

地域社会 DX 推進パッケージ事業(AI 検証タイプ)

兵庫県神戸市

スタジアムにおける人流監視のための
エッジ AI を用いた通信量削減の実証

実証報告書

2026 年 1 月 30 日

AI04 神戸市

楽天モバイル株式会社

AWL 株式会社

楽天ヴィッセル神戸株式会社

目次

0.	エグゼクティブサマリ.....	1
0.1	実証概要	1
0.1.1	背景と課題.....	1
0.1.2	目的	1
0.1.3	検証内容と使用技術.....	2
0.2	KPI/KGI の内容と達成状況.....	3
0.2.1	ユースケース①:エッジ AI による通信量の低減.....	3
0.2.2	拡張性検証.....	5
0.2.3	効果検証.....	6
0.3	考察.....	7
0.3.1	ユースケース①:エッジ AI による通信量の低減.....	7
0.3.2	拡張性検証.....	8
0.3.3	効果検証.....	8
0.4	成果.....	9
0.4.1	ユースケース①:エッジ AI による通信量の低減.....	9
0.4.2	拡張性検証.....	10
0.4.3	効果検証.....	10
0.5	課題.....	11
0.5.1	ユースケース①:エッジ AI による通信量の低減.....	11
0.5.2	拡張性検証.....	12
0.5.3	効果検証.....	12
0.6	AI×通信の社会実装に向けた課題と解決の方向性.....	13
1.	実証の目的および内容等	14
1.1	実証の背景・取り組むべき課題.....	14
1.2	実証の目的	15
1.3	最終目標・構想イメージ.....	16
1.4	本実証の位置づけ・目標.....	17
1.5	社会実装に向けたロードマップ・取り組みの発展性.....	21
2.	業務実施体制.....	23
2.1	実証機関	23
2.2	実施体制図	23

3.	通信システムおよび AI システムの構築.....	25
3.1	通信システムおよび AI システムの全体像	25
3.2	通信システムおよび AI システムの設置場所	27
3.2.1	通信システムおよび送受信場所.....	27
3.2.2	AI 監視カメラシステム設置場所.....	28
3.3	通信システムおよび AI システムの構築・運用に要した費用.....	31
3.4	通信システムおよび AI システムの構築にあたっての留意事項等.....	32
3.4.1	有線 LAN ケーブルの選定時、長さが速度に影響.....	32
4.	AI モデルの開発・学習.....	34
4.1	AI モデルの全体像	34
4.1.1	AWL Engine Agent (ファーエッジ上のアプリケーション).....	35
4.1.2	AI 異常レポート要約エージェント	36
4.1.3	本実証 AI モデル全体像のまとめ	39
4.2	取得したデータ.....	39
4.2.1	取得したデータ一覧.....	39
4.2.2	データセット作成に係る処理	40
4.2.3	システム全体のデータフロー図.....	48
4.2.4	データの適切さ	54
4.3	AI モデルの学習プロセス	56
4.3.1	AWL Engine Agent	56
4.3.2	Rakuten Mini 2.0 のファインチューニングプロセス.....	57
4.4	AI モデルの開発・学習にあたっての留意事項等	58
4.4.1	AWL Engine Agent	58
4.4.2	AI 異常レポート要約エージェント関連の開発について.....	60
5.	実証の手法	62
5.1	ユースケース①:エッジ AI による通信量の低減	62
5.1.1	実証内容の詳細	62
5.1.2	利用技術・データ	63
5.1.3	必要性・新規性.....	78
5.1.4	検証条件	80
5.1.5	開発・評価項目	81
5.1.6	KPI/KGI.....	102
5.2	ユースケース②:山間部や海中等の携帯電話網不感地域における通信の確立 ...	111
5.3	ユースケース③:多種多様なデバイスに対する通信リソースの最適化	111
5.4	ユースケース④:分散ネットワークにおける新たな AI ソリューションの創出	111
5.5	拡張性に関する検証.....	111

