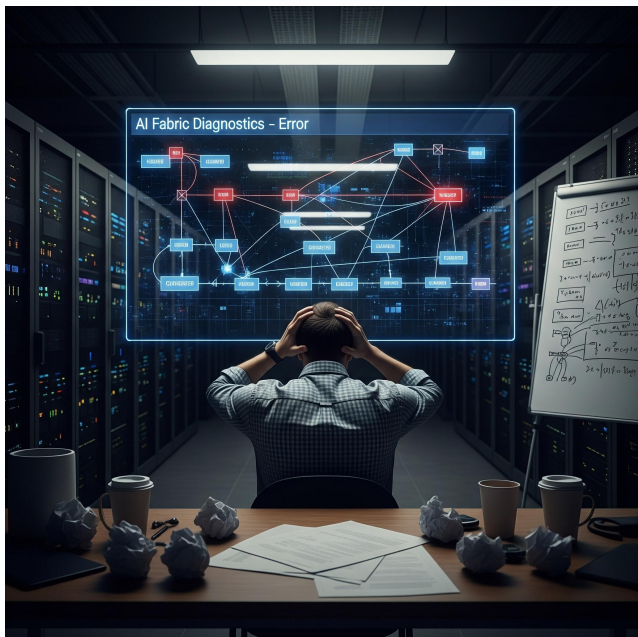


AIネットワークの可視性の提供

CVP UNO(Universal Network Observability)-

Shishio Tsuchiya shtsuchi@arista.com

ネットワーク管理者の苦悩

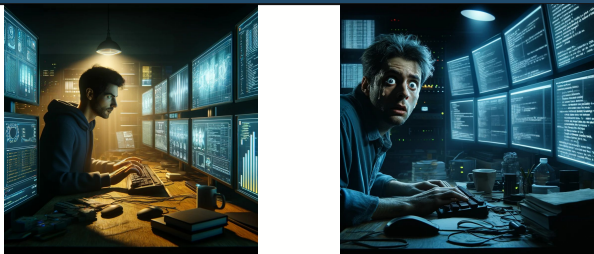


- ネットワークの変更で重要な機能が壊れる可能性はあるか？
- ネットワーク上でどのアプリケーションがどこで実行されているか？
- 仮想マシンが移動またはスケールアップしたことで、ネットワークの信頼性やパフォーマンスに影響があったか
- ネットワークのせいになってるが他はすべて正常に動作しているのか？
- 設定変更によってネットワークに問題が生じる可能性はあるか？
計画した変更は意図しない結果をもたらしたのか？

今のツールは「症状」の検出に優れているが
根本原因の特定は依然として手作業

Cloud Vision Universal Network Observability

従来のIT環境



手動による診断

- データアクセス／データ洪水
- 過剰なコンソールウィンドウ
- 手動による処理と分析
- 遅いインシデント分析

最新のエンタープライズ



自己診断ネットワーク


- 集中および最適化されたステート (状態)の保管
- 単一画面
- クラウドベースの AI/ML処理
- プロアクティブ リスク分析 / 迅速なインシデント分析 / 正確な根本原因分析

CV UNO: CVaaS + Network Observability

 **自動デプロイメント**


ゼロタッチ、ネットワーク全体の設定データモデル、プリビルド+カスタム Studios ワークフロー




 **リアルタイムテレメトリ**

メトリクス、フロー、イベントのきめ細かな状態ストリーミング、相関、傾向分析、予測アルゴリズム、ネットワーク全体




 **変更管理**

ネットワーク全体のアップグレード、ロールバック、スナップショットのオーケストレーション



ネットワークの観測性

- アプリケーションディスカバリー
- 物理/仮想ホストディスカバリー
- アプリケーションダッシュボード
- アプリケーション依存関係のマッピング
- マルチドメインの影響分析
- イベントの相関関係
- 問題の推論




 **コンプライアンス / リスク**

インベントリ、逸脱、脆弱性、バグの継続的な評価、報告、修正



 **セグメンテーションサービス**

セキュリティポリシー管理 / 実施、ポリシー / アイデンティティ統合、ワイヤレス IPS



データセンター、キャンパス有線/WiFi、パブリッククラウド、WAN インターコネクト

特にAIファブリックで観測可能性が重要な理由



AIワークロードは複雑

- 大規模なAIモデルは分散コンピューティングに依存しているため、問題検出が困難
- 性能のボトルネックは、ネットワーク、ハードウェア、ソフトウェアの非効率性の可能性



可視性の欠如＝リスクの増大

- 隠れた障害は、モデル精度の低下、遅延が増大し、非効率につながる
- リアルタイムの解析なしでAIパフォーマンス問題のデバッグは、時間とコストがかかる



観測可能性がAIの最適化を解き放つ

- ネットワーク、システム、AIジョブのパフォーマンスをリアルタイムで深く可視化
- 問題の迅速な検出、根本原因の分析、プロアクティブな解決が可能
- GPU/TPUの利用率を最大化し、コストの削減と効率の向上



ビジネスインパクト

- モデル学習と推論の高速化＝市場投入までの時間の短縮
- リソースの最適利用による運用コストの削減
- AIの信頼性、拡張性、および長期的な成功を保証

AIファブリックは信頼性が重要

Component	Category	Interruption Count	% of Interruptions
Faulty GPU	GPU	148	30.1%
GPU HBM3 Memory	GPU	72	17.2%
Software Bug	Dependency	54	12.9%
Network Switch/Cable	Network	35	8.4%
Host Maintenance	Unplanned Maintenance	32	7.6%
GPU SRAM Memory	GPU	19	4.5%
GPU System Processor	GPU	17	4.1%
NIC	Host	7	1.7%
NCCL Watchdog Timeouts	Unknown	7	1.7%
Silent Data Corruption	GPU	6	1.4%
GPU Thermal Interface + Sensor	GPU	6	1.4%
SSD	Host	3	0.7%
Power Supply	Host	3	0.7%
Server Chassis	Host	2	0.5%
IO Expansion Board	Host	2	0.5%
Dependency	Dependency	2	0.5%
CPU	Host	2	0.5%
System Memory	Host	2	0.5%

Table 5 Root-cause categorization of unexpected interruptions during a 54-day period of Llama 3 405B pre-training. About 78% of unexpected interruptions were attributed to confirmed or suspected hardware issues.

