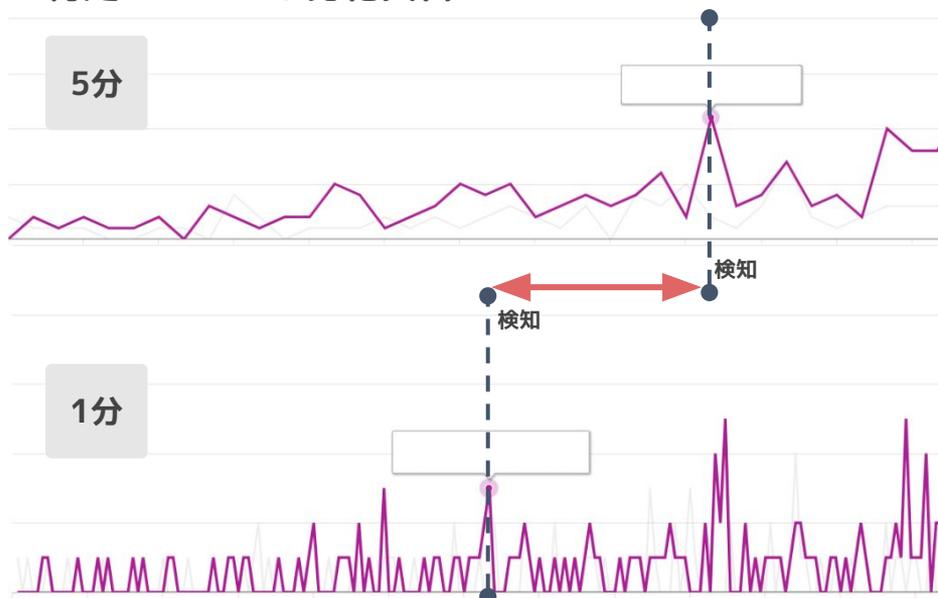
※ 技術的、NW機器のリソース負荷、両面でメリット



同等ロジックにおける、集計期間での検知時間の差を比較

- 5分集計データ
- 1分集計データ

特定IFにおける劣化具合



- 5分集計パターンだと検知が遅い？
- 1分集計パターン程の早期検知は不要？

この判断基準の制定は難しい。
予兆の検知？ or 障害の検知？

データ量の肥大化



- サーバリソース
+ ストレージ料金
+ データ転送の帯域..
- 不要なデータは
前段で削除したい。
とはいえ、後から
必要になることも。。

データの保持場所



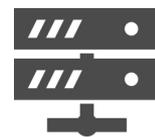
- オンプレミス
→ 保守運用コスト
- クラウド (IaaS), SaaS
→ データ転送量に
対する従量制課金
→ ストレージ料金

データ取込み処理



- 事前のETL処理が必要
- **同じイベント内**での計算
例: %の算出
- **異なるイベント間**の計算
例: カウンタ値から
差分算出 → pps

インフラ負荷考慮



- 検知のため
全IFを集計している。
- なおかつ、高頻度で
サーチすることによる
インフラの高負荷

独自コレクション開発

早期検知・復旧が組織の必達目標

- 何としても障害を**早期**（1秒,1分でも早く）に検知したい
 - 現状のSNMPで取れるログ+**障害の前兆**を把握するためのトラフィック等の情報が必要
- **傾向異常検知**では複数点の異常トラフィックのデータが必要
 - SNMP（5分毎）だと異常データ3つ取るだけで15分かかってしまう
 - Telemetry（1分以下）だと長くても3分で取得可能

今後、早期検知・復旧の温度感は上がっていく

- 社内の全てのルータ（n万台）から上記の情報を取得したい
 - 多種多様な多数のルータの一元管理

Pipeline

Telegraf

gNMIc

最初はOSSのコレクタを使用
微妙に帯に短かしたすきに長しかった

※今は違うかもしれないし、我々の使い方が悪かったかもしれない

→多少コストがかかっても
自由に運用できるコレクタを開発した方が今後活きるのでは？



Telemetryコレクタ独自開発へ

Aベンダー

Aベンダー
+
Bベンダー

Aベンダー
+
Bベンダー
+
Cベンダー

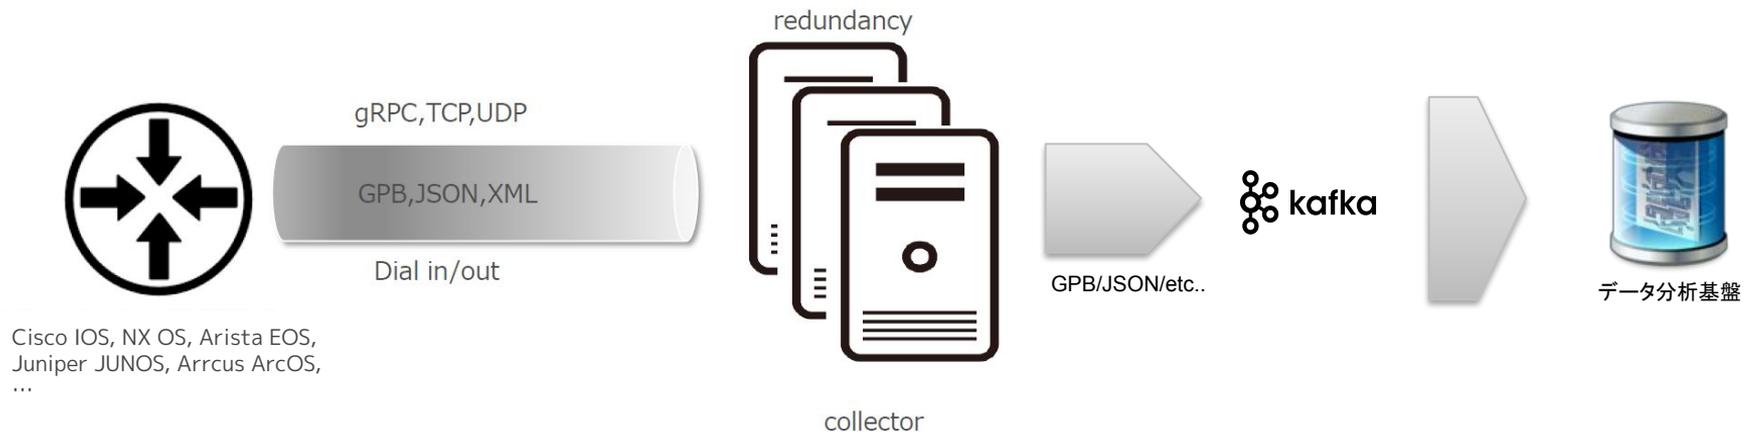
6社対応

OpenConfig/Vendor Native
Dial-in/Dial-out
TCP/UDP/gRPC/gNMI
Json/XML/GPB KV
圧縮/非圧縮
フル冗長