5.5.1	実証内容の詳細	111
5.5.2	前提条件	113
5.5.3	評価項目	117
5.5.4	KPI/KGI.....	128
5.6	効果検証	130
5.6.1	実証内容の詳細	130
5.6.2	前提条件	131
5.6.3	評価項目	132
5.6.4	KPI/KGI.....	133
6.	実証の結果・考察	136
6.1	全体スケジュール	136
6.2	ユースケース①:エッジ AI による通信量の低減	136
6.2.1	実証スケジュール	136
6.2.2	開発・評価項目の結果	137
6.2.3	KPI/KGI との比較結果.....	185
6.2.4	考察	198
6.3	ユースケース②:山間部や海中等の携帯電話網不感地域における通信の確立 ..	200
6.4	ユースケース③:多種多様なデバイスに対する通信リソースの最適化	200
6.5	ユースケース④:分散ネットワークにおける新たな AI ソリューションの創出	201
6.6	拡張性に関する検証.....	201
6.6.1	実証スケジュール	201
6.6.2	評価項目の結果	201
6.6.3	KPI/KGI との比較結果.....	210
6.6.4	考察	214
6.7	効果検証	217
6.7.1	実証スケジュール	218
6.7.2	評価項目の結果	218
6.7.3	KPI/KGI との比較結果.....	220
6.7.4	考察	223
7.	本実証の総括	226
7.1	本実証の成果・課題.....	226
7.1.1	ユースケース①:エッジ AI による通信量の低減(6 章 2 節).....	226
7.1.2	拡張性に関する検証(6 章 6 節)	227
7.1.3	効果検証(6 章 7 節)	227
7.1.4	総括	228
8.	参考資料	229

8.1	システム構成図・設計書	229
	8.1.1 エッジサーバまでのシステム構成図.....	229
	8.1.2 エッジサーバ以降のシステム構成図	230
8.2	ネットワーク構成図・設計書	230
8.3	使用機器・ソフトウェア一覧	231
	8.3.1 データ取得に関する機器・ソフトウェア(センサ類)	231
	8.3.2 データ処理に関する機器・ソフトウェア.....	232
8.4	取得したデータの例	236
8.5	第 6 章における効果検証の前提条件及び計算式.....	242
	8.5.1 総コスト(導入費用+運用費用).....	243
	8.5.2 業務負荷軽減の検証.....	244
	8.5.3 一般ソリューションのコスト.....	245
	8.5.4 通信費削減.....	249
8.6	その他、当該システムを再現する上で参考となる資料	250
8.7	広報活動実績.....	250
8.8	参考文献	254

0. エグゼクティブサマリ

0.1 実証概要

0.1.1 背景と課題

現代社会では労働力不足が深刻化しており、特に警備分野でその影響が顕著である。厚生労働省の一般職業紹介状況(令和7年10月分)によれば、保安職業従事者の有効求人倍率は全国平均で6.66倍に達し、全産業平均の1.10倍を大きく上回っている。また、この人員不足に加え、最低賃金の上昇により人件費が高騰し、過去令和2年度からの5年間で24%増となっている。楽天ヴィッセル神戸(御崎公園球技場(ノエビアスタジアム神戸)の管理運営事業者)では、これらの人員不足と最低賃金上昇に伴う人件費高騰により、将来的には、警備員の不足や、人員不足等に伴う監視が不十分な状況になる恐れがあり、安全上のリスクを高まることが懸念されている。労働力不足に対し、AI技術を活用した監視業務の代替など、解決策が模索されているものの、クラウド上でのAI運用はデータをインターネット経由で送信する必要があり、これが社会資源であるトラヒックの逼迫を招く要因となっている。また、固定回線を利用した既存監視システムの更新は大規模な施設改修を伴い、多大な費用を要することが課題となっていた。

0.1.2 目的

本実証において提案するソリューションは、カメラ入力映像をエッジ(ファーフエッジ:本実証ではカメラと対で動作する情報処理デバイス)で動作するAIで一次処理を行い、ケースに応じて映像の一部切り出し、画像、およびメタデータを抽出する。さらに、生成AIであるSLM(小規模言語モデル¹)によってメタデータを自然言語の要約レポートへテキスト化し、これらの情報を警備担当者に配信するものである。このシステムは単独で動作するのではなく、複数のカメラ・ファーフエッジで処理された情報をエッジサーバで統合し、ファーフエッジの一次処理・エッジサーバの二次処理で高度に圧縮したデータをユーザ側のデバイスにヒューマンフレンドリーな形式で通知することにより、効率よく警備担当者に状況を通知することを想定する。これにより、前述した課題に対して、以下の効果を期待する。

- (1) 同システムのネットワーク利用量・電力消費量削減による運用コスト削減および帯域・電力の確保
エッジデバイスなどの計算資源での処理の分散によりデータ伝送量とAI利用による電力消費量の最適化は警備・監視システムの運用コストを削減することができる。また、データ伝送量の最適化により、他のユーザへの影響を最小限に抑え、社会インフラである電波を有効に利用することができる。
- (2) 大規模・多用途施設での警備・監視システムの可搬性向上による導入・横展開コストの削減
用途に応じて監視対象となる場所が異なる大規模施設運営において、可搬性のあるソリューションに