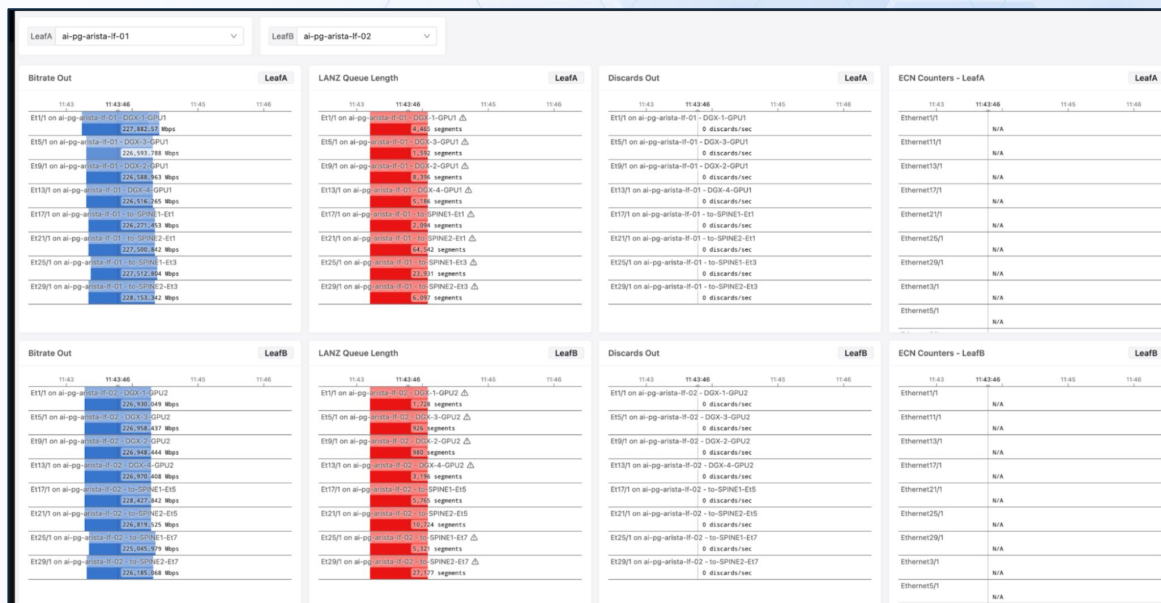
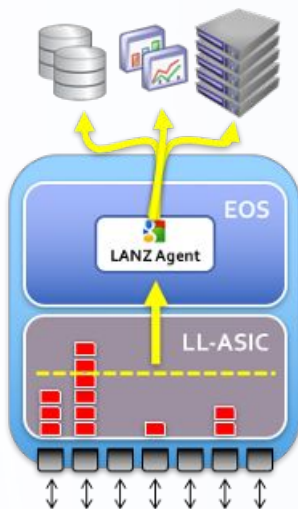
https://www.tomshardware.com/tech-industry/artificial-intelligence/faulty-nvidia-h100-gpus-and-hbm3-memory-caused-half-of-the-failures-during-llama-3-training-one-failure-every-three-hours-for-metas-16384-gpu-training-cluster?utm_source=twitter.com&utm_campaign=social&utm_medium=social

- MetaがLlama 3 405Bモデルのトレーニングを54日間にわたって実施
- この期間中、クラスターは合計466回のジョブ中断を経験
- 47回は計画的なメンテナンスだったが、残りの419回は予期せぬ障害によるものだった