一つ一つ対応していき独自のコレクタを作成

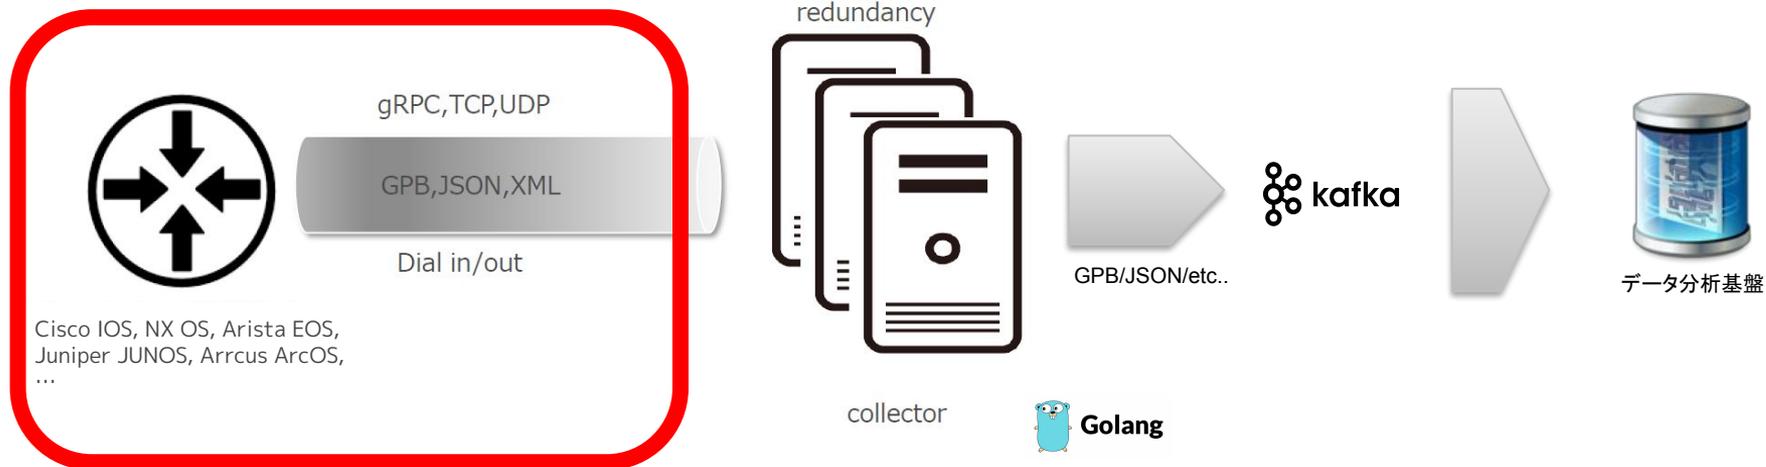
コンセプトは Telemetryデータ取得の一元化

- **多様なルータ** から、**多様なデータ** を、**リアルタイム** で取得したい
 - **社内導入済の各ベンダ** から、**Telemetryデータ** を、**高頻度** でデータ取得
- 取得したデータは遅滞なく確実に後段へ転送



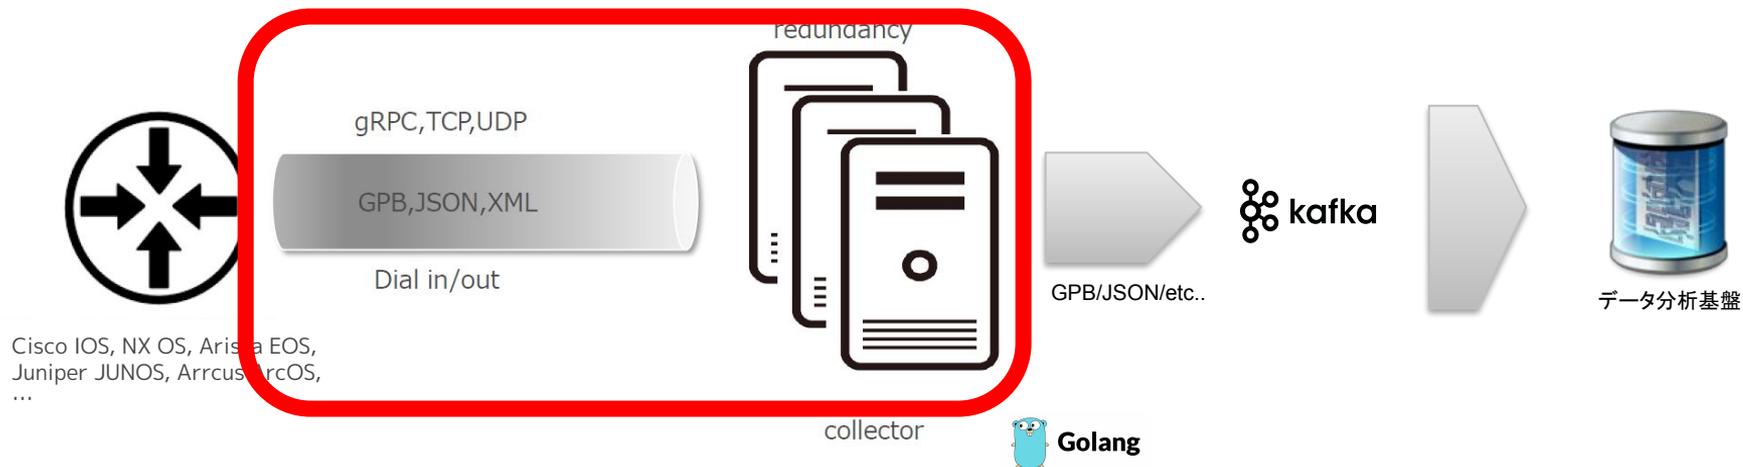
複数ルータ対応

- Cisco gRPC, Juniper gRPC(認証方式が違う), gNMI, ...
- 取得方式(Dial-In / Dial-Out), データ構造(GPB / JSON, ...)の差を吸収
 - プロファイルごとにロジックを分け、制御できる仕組み