¹ 小規模言語モデル(SLM)は、自然言語コンテンツを処理、理解、生成できる人工知能(AI)モデルです。その名前が示すように、SLMは大規模言語モデル(LLM)よりも規模と範囲が小さなものです。出典:<https://www.ibm.com/jp-ja/think/topics/small-language-models>

より、監視装置を都度最適な配置に変更することで施設全域への固定設置型の大規模監視設備導入を不要とする。それにより、初期導入コストを削減する。加えて、可搬型ソリューションの他施設への流用も容易となる。

(3) 労働力不足が招くセキュリティリスクへの対処

現場への巡回や常駐をすることなく、遠隔からの監視や不審事象の検知を可能にすることで、少ない労働力でも人力かつ現場で監視している場合と同等以上の監視能力を担保する。

0.1.3 検証内容と使用技術

技術的可用性の検証として、①侵入検知および人物のリスク度判定、②属性検出による迷子検知、③炎・煙検知による火災検知をファアーエッジ上で実施する。ネットワーク利用量削減効果の検証では、状況に応じて超高圧縮(テキスト化)、高圧縮(画像化)、中圧縮(映像部分抽出)を使い分ける。また、AIモデル拡張性検証として「転倒検知」、「暴力検知」、「顔認識」の精度を評価し、システム可搬性検証として可搬型カメラの導入効果と最適配置設計を検証する。

(1) エッジ AI による通信量の低減

映像から検知された事象のリスクレベルと設置場所のネットワーク混雑状況を把握し、カメラと直結したファアーエッジで AI アルゴリズムを用いることで、状況に応じて、超高圧縮(テキスト化)、高圧縮(画像化)、中圧縮(映像部分抽出)を行い、データ量の少ない形式に変換・送信を行う。

更に複数のファアーエッジを束ねるエッジサーバにおいて、SLM を用いて 1 本のレポートに統合することで、更なる通信量削減を行う。

(2) 拡張性に関する検証:スタジアム以外の異なる産業・分野・地域への横展開が期待される、汎用的な異常検知の実現

様々な異常検知 AI のファアーエッジでの実装可能性を検証する。「転倒検知」、「暴力検知」、「顔認証」といった様々な異常検知 AI のファアーエッジでの実証可能性を検証し、AI モデルをオンライン化(ファアーエッジへ搭載)する際の課題とその解決策について考察する。また、システムの可搬性に関する検証として、大規模多目的施設における警備監視システムの可搬性に伴う導入効果および実現性について検証し、今後の実現性を高めるための課題や、可搬性を持つシステムの運用効率や運用上の課題を把握することを目的とする。

(3) 効果検証:コスト削減効果、投資対効果(ROI)

本ソリューションを導入することで削減できる業務時間や工数を把握し、業務負荷軽減効果やカメラ設置の柔軟性向上を検証する。また、設備導入・運用コストの削減効果を他のソリューション(固定式のカメラ、Wi-Fi®型、ローカル 5G 新設)と比較するとともに、消費電力の削減効果を試算する。

0.2 KPI/KGIの内容と達成状況

0.2.1 ユースケース①:エッジ AIによる通信量の低減

本実証では、監視カメラに近いファーフエッジ上で動作する AI が、カメラ映像から検知された事象の重大度合いと設置場所のネットワーク混雑度に応じてカメラ映像を圧縮されたデータ形式(テキスト化/画像化/映像の一部抽出)に変換・送信することで従来のシステムと比較して通信量の削減を行うことを検証した。更に複数のファーフエッジを統括するエッジサーバにおいて、SLMにより要約してレポートを生成することにより、更なる通信量削減を行った。以下の表 0.2-1 に達成状況を示す。