Latency Analyzer (LANZ)とCVPによる可視化

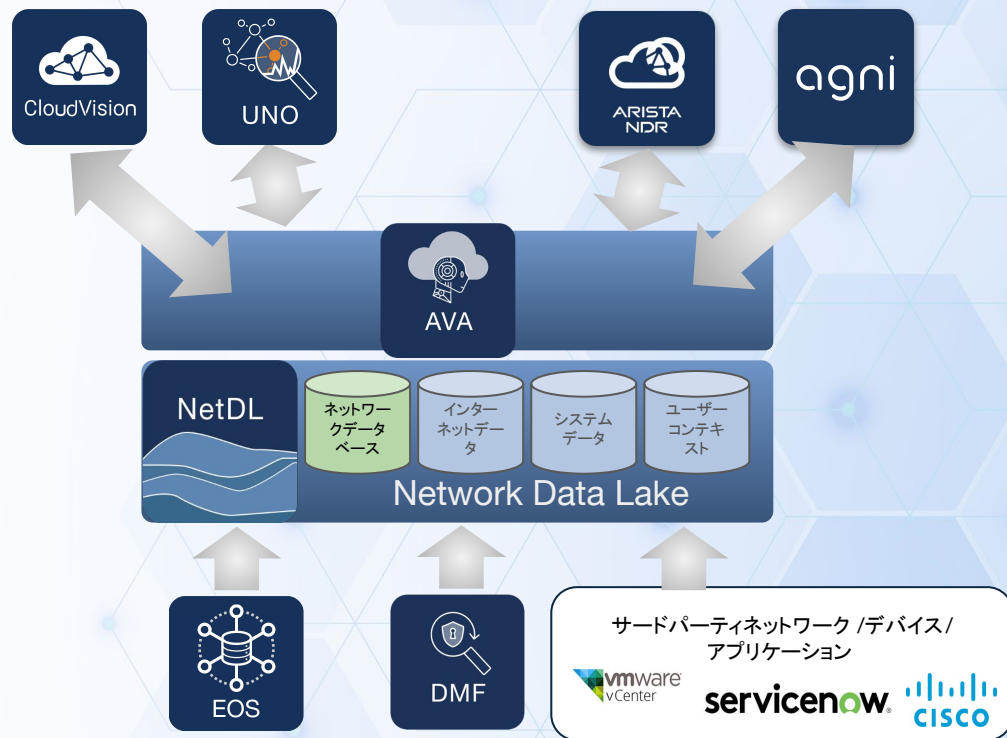


- EOS LANZ (Latency Analyzer):
 - マイクロ秒でキュー混雑、ドロップを記録
- CVP:
 - 時系列でLANZ情報を表示

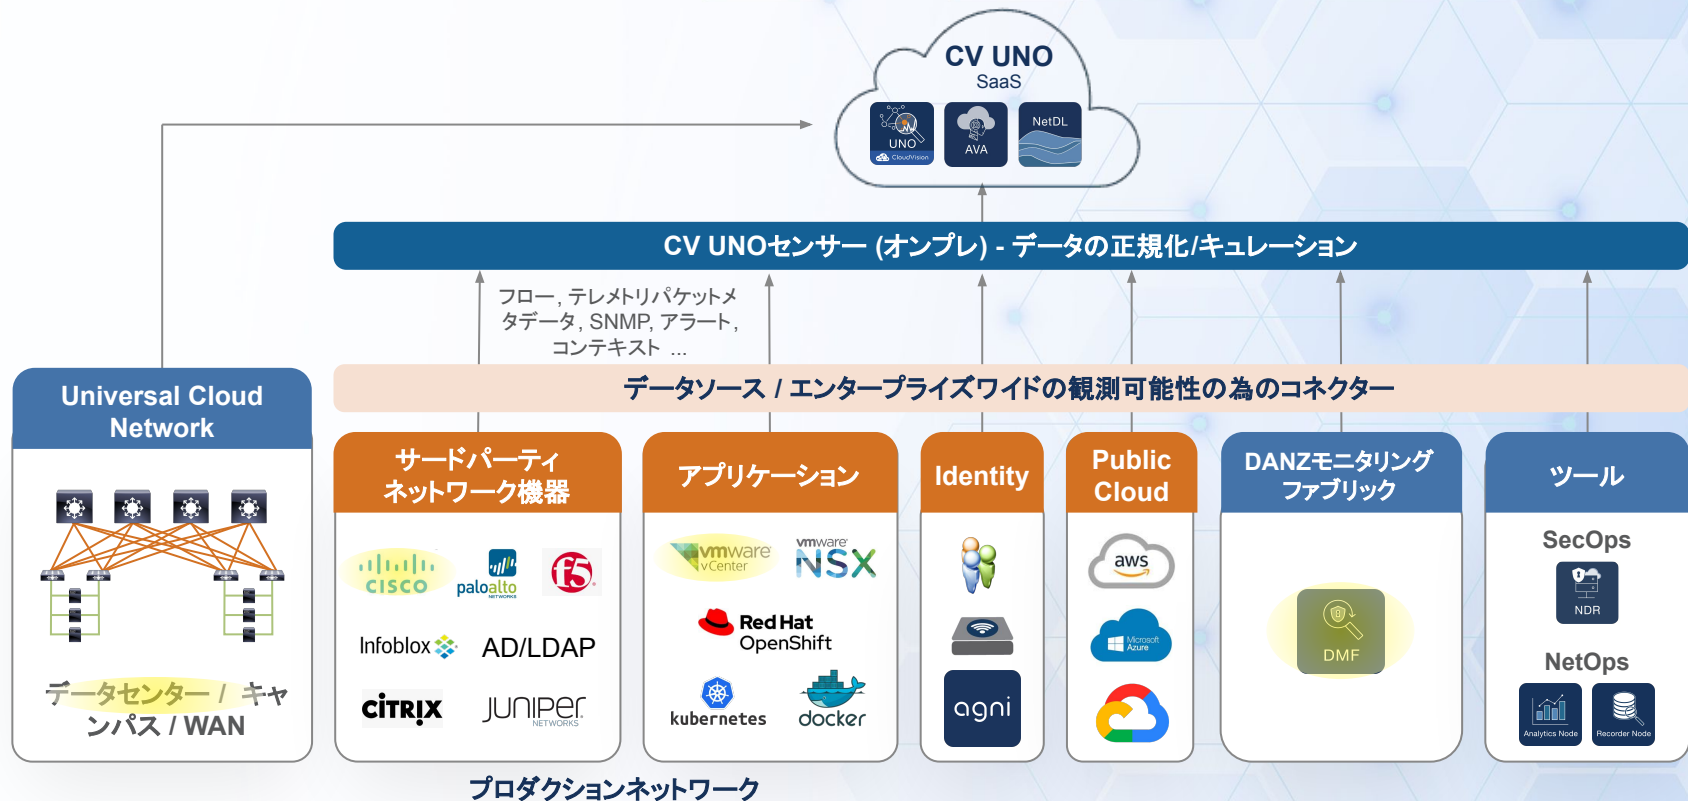


データドリブンアーキテクチャにおける Network Observability

データレイクとは構造化されたデータ/非構造化データ/半構造化データを集めた中央のレポジトリ



CV UNO アーキテクチャモデル



CVaaSとCV UNO

アリスタのホスティング /
マネージドインフラストラクチャ



NetDL

ML

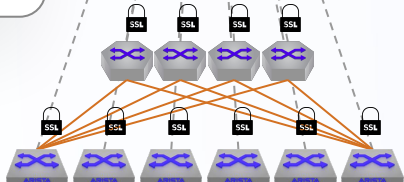
AI / AVA

CV UNO

アリスタUniversal
Cloud Network



sFlow, テレメトリ,
LANZ Alerts



データセンター | キャンパス | エッジ

ミラーされた
トラフィック
TAP/SPAN/L2GRE

CV UNOセンサー (VM)

データの正規化 / キュレーション

エンドツーエンドの遅延と
ドロップ TCP分析

DANZモニタリング
ファブリック



DMF

インベントリーフローデー
タ
アプリケーションタグ

アプリケーション
インフラストラクチャ



SNMP
フローデータ

サードパーティネット
ワークデバイス



クラウド
オンプレ

CV UNO 根本原因の分析：ネットワークの推論



根本原因の分析

問題の引き金となる
ネットワーク変更の可
能性を特定

根本原因の分析

ネットワークパフォーマ
ンスイベントが問題を
引き起こす可能性は
低い

◆ Application Packet Drops Breached Threshold impacting 3 Sources

● Active — Started Nov 29, 2023 19:21:13 (2m ago)

Summary Related Events

Probability ■■■

◆ Application Packet Drops Breached Threshold
3 Sources

likely

① Change Control Change 20231129_191940 Succeeded
2 Devices

moderate

② Abnormal Interface RX Discards
Ethernet52/1 on cdv507

③ Abnormal Interface RX Errors
Ethernet52/1 on cdv507

④ Interface RX Discards Breached Threshold
Ethernet52/1 on cdv507

コンポーネント故障の事前予知



BETA

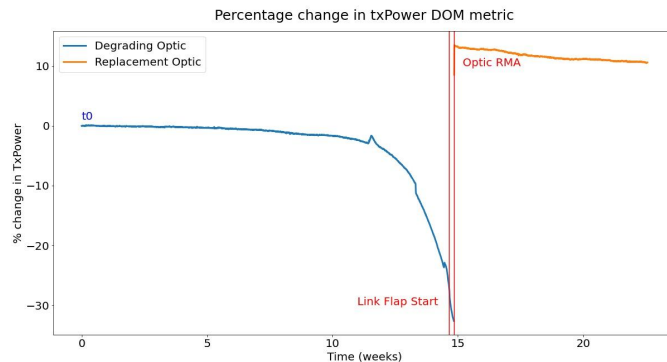
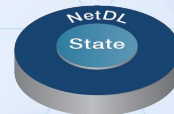
オプティクス障害の例

- リンクの送受信両方のDOMデータをNetDLが蓄積し、AVAが分析
- 電流、温度、フレームエラー、送受信光強度に基づき、AVAがオプティクスの故障をモデル化
- AVAは、実際に障害が発生する前に、ユーザやアリストにアラートをあげ、プロアクティブなオプティクスのRMAを実施



AVA- Autonomous Virtual Assist

Proactive NetOps
Predictive component failures
Device capacity planning and resource mgmt



- エンジニアリングチームは2つの大規模顧客と緊密に連携
- CVPIにより、22Kのオプティクスを1年間にわたって監視
- 16件の障害が予測され、その後、その障害が確認された0誤検知
- 現在、すべてのCVaaS顧客に導入中
- TACによるプロアクティブなRMAの開始