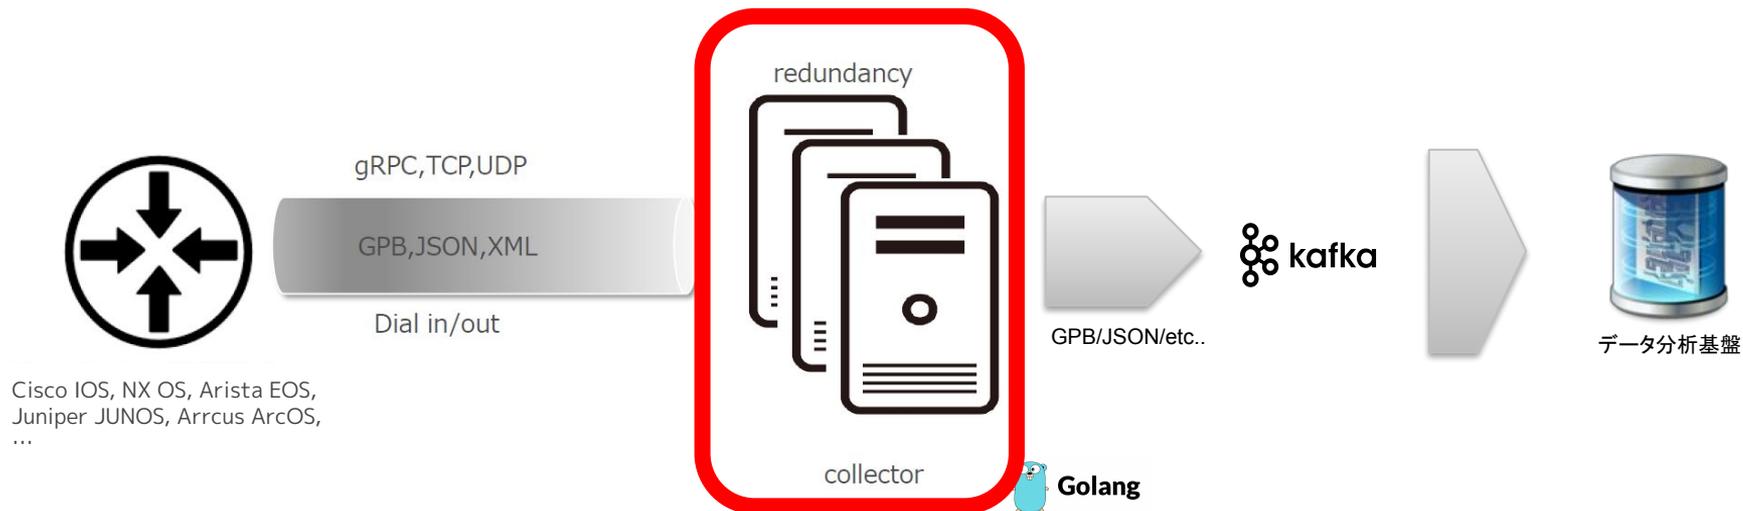
耐障害性(ルータ側 down / S.O. 後のデータ取得自動再開)

- ベンダ、ルータ毎に復旧までの時間が違うので、その辺りも柔軟にしたい
- 5桁オーダーの数のルータをコレクタ内で上手く分散処理させたい
 - コレクタ追加、障害時にも自動でロードバランシングする仕組み