表 0.2-1 ユースケース①の実証における目標値と達成状況

番号	目標値	結果	達成状況	
定性評価	1	スマートグラスアプリの方がスマートフォンアプリよりも満足度が高い	未達成	スマートグラスアプリの方がスマートフォンアプリよりもユーザ満足度が高いことを期待したが、アンケート結果では、警備員に業務を委託する責任者である被験者 2 名は、ともにスマートフォンアプリに対する満足度の方が高かった。
定量評価	2	ファーフエッジ上の圧縮プロセスによる映像圧縮率が右記の値を満たすこと	達成	3 つの圧縮方法すべてについて、またすべての時間帯について、KPI 目標値は達成された。 超高圧縮(テキストへの変換):99%以上 10/17 午前(輻輳なし) 0.99999 10/17 午後(試合開始前、輻輳あり) 0.99994 10/17 午後(試合終了後、輻輳あり) 0.99997 高圧縮(画像への変換):97%以上 10/17 午前(輻輳なし) 0.99910 10/17 午後(試合開始前、輻輳あり)0.99610 10/17 午後(試合終了後、輻輳あり)0.99778 中圧縮(映像クリップへの変換):94%以上 10/17 午前(輻輳なし) 0.98976 10/17 午後(試合開始前、輻輳あり) 1 ※ 10/17 午後(試合終了後、輻輳あり) 1 ※ ※輻輳時、中圧縮は使用されないため 1 となる
	3	ネットワーク混雑時に中圧縮方式の使用を避けることによるデータ送信削減率が右記を満たすこと	達成	データ送信削減率 73%以上 試合開始前、終了後ともに、KPI 目標値は達成された(ともに 95.43%)。また、目標値よりも大幅に削減率は高くなった。
	4	エッジサーバでの情報集約によるデータ送信削減率が右記を満たすこと	達成	データ送信削減率 35%以上 映像クリップダウンロード率が 50%の場合、集約による削減率は 39.99%となった。なお、テキストデータ削減率に限定した場合、92.85%となった。
	5	AI パイプラインによる検出の精度が右記を満たすこと	一部達成	人物の検出 未検知率: 1%以下 誤検知率: 10%以下 <結果> 性能は KPI 目標(未検出率≤1%、誤検知率≤10%)を満たしている。 目標値 : 未検知率≤1%、誤検知率≤10%

				<p>評価件数：214 件 正解率:99% 偽陽性(誤検知):0% 偽陰性(未検知):1%</p> <p>群衆検知(2 名以上) 正解率: 95%以上 <結果> 最終的な正解率は 96%となり、KPI 目標を達成した。また、中間評価から最終評価まで安定した数値を維持した。 評価件数:80 正解率:96% 偽陽性(誤検知):2% 偽陰性(未検知):3%</p> <p>マスクの検出 未検知率: 1%以下 誤検知率: 10%以下 <結果> 未検知率・誤検知率が KPI 基準を満たしておらず、大幅なモデル改善が必要。 評価件数: 30 件 正解率:40% 偽陽性(誤検知):3%。 偽陰性(未検知):57%。</p> <p>年齢推定(10 歳未満・70 歳以上・それ以外の判定) 正解率: 90%以上 <結果> 正解率が年齢推定の KPI 要件を満たしていない。 評価件数：64 件 総合的な正解率: 11% 偽陽性(誤検知): 0% 偽陰性(未検知): 89%</p> <p>煙・炎の検出 未検知率：1%以下 誤検知率：10%以下 <結果> 未検知率、誤検知率とも、中間評価では KPI 目標を達成したが、スタジアム試験では達成できなかった。 評価件数：50 件 正解率：58%。 偽陽性(誤検知):36% 偽陰性(未検知):6%</p> <p>リスクアセスメント(高リスク・低リスク・リスクなしの判定) 未検知率：1%以下 誤検知率：10%以下 <結果> 低リスクイベントについては達成、高リスクイベントについては未達成。高リスクイベントについては、マスク検知や年齢推定などの上流モデルの精度により、強い影響を受けている。 評価件数：高リスク：384 件、低リスク：80 件 総合的な正解率: 高リスク: 40%、低リスク: 100%。 偽陽性(誤検知):高リスク: 30%、低リスク: 0% 偽陰性(未検知):高リスク: 30%、低リスク: 0%</p>
--	--	--	--	---

	6	エンドユーザの反応時間が右記を満たすこと	一部達成	通知への反応時間: スマートグラスアプリの方がスマートフォンアプリよりも短い:達成 映像クリップ表示までの時間: スマートグラスアプリの方がスマートフォンアプリよりも短い:未達成
	7	ファーエッジ推論の遅延時間が右記を満たすこと	達成	遅延時間: 200~5000 ミリ秒 (1000 ミリ秒をデフォルトのパラメータ設定とする予定。200 ミリ秒とする場合リアルタイム性は高いが、ノイズ誤検知が増えるため) <結果> リアルタイム AI モデルのリスクイベント処理遅延 リアルタイム AI モデルにおけるリスクイベント処理遅延は、KPI で定義された 200~5000 ミリ秒の範囲内で安定して動作し、一部のケースでは想定よりも低遅延となり、目標性能を上回る結果が確認された ファーエッジデバイスにおける複雑なリスク分析処理は、実測において 50~252 ミリ秒の範囲で完了し、安定した低遅延性能が確認された。