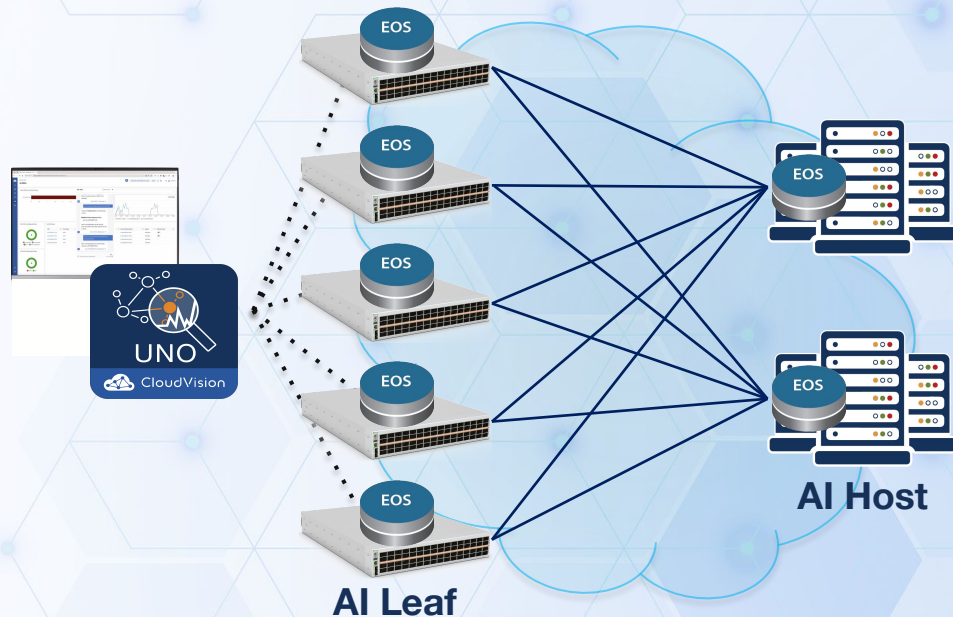
AI向けのCVP UNOの機能

1. Jobとネットワークのパフォーマンスデータの統合
2. 高精度ストリーミングデータとサードパーティデータの統合
3. Jobパスの可視化
 - a. サーバー/NIC/ネットワークに横断するパスを可視化
4. 相関分析と推論
 - a. AIを活用したイベント相関分析や異常/障害検出

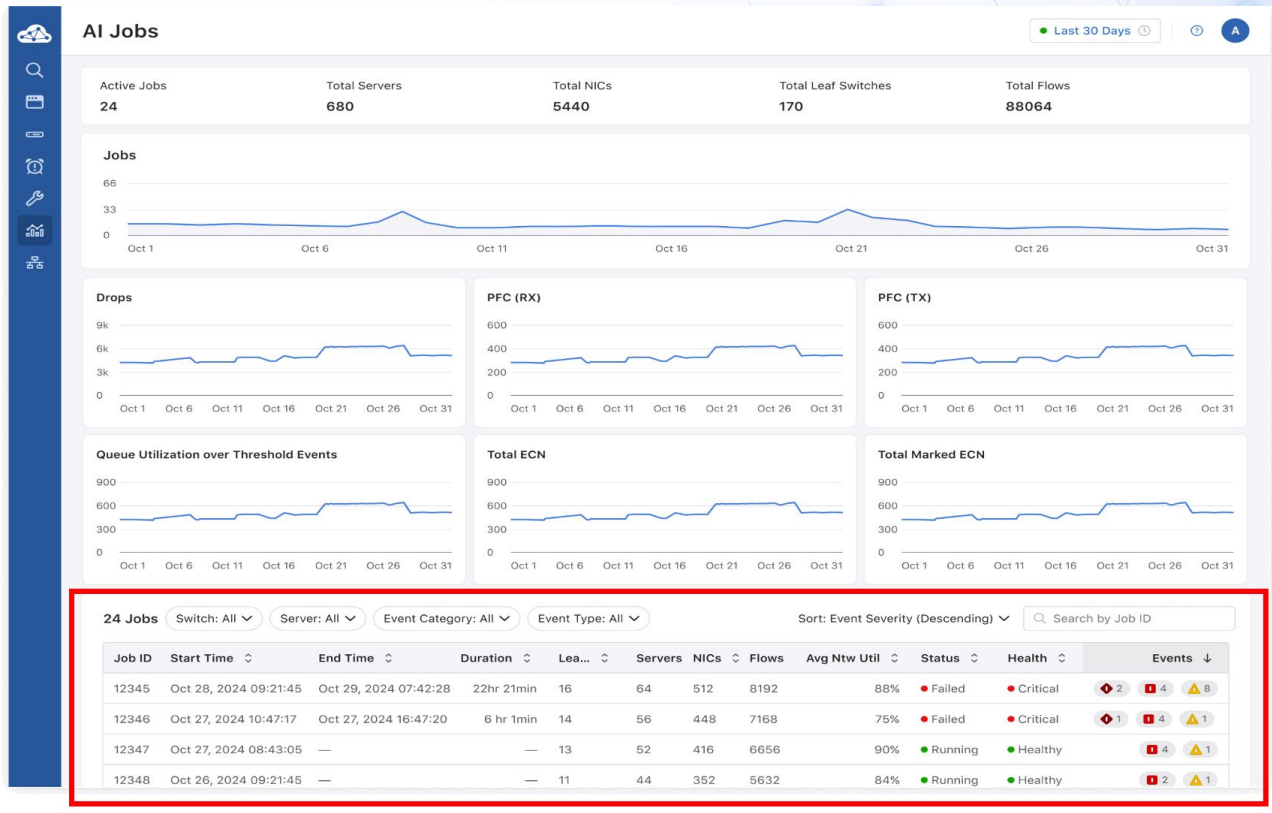


CV UNOの利点

- **全体的なAIジョブ監視** – ジョブの健全性、輻輳、リソース利用状況をマイクロ秒単位でリアルタイムに把握
- **ディープダイブ分析** – ネットワークデバイス、サーバーNIC、RDMAエラーを分析することでボトルネックを特定
- **エンド・ツー・エンド・フローの可視化** – AIによる直感的なジョブ・フロー追跡により、問題を迅速に検出
- **プロアクティブな問題解決** – 早期の異常検知により、AIワークロードの実行を中断を防ぐ