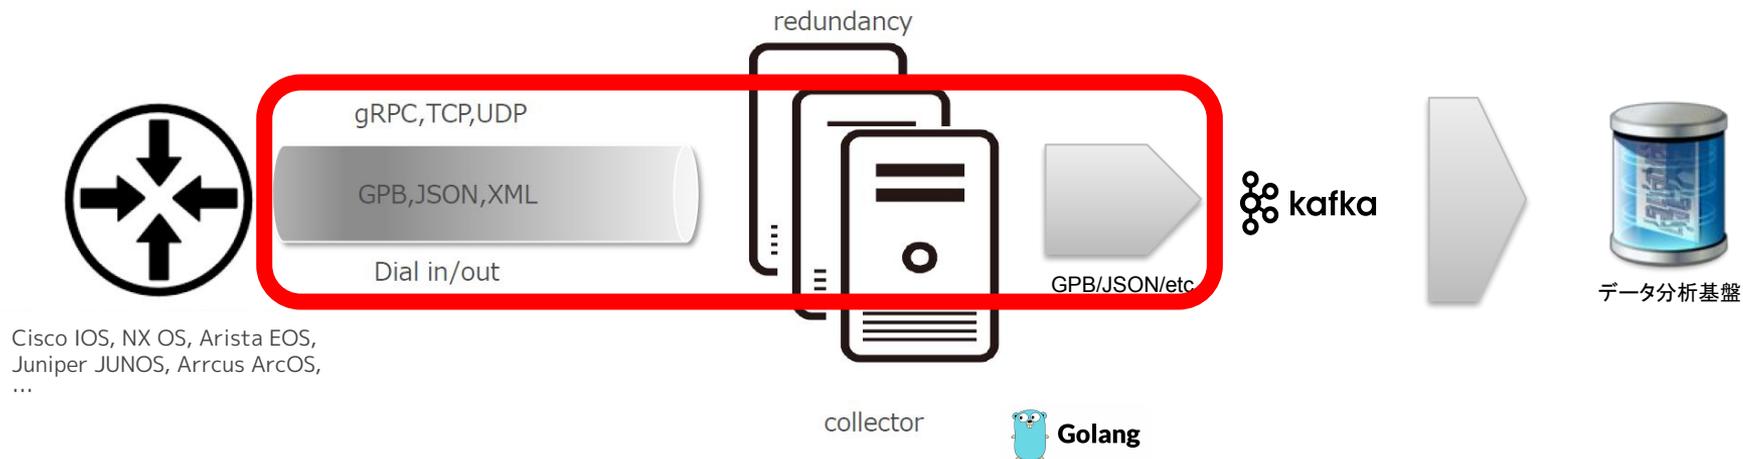
様々な用途のデータを一様に管理

- タグ付け機能などでデータを管理
- ルータごとの収集・転送設定をプロフィールで管理
 - タグをつけたデータをkafkaの特定Topicに転送、など



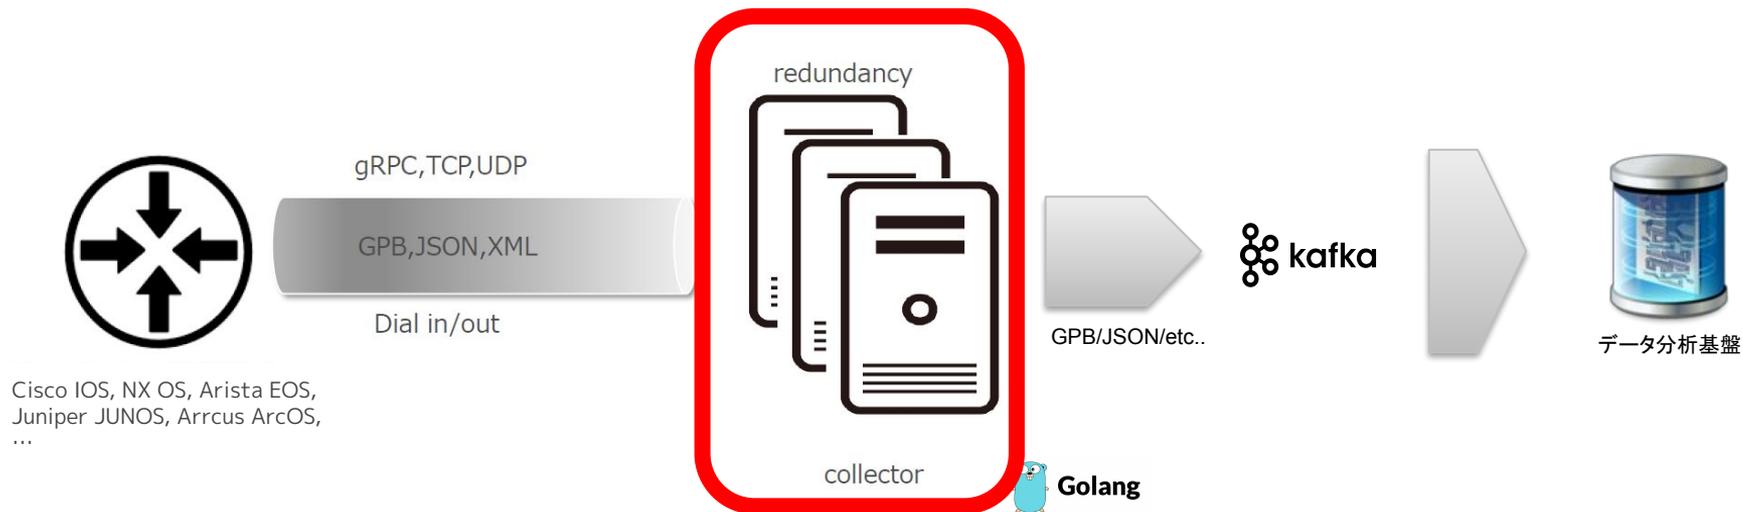
トラフィックをさばく仕組み

- Telemetry取得・転送用のNW(広帯域)を用意し大規模データ取得を可能に



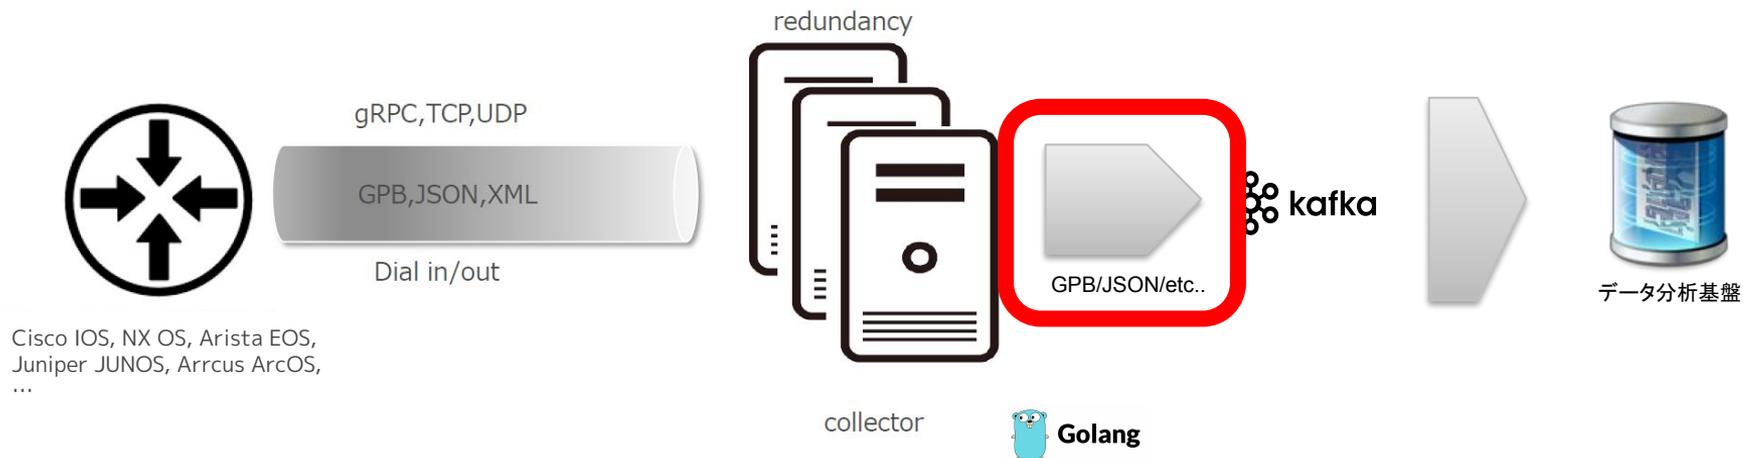
各コンポーネントの冗長可

- 取得先が商用ノードなので一定の対障害性が必要



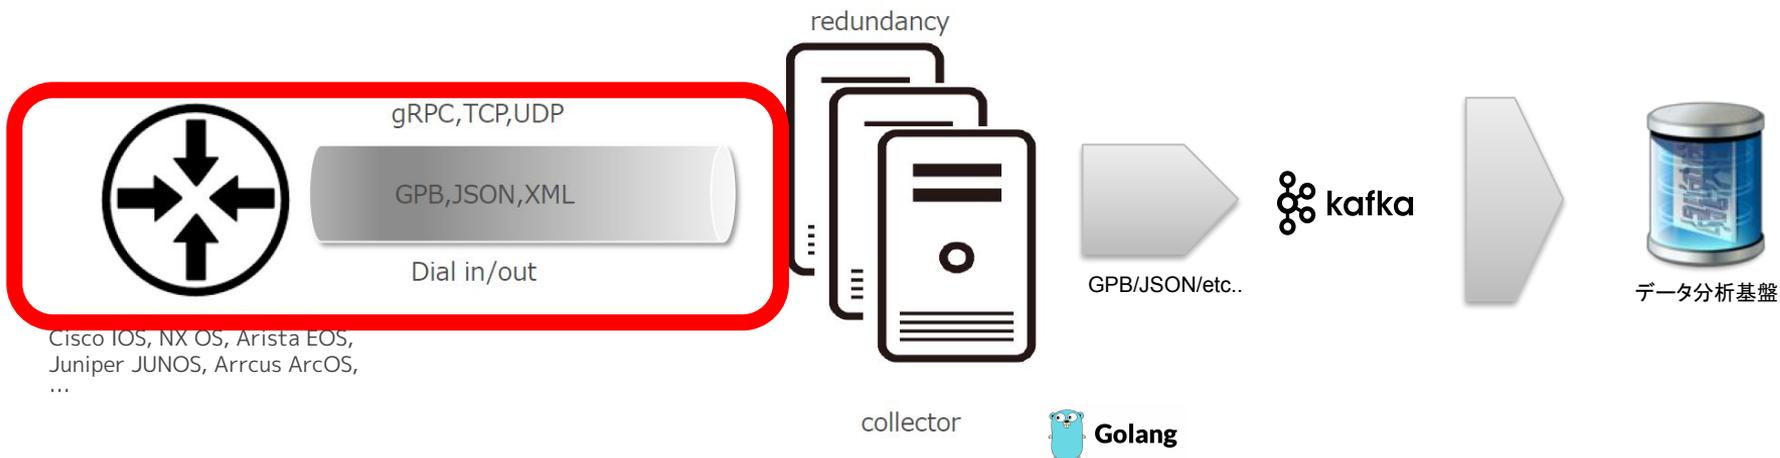
後段へのデータ転送

- データを処理し、後段の分析基盤へ漏れなく転送
- kafkaの転送管理とか再送処理とか

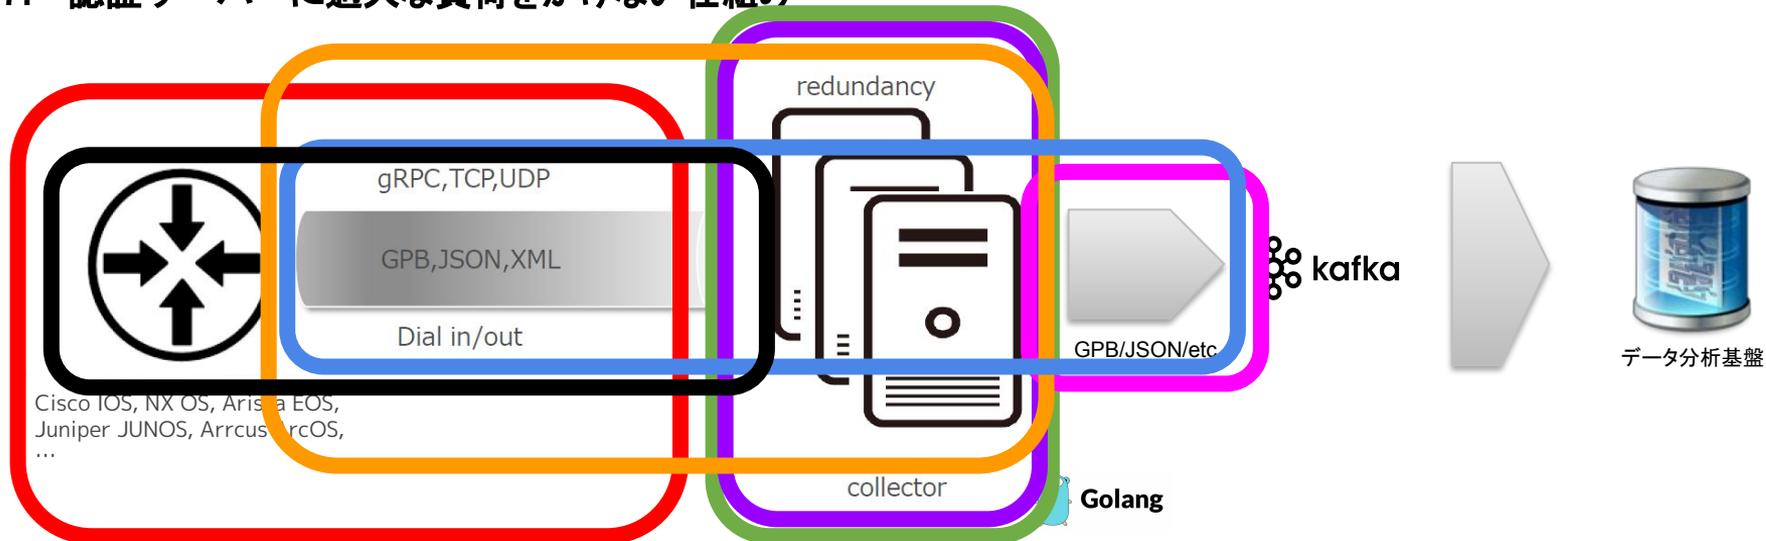


認証サーバーに過大な負荷をかけない仕組み

- 認証情報/セッションのキャッシュ化など



1. 複数ルータ対応
2. ルータ側 down / S.O. 後のデータ取得自動再開
3. 様々な用途のデータを一様に管理
4. トラフィックをさばく仕組み
5. 各コンポーネントの冗長可
6. 後段へのデータ転送
7. 認証サーバーに過大な負荷をかけない仕組み



	独自コネクタ	OSSコネクタ
導入容易性	小規模開発ではあるが スクラッチ開発が必要 	大手通信機器ベンダーから OSS公開あり 
運用保守性	開発チームによるサポートあり 	原則サポートなし 
システム連携 (後続)	後段システムの構成にあわせた 柔軟な対応が可能 	OSS内で定められた手法のみ可能 
ベンダー制約	仕様が分かれば 全ベンダ対応可能 	コネクタの仕様に依存 

生みの苦しみを越えてしまえば自由な運用が可能

傾向異常検知

短期間の視点だけではなく

ある日のトラフィック流量を示すグラフにて

トラフィック量

監視の判定に使用していない
過去データ

(使用していないので、監視機能からは見えない部分)

正常?