0.2.2 拡張性検証

ここでは、AI モデルの拡張性とシステムの可搬性および設置環境の変化に伴う観点で検証を行った。

(1) AI モデルの拡張性の検証

「転倒検知」、「暴力検知」、「特定人物の顔認識」のパターンにおいて KPI 目標値として「未検出率」、「誤検出率」、「処理遅延」を設定し、精度評価を行った。

表 0.2-2 AI モデルの拡張性検証における目標値と達成状況

番号	目標値	結果	達成状況
定量評価 1	人物の転倒検知、暴力検知、特定人物の顔認識において ・未検出率: ≤ 1% ・誤検知率: ≤ 10% ・処理遅延: 200~5000 ミリ秒	達成	人物の転倒検知:達成 <ul style="list-style-type: none"> 未検出率:0%(0/30) 誤検知率:3.33%(1/30) 処理遅延:800~1200ms 暴力検知:達成 <ul style="list-style-type: none"> 未検出率:0%(0/45) 誤検知率:2%(1/45) 処理遅延:900~1500ms 特定人物の顔認識:達成 <ul style="list-style-type: none"> 未検出率:0%(0/56) 誤検知率:0%(0/56) 処理遅延:500ms 未満

(2) システムの可搬性、および設置環境の変化に伴う AI 検知精度の安定性を評価

表 0.2-3 AI 検知精度検証の目標値および達成状況

番号	目標値	結果	達成状況
定性評価 1	設置・撤去時間	達成	以下のような利便性や今後の課題解決策についてのフィードバックが得られた。 <ul style="list-style-type: none"> 短時間で完了し、イベント警備や一時的な監視強化において高い運用柔軟性を提供できる。 機器の重量、サイズ、形状、可搬性がいずれも「とてもよい」と評価さ

				れ、破損リスクへの懸念も「全くない」とされており、物理的な移動の容易さが確認された。これにより、運搬時の負担が軽減され、効率的な運用に寄与すると想定できる。
定量 評価	2	環境変化に伴う AI 検出精度 場所 A と場所 B の検出差(誤差率 の差):10%未満	一部 達成	照度 Lev.1 <ul style="list-style-type: none"> 10 秒未満立ち入り:達成 マスク:達成 炎:達成 照度 Lev.2 <ul style="list-style-type: none"> 10 秒未満立ち入り:達成 マスク:達成 炎:未達成 照度 Lev.3 <ul style="list-style-type: none"> 10 秒未満立ち入り:未達成 マスク:未達成 炎:達成
	3	設置・撤去時間	設置: 16 分 撤去: 4 分	<ul style="list-style-type: none"> 1 回以上の設置経験を有する利用者を前提とした場合、カメラ 1 台あたりの設置時間は約 16 分であった。 カメラ 1 台あたりの撤去時間は 3~4 分であった。 エッジサーバからカメラまでの距離を 5m 以上となる場合はケーブル配線の作業に要する時間の考慮が必要である。

0.2.3 効果検証

この検証では、本ソリューションを導入する場合のコスト削減効果や業務負荷軽減、消費電力等について検証を行った。すべての項目において、効果が見込める結果となった。

表 0.2-4 効果検証における目標値と達成状況

番号	目標値	結果	達成状況	
1	コスト削減効果 (総コスト)	削減 見込みあり	本ソリューションと一般的なソリューションの 5 年間総コストを比較した結果、コスト面でのメリットが確認された。結果は以下の通りである。 <ul style="list-style-type: none"> 固定式カメラとの比較:約 1,198 万円の削減 Wi-Fi 型との比較:約 2,716 万円の削減 ローカル 5G 新設との比較:約 3,913 万円の削減 	
2	業務負荷軽減効果の検証	削減 見込みあり	現行システムに対し、本ソリューション導入時の方が 1 日あたり 118 時間の総監視稼働時間業務時間削減が見込める結果となった。	
定量 評価	3	カメラ設置の柔軟性向上の検証	柔軟性向上 見込みあり	一般的な固定式のカメラソリューションは約 500,000 円であった。これに対し本ソリューションは固定式ではないため、設置工事が不要である。
	4	消費電力削減効果	削減 見込みあり	AI 圧縮による伝送データ量削減に伴う通信機器の消費電力削減可能性の理論的確認