CV UNO Dashboards: AI Job View

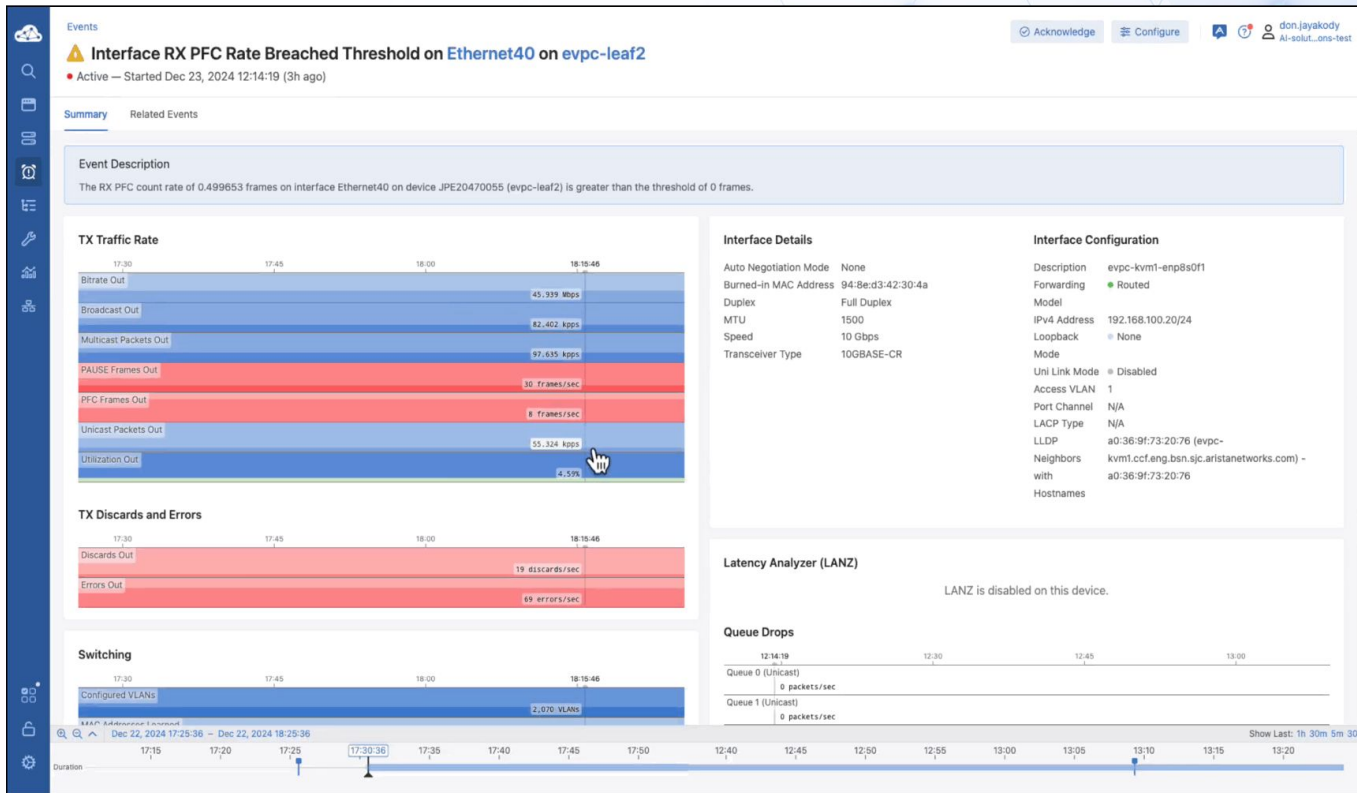


AIのJob IDの実行
時間やステータスが
表示

Failになった12345
というjobに関してド
リルダウン

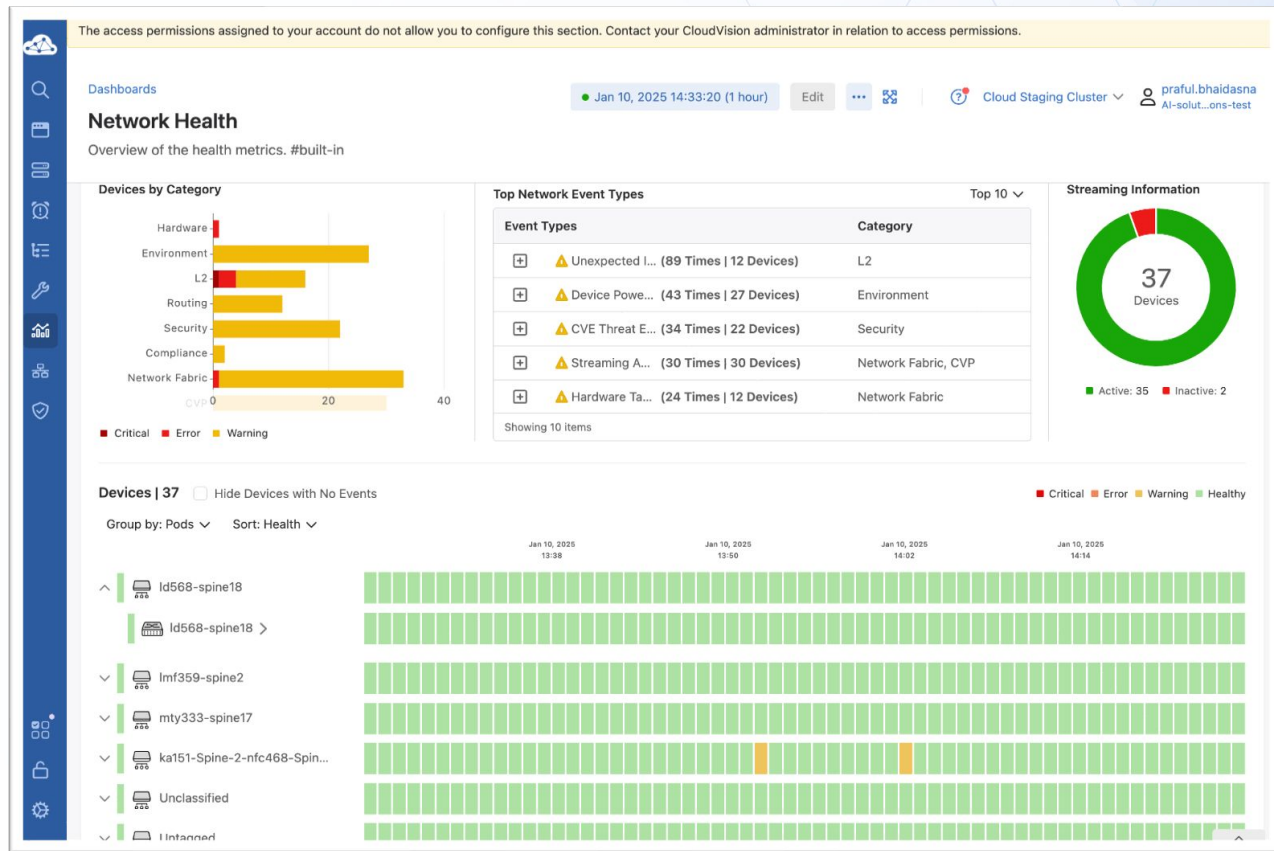
サーバー/Leaf
Switch/Flowとドリル
ダウン解析が可能

CV UNO Dashboards: Events for AI



leaf2のRXでPFCを受けている。他のインターフェースを見るとECNのスレッシュホールドに到達設定の見直しを実施