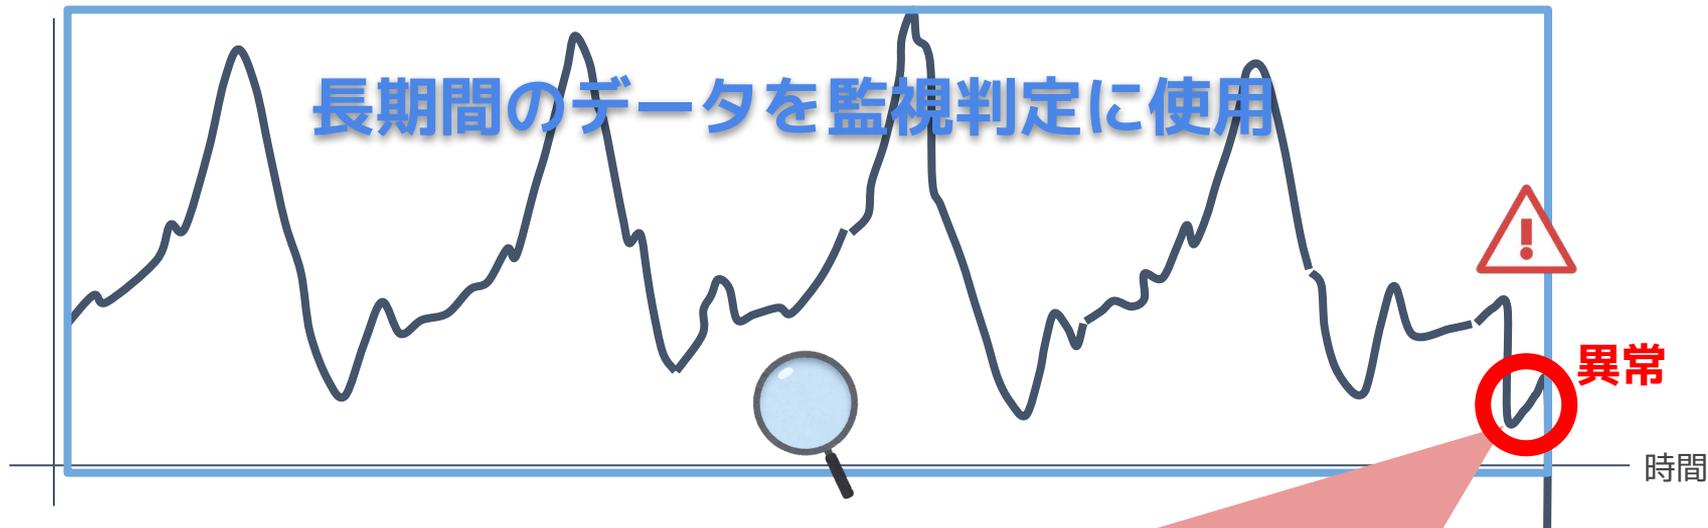
時間

短期間で見ると、トラフィックも
流れているし正常に見える

長期間の視点も必要

ある日のトラフィック流量を示すグラフにて

トラフィック量



長時間で見ると波形が通常と異なり、異常と分かる

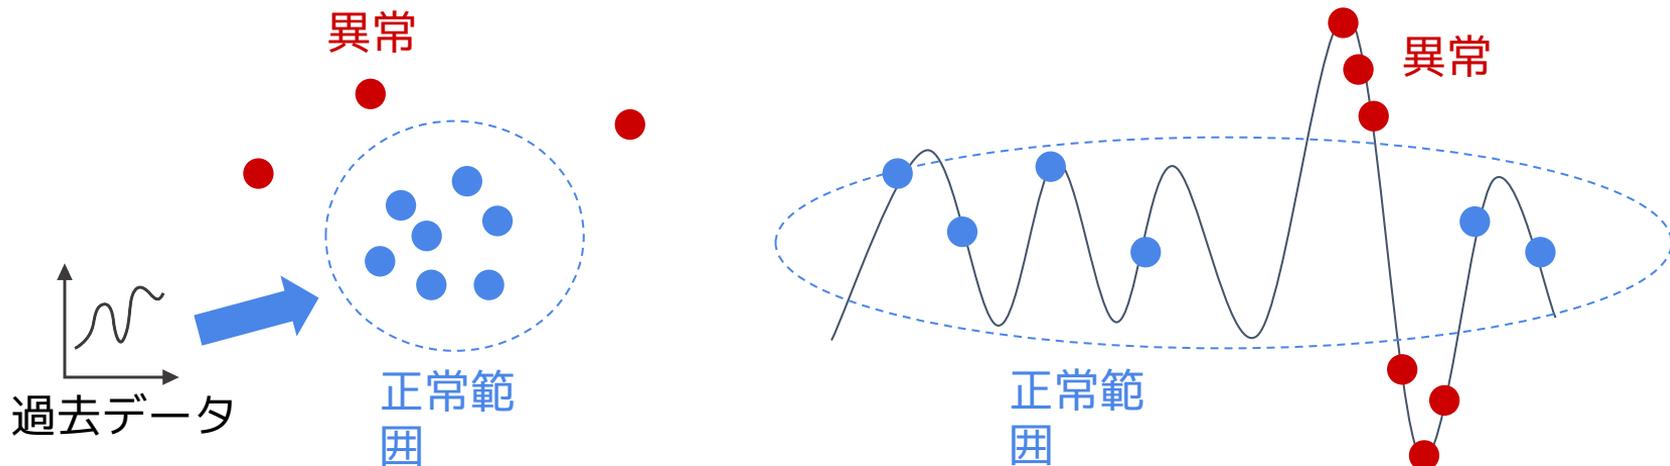
👉 傾向異常検知が必要

傾向異常検知における異常の定義

傾向異常検知における異常のパターンは多様で、未知のパターンも含む

→決まったパターンや固定の閾値での監視が困難