0.3 考察

本実証で各検証結果から得られた考察は以下の通り。

0.3.1 ユースケース①:エッジ AI による通信量の低減

- 通信量削減:
 - 映像データの超高圧縮、高圧縮、中圧縮は、ファーエッジでの映像データ圧縮が期待通りに機能したため、継続的な映像送信に比べ、全方式について削減率 97%以上の大きな削減効果を示し、KPI を達成した。
 - ネットワーク輻輳時に中圧縮方式を避けることによる削減率は、送信データの大半を占める画像データサイズが想定よりも少なく抑えられたため、KPI 目標値 79.47%を大幅に上回る約 95.43%を記録した。これにより、ネットワーク状況に応じて圧縮方式を変更する手法の有効性が裏付けられた。
 - エッジサーバでの情報集約による削減率は、KPI 目標値を上回る 39.99%を達成した。このデータ削減の大半は、映像クリップをユーザが要求するまで送信しないことによるものだったが、SLM 要約によるテキストデータ削減(削減率 92.85%)も寄与した。
- AIパイプライン検出精度:本実証により、侵入や群衆検知など身体の有無や動きといった粗い特徴に依存するタスクでは 95%以上の精度を達成し、クラウドに依存しないリアルタイム処理の有効性が確認された。一方で、マスク検知、年齢推定、火災・煙検知といった、より微細な認識が必要なタスクについては、今後のモデル強化、または高性能エッジサーバでの処理により精度向上が見込める領域であることが明らかになった。これにより、エッジ側での高速処理と、サーバ側での高精度処理を組み合わせた「ハイブリッドアーキテクチャ」が、広範な社会実装に向けた有望策であることを裏付ける結果となった。本アプローチは、多様な施設環境において拡張性と実効性を両立する、将来性の高い構成である。
- ユーザアプリケーション:
 - ユーザ(警備担当者)満足度は、スマートグラスアプリの方がスマートフォンアプリと比較して低く、ユーザ反応時間についてもスマートグラスアプリの方が長いという結果になった。スマートグラスの操作はスマートフォンと比較して慣れるのに時間がかかるため、操作経験の少ないユーザは操作が難しいと感じた可能性が高い。
 - ユーザからのフィードバック結果は、スマートグラスアプリの利便性について複数の課題が存在することを示したが、一方で本システムが警備業務の効率性向上に貢献する可能性を強く示した。
- SLM 要約精度:当初、一般的な要約生成用プロンプトの入力手法では SLM の推論能力の限界が確認されたが、入力データの整形、システムプロンプトの簡素化などの対策の結果、正解率は 47%に向上した。さらに誤った出力に対して正解のヒントを与えるフィードバックループの導

入により、最終的に要約の正確率を 99%まで大幅に向上させることに成功した。

0.3.2 拡張性検証

- AI 精度(転倒・暴力・顔認識):ファームウェアでのリアルタイム処理と、エッジサーバでの高度な分析が明確に分離された構成により、既存のリアルタイム処理の安定性を損なうことなく、新しい AI 機能を追加できることを確認した。転倒検知、暴力検知、顔認証などの各モデルについては、記録データを用いたオフライン評価により、精度や処理特性を詳細に分析でき、反復的な検証・調整を効率的に実施できた。これにより、エッジ側のリアルタイム性を維持しつつ、サーバ側の高度な分析機能を組み合わせることで、将来的な機能追加やモデル高度化にも拡張可能な構成であることが示された。
- 可搬性(照度):照度 Lev.1(数十メートル先が確認できる程度の明るさ)および 2(足元が確認できる程度の明るさ)では、「炎」を除く全項目で KPI を達成し、通常照度環境における安定した検知性能を確認できた。一方で「炎」検知については、学習データと実環境の差異やカメラ側の撮像条件など、複合的要因による改善余地が示唆された。照度 Lev.3(無光)では全体的に精度が低下し、特に「マスク」など細かな特徴を扱うタスクで性能差が顕著となった。これは、低照度環境特有の撮像ノイズやコントラスト低下がモデル推論に影響したためであり、カメラ性能・設定と AI モデルの両面で最適化が必要であることを示す重要な知見となった。これらの結果は、暗所環境における検知性能の向上に向けて、カメラ性能と AI モデルを一体的に改善することで、さらなる性能向上が期待できることを示しており、次期バージョンの強化ポイントが明確になった。
- 可搬性(設置/撤去):本ソリューションは、カメラ 1 台あたり人員 1 名で約 16 分という短時間での設置、および 3~4 分での撤去が可能であることが実証され、短時間で運用環境を構築できる可搬型システムとしての有効性が確認された。しかしながら、150m×150m の面積に 10 箇所設置した場合には配線作業等も含み、約 6 時間を要したことから、大規模環境における設置時間のさらなる短縮や省力化が課題であることを示唆している。同時に、設置作業の主な時間要因がケーブル配線作業であることも明らかとなり、配線方法の最適化や無線化により、さらに短時間での構築・撤去が可能になる余地があることが確認できた。加えて、施設利用者の動線、安全性や景観に配慮したケーブル設計についても改善方向が明確になり、より実運用に適したシステムとしての発展の可能性が示された。