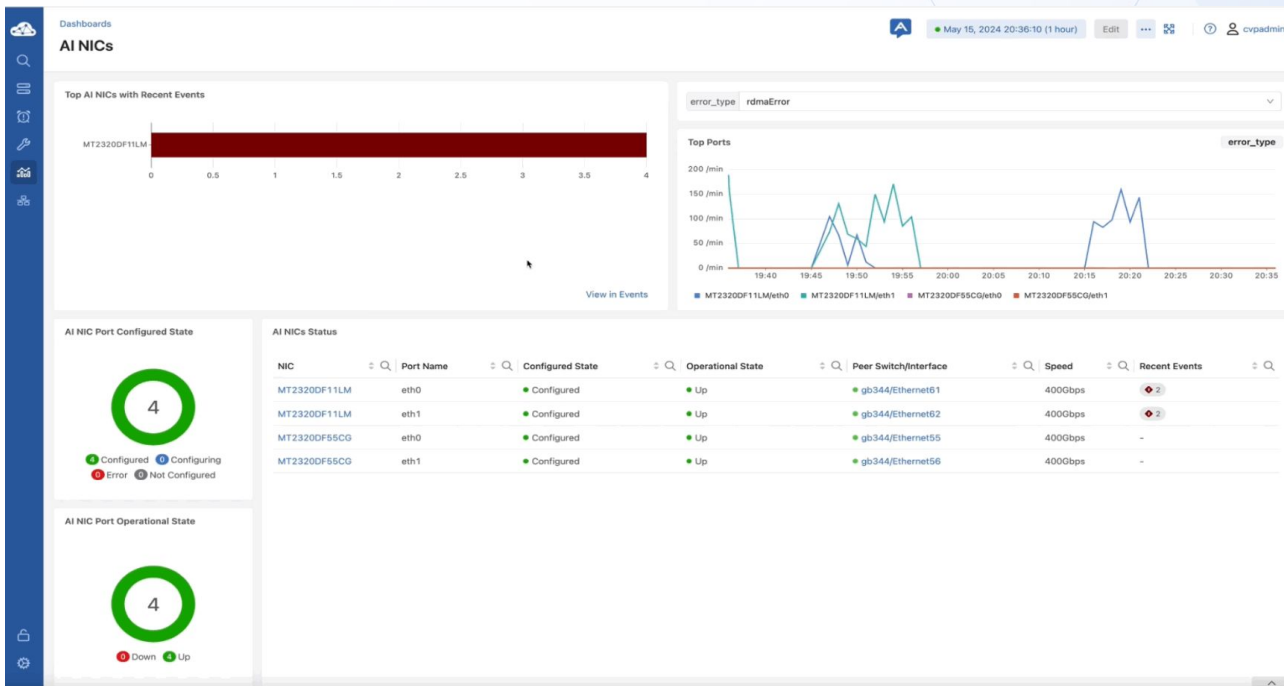
CloudVision Dashboards: Network Health



ネットワーク全体の各
デバイスの時間ごとの
Critical/Warning/info
情報のヒートマップを
表示

スイッチ/サーバとそれ
ぞれの詳細ドリルダウ
ンが表示可能

CV UNO Dashboards: NIC Health

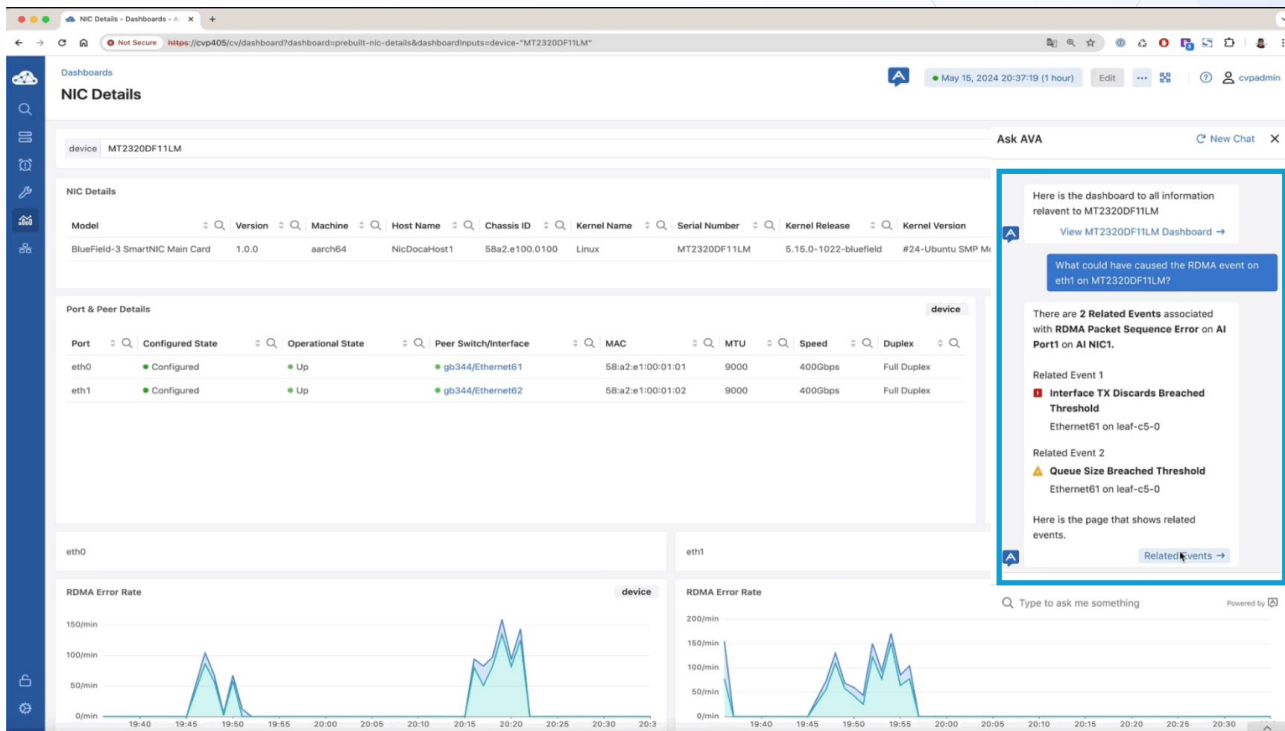


NICのAI特有のイベントのダッシュボードを表示