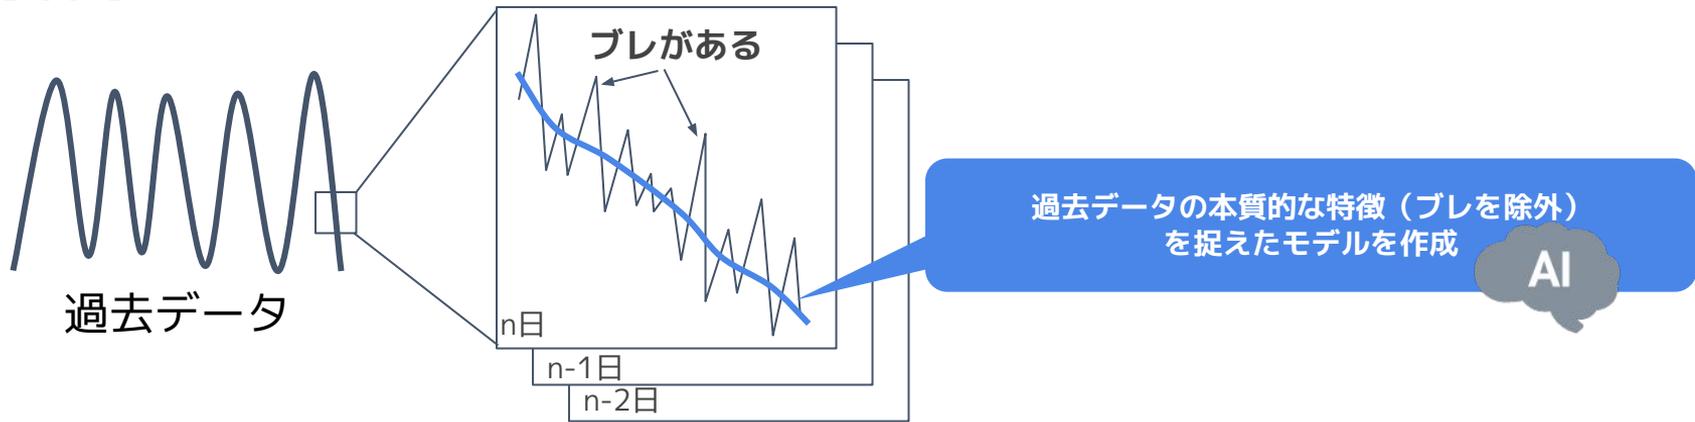
→よって、過去データの分析結果から正常な状態を設定し、そこから外れた状態を異常として判定する
(外れ値検知)



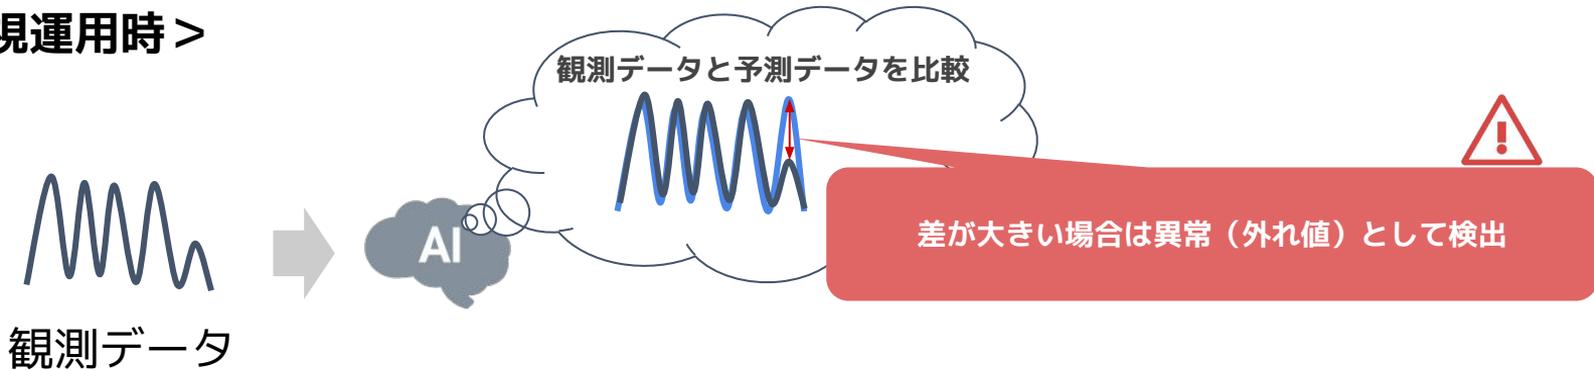
外れ値検知のイメージ

傾向異常検知の導入(周期特性)

< 学習時 >

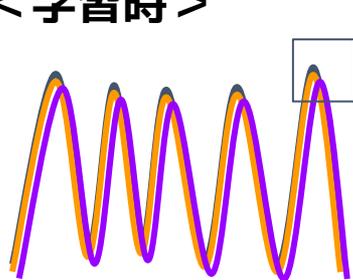


< 監視運用時 >



傾向異常検知の導入(相関特性)