0.3.3 効果検証

- コスト削減効果(総コスト):本ソリューションは現在の監視業務時間負荷を 1/5 に軽減し、初期導入から投資回収が見込まれる(人員配置によっては 2 年程度で回収見込み)。一般的なソリューションと比較しても、固定式のカメラ、Wi-Fi 型、ローカル 5G(新設)に対してコスト削減効果が期待できる。この削減効果は、AI 圧縮によるデータ伝送量の抑制(通信費削減)と、無線化による追加回線工事が不要になることにより実現される。

- 業務負荷軽減効果:監視業務の負荷が従来の方式では 120 時間(24 時間×5 名)要するのに対し、本ソリューションでは 1 名が 2 時間で対応が見込めることから、1 日あたり 118 時間削減することを確認した。これは、従来のシステムにて大量の映像データを常時監視していた業務を AI がリスクイベントのみを抽出し、監視員が確認すべき映像を絞り込むことで、監視員の業務時間を大幅に軽減する。
- カメラ設置の柔軟性向上の検証:一般的な固定式のカメラソリューションは設置に 500,000 円程度要する。これに対し本ソリューションは固定式ではないため、設置工事が不要である。
- 消費電力削減効果:AI 圧縮により伝送データ量が削減されるため、通信機器の消費電力も削減される。運用コストの低減だけでなく、環境負荷の低減にも貢献する。

0.4 成果

本ソリューションはスタジアムに限定されず、イベント施設、オフィスビル、工場など監視・警備を必要とする施設への横展開が可能であることが確認された。既存 LTE 回線を活用することで初期投資を抑え、可搬性の高いシステムにより必要な場所・時期に柔軟に導入できる点も大きな強みである。他ソリューションと比較しても経済的優位性を示した。また、AI 導入により常時モニタリングではない効率的な警備・監視が可能となり、人件費抑制や労働力の最適配置に寄与することが明らかとなった。

0.4.1 ユースケース①:エッジ AI による通信量の低減

- 通信量削減:
 - ファーエッジ・エッジサーバの二段階でデータ量を圧縮することにより、大容量のカメラ映像をそのまま集中型サーバやクラウド環境に配信するシステムと比較し、大幅なデータ通信量の削減が可能であることが示された。
 - また導入先のネットワーク輻輳時に、圧縮率の高い映像圧縮方式のみを使用することにより、さらなる通信量削減を実現できることが示された。これにより、一般の利用者のネットワーク利用に影響を及ぼさずに社会資源である電波を有効利用できることが期待される。
- AI パイプライン検出精度:ローカル推論とテレメトリ通信を組み合わせた本構成は、ネットワークの遅延・パケット損失・ジッターの影響を受けないため、未検知を回避し、安定したフレームタイミングで高精度なモデル動作を実現できる。また、映像データをエッジデバイスから外部に出さないため、プライバシー保護の観点でもクラウド型より優位である。これにより、中央集権的なストリーミング方式と比較して、より堅牢で信頼性の高いシステム基盤の構築が可能である。
- SLM 要約精度:エッジサーバに搭載した、ファーエッジからの情報を要約する SLM について、当初は追加学習を行わずに検証を実施した結果、要約精度は正解率 47%にとどまった。その後、

プロンプトエンジニアリングの手法を通じて精度を大幅に向上させることができ、99%の高い正解率を達成した。しかし、現状の手法は要約ケースの複雑化への対応に課題があるため、最終的に追加学習(ファインチューニング)も検証を行い、95%の要約正解率を達成した。SLM をベースに追加実装した AI 要約エージェントにより高い正解率は実現されたが、監視システムにおける誤った緊急通報は安全性に影響を及ぼすため、正解率 100%の確保が次期の課題となる。

- ユーザアプリケーション:スマートグラスアプリケーションでは、検知詳細情報が 3D スタジアムモデル上に 3D で表示されることにより異常発生場所を直感的に把握できる利点を評価する声があった。また、端末を手にとらずに異常を確認できる利点を評価する声もあった。これらにより、スマートグラスを警備業務に使用する利点があることを示せた。