RDMAエラー/PCIeエラー/インターフェースエラーやPFC/ECNカウンター

QoSの設定などを一括表示

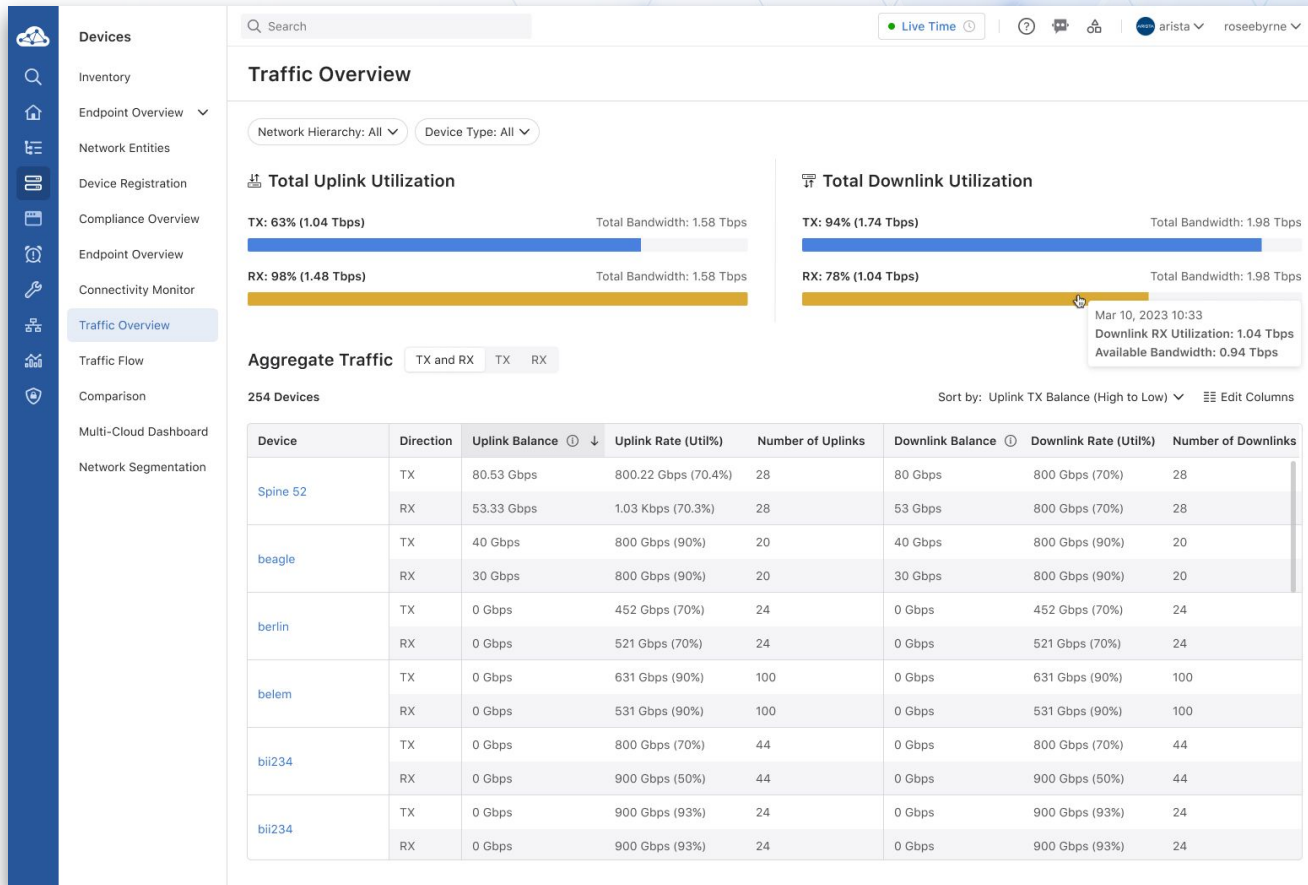
CV UNO Dashboards: Simplified Incident Analysis



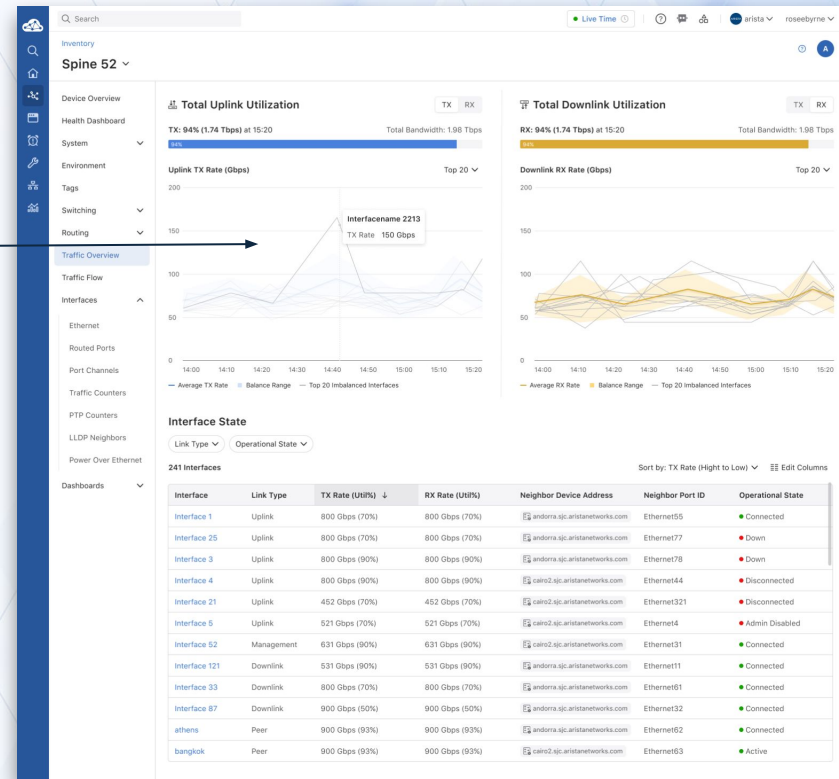
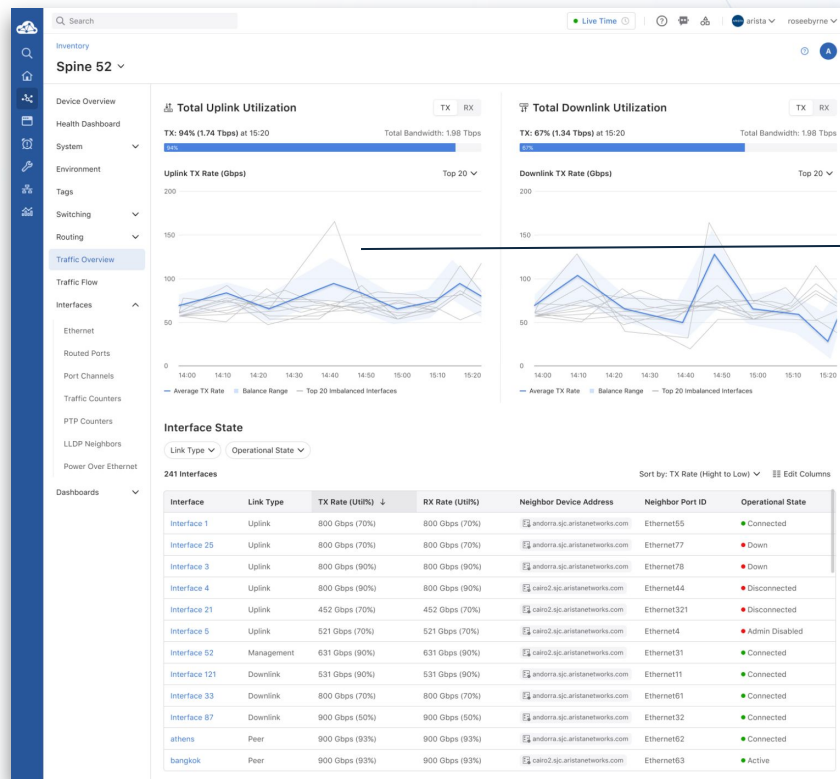
Ask AVAにエラーの詳細原因を尋ねることで、関連イベントを調査各種イベントを相関付けし、特定してくれる。トラブルシューティングが簡単に