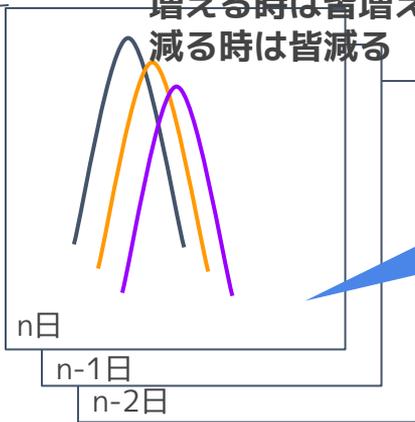
<学習時>



過去データ

増える時は皆増える
減る時は皆減る

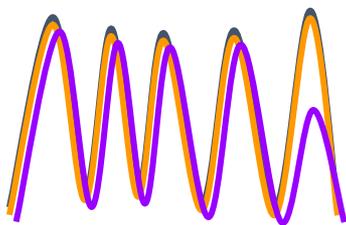
=相関特性がある



過去データの相関関係について
本質的な特徴(ブレを除外)を捉えたモデルを作成

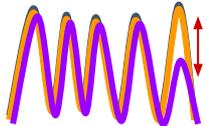
AI

<監視運用時>



観測データ

観測データと予測データを比較



相関関係が崩れている場合は
異常(外れ値)として検出



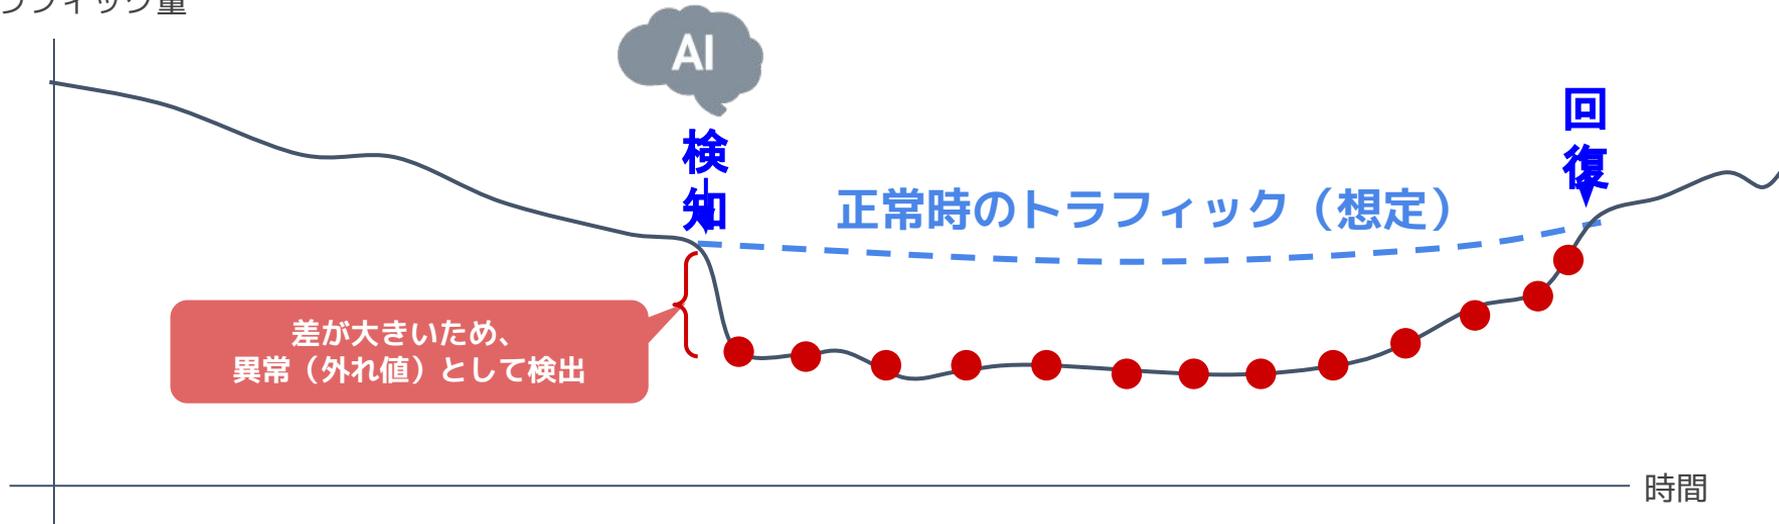
AI

傾向異常検知が活きるパターン例

NW運用の中で、稀に発生する障害

- **スループットが低減** (ex.5割減)
- しかし、完全に通信断になる訳ではない (半死状態) ので、ping監視などでは気付きづらい

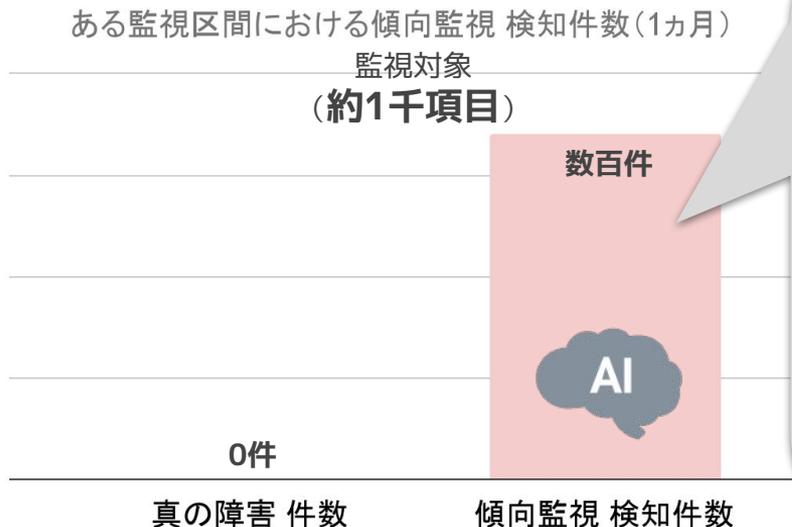
トラフィック量



しかし、この仕組みだけでは課題が

<課題>

真の障害の発生件数（数年に1件か、それ以下）と比較し、
傾向異常検知の検知件数が高い



少しでも怪しかったら
通知するポリシーだとして
も。。。

通知先がオペレータ（人間）なので
検知数が多い

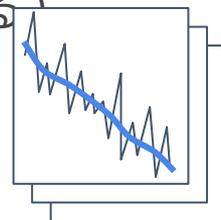
確認
しきれないよ。。



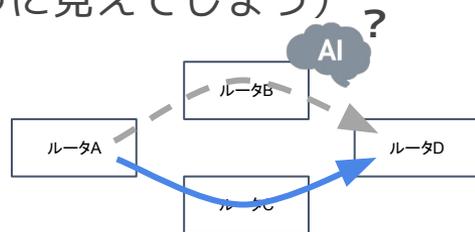
なぜ検知件数が多いのか？

- 周期特性や相関特性は、常に一定ではない（誤差が多分に含まれる）

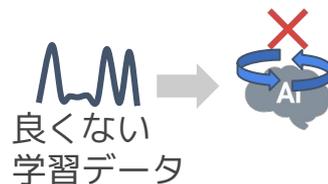
本質的特徴を学習するも
完璧ではない



- NW運用により、通信経路の変更が散発的に発生
（NWサービスは正常だが、事前学習した正常範囲から外れたように見えてしまう）



- トレンド変化への追従のために定期的な再学習を行うが、良い学習データが得られるとは限らない（※上記の通信経路変更などの影響etc）



他にも色々、要因がある。。

監視対象の全体母数が多い（数千項目以上）ため、低確率でも誤検知が月に**10～数十件発生**してしまう場合がある

監視メトリックのサマリ化
（ex.複数監視項目の合算値）

→周期性は安定するが、特定区間の異常が薄まってしまい鈍感になってしまう

異なる種別のメトリックを複合的に判断

→関連性がある項目を組合せないと意味がなく、未知の異常ではどの組合せに意味があるのか不明

LLMを使って、誤検知と思われるものを分類したいが、現在試行中

<議論したい点>

傾向異常検知を導入している組織は他にもあると思う。
機能や運用での工夫点など、是非議論したい



<リアルタイム検知>

センサパスに関する課題

- 一部のOSではセンサパスを機器側に設定
- 適切なセンサパスの探し方

データ量の肥大化

- 本来は多数のパスからデータ蓄積をしたい。
→ 障害時にクリティカルなパスを確認

NW機器自体のVerUP追従

- バージョンによる取得パスの違い

データ取得間隔に関する課題

- 数秒のスパンで見えるもの/実例があるか。

<傾向異常検知>

傾向異常検知を導入している組織は他にもあると思う。
機能や運用での工夫点など、是非議論したい

Appendix

End of Slide