ECMPの可視化

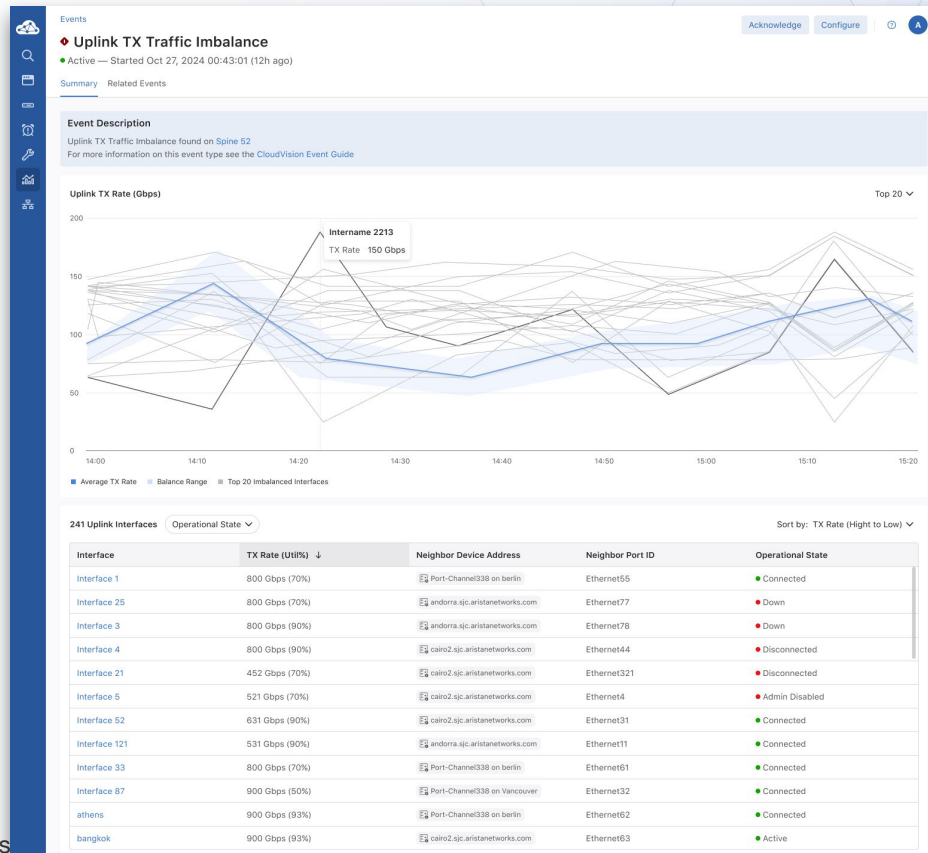
Traffic Overview



ECMP Per Device Traffic Overview



ECMP Imbalance Events



まとめ

- ネットワーク全体でロスレス/バーストで分散処理を行うAIファブリックにおいて必要と思われる可視性を提示
 - QoS設定およびカウンター(DSCP/PFC/ECN)
 - NIC/サーバーのカウンター
 - ネットワーク全体でのフローの相関付
 - JCTとJob IDとそれらの関連付け
 - ECMPの偏りの確認





ARISTA

Thank You

www.arista.com

FAQ

Q.LANZデータの更新の頻度は？

A.LANZ自身はマイクロ秒単位で観測、ストリーミングテレメトリーとしてインターフェースデータなどは2秒間隔/LANZの閾値を超えたときにはsub secでのアップデートを行う。

Q.テレメトリーデータの保管期間は？

A.生のデータは2秒毎に送られ集約データは10秒、1分、15分の各間隔で計算される。保管はCVaaSでは90日 / オンプレ版では7日間

Q.AI Jobデータやサーバーデータはどこと連携するか？

A.Slurm APIなどを通じてセンサーが情報を収集、サーバーに関してはPrometheusを使用

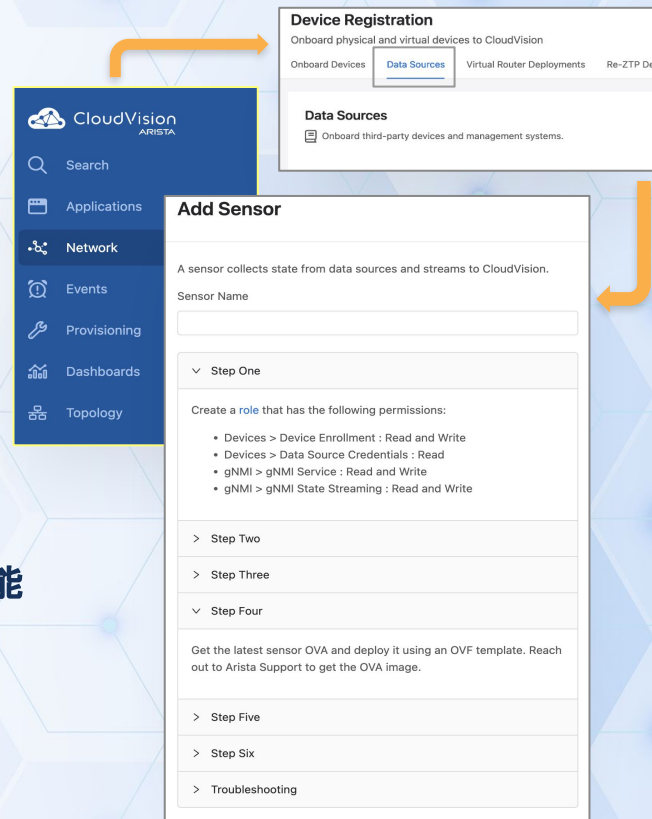
FAQ

Q.コンプライアンスダッシュボードはどの頻度でアップデートされるか？

A.AristaからAlertBaseというバグ情報/脆弱性を公開している。この情報を自動的に同期し、自分が管理するデバイスに対してチェックを行う。

CV UNO センサーのハイライト

- ✓ 様々なデータソースからデータを収集
 - 例: vCenter, ベアメタルサーバー, サードパーティーネットワークデバイス, DMF
- ✓ センサーは収集したデータを安全に CVaaSにストリーミング
- ✓ VMware環境の仮想ホストとして展開 (OVAアプライアンス)
- ✓ センサーは顧客施設内に設置
- ✓ ほとんどの場合、単一の CV UNOセンサーで DC全体に対応可能
- ✓ TLS 1.3 over HTTP2



CV UNO データソース

ネットワーク中心のデータ

EOS

(テレメトリとフローデータ)



サードパーティー

(SNMP)



vCenter

(vDSwitchからのNetflow)



サードパーティー

(フローデータ)



アプリケーション中心のデータ

vCenter

vCenterインベントリデータ
(ESXi, VMs, vDS)



ベアメタル

帯域幅(接続されたスイッチインター
フェースから得られる)



アプリケーション定義

(CMDBを活用)



パケットの分析

DMFサービスノード

(TCP分析 -
エンドツーエンド遅延)