0.4.2 拡張性検証

- AI 精度(転倒・暴力・顔認識):ファーエッジデバイスでのリアルタイム処理と、エッジサーバでの高度な分析を行う構成において、ファーエッジのハードウェアを交換することなく、サーバ側の改善のみで新たな AI 機能を柔軟に追加・拡張できることが確認された。加えて、オフライン評価手法では、エッジサーバが有する十分な計算資源を活用することで、リアルタイム制約に縛られず高度な AI モデルの検証が可能であり、この仕組みはスタジアムに限らず多様な施設・用途への展開においても有効であることが示唆された。これにより、将来的な機能強化やモデル高度化に継続的かつ効率的に取り組める拡張可能な基盤が確立されていることが明らかとなった。
- 可搬性(設置/撤去):今回実証した可搬式カメラシステムでは、固定式のカメラシステムでは実現困難な高い運用柔軟性を発揮し、短時間で監視環境の構築と撤去が求められるイベント警備、一時的な監視強化、災害時における緊急監視など、多様なシーンに迅速に対応できることが確認された。これにより、必要な場所へ必要なタイミングで即時展開できる“モバイル監視基盤”として優れた拡張性を有することが明確となり、今後の幅広い社会実装において重要な選択肢となり得る。

0.4.3 効果検証

- コスト削減効果(総コスト):可搬式カメラシステムが有線ケーブル敷設に伴う大規模工事や高価な通信インフラ導入が不要となる点は、導入障壁の低減に大きく寄与する。
- 業務負荷軽減効果の検証:AI が異常を検知・通知することで、熟練者とのスキルの差を解消し、対応できる人材の幅を広げることできる。これにより、警備業務の質を維持しつつ、他の業務とのリソースの最適配置が可能となる。
- カメラ設置の柔軟性向上の検証:回線工事が不要になることで、カメラの設置場所の制約が大幅に緩和される。これにより、施設の形状や既存インフラに左右されず、必要な場所に迅速にカメラ

を設置できる。

- 消費電力削減効果: バッテリー駆動の監視カメラなど、電源供給が限られる環境での運用において、この効果は非常に重要となる。

0.5 課題

本実証では多くの KPI を達成した一方で判明した課題もあった。これら課題については今後の社会実装を目指し、解決の方向性を以下に示す。

0.5.1 ユースケース①: エッジ AI による通信量の低減

- 通信量削減:
 - 本年度採用した予測アルゴリズムでは、短時間で大きく変化する実環境のネットワーク輻輳度を正確に予測することが困難であることが示された。
 - 無線品質や通信の混雑状況により、必要となる削減量は異なるため、将来的には RIC プラットフォームと連携して、リアルタイムで取得したネットワーク情報を基にしたネットワーク輻輳度を使用した圧縮アルゴリズム制御を実現することにより、通信利用者への影響を最大限抑止した形で、ファーエッジからエッジサーバの間の無線化を実現していく。
 - AI が検知した事象が重大である場合は、ネットワークが混雑していても高解像度の映像を安定的に送信する必要がある。この場合、ネットワークスライシング技術や QoS 制御などの優先制御を活用し、RIC アプリケーションと連携して映像配信に必要な帯域を動的に割り当てることで、異なるサービスレベルを本ソリューションに適用し、高い監視能力を維持することができると見込まれる。
- AI パイプライン: 本エッジ AI 技術は、自治体の安全対策、都市インフラ(交通拠点、公園、学校)、商業施設など幅広い分野で適用可能であり、前述した「ハイブリッドアーキテクチャ」の採用やモデルの継続的な改良を通じた検知精度の向上により、さらなる市場拡大が見込まれる。この技術は日本の DX 推進と整合性が高く、国内事業者が競争力のある監視ソリューションを提供する好機である。継続的なモデル改良とシステム最適化を進めることで、公共の安全強化と日本全体のデジタル変革を支える強力なツールとなり得る。
- SLM 要約精度: 要約の正解率 100%の確保を次期課題とし、異なる AI エージェントのデザインパターンの検討・実装を進める。あわせて、より高い推論能力を持つ SLM(小規模言語モデル) または LLM(大規模言語モデル)の採用も有効である可能性がある。並行して処理負荷の最適化を検証し、要約の正解率 100%を目指しつつ、システムの堅牢性と低遅延を維持することを課題とする。さらに、複雑な異常イベントへの対応や要約仕様の改善も今後の課題として位置づける。

- ユーザアプリケーション:スマートグラスアプリについての改善点・要望については、すべて実装による対応が可能な項目であるため、今回得られた改善点・要望を踏まえて細部の作り込み、改善、機能追加により、ユーザ満足度を向上させられる余地が十分にあると言える。また、今後の社会実装に向けては、スマートグラスのクリック操作は初心者にとって難易度が高いため、ユーザが慣れるための時間を十分に確保するなどの対応が考えられる。また、本実証で採用した Apple Vision Pro の重量は 750~800 g とやや重く、また稼働時間は一般的な使用で最大約 2~2.5 時間程度であり、現時点では常時装着は難しい。しかし、将来的に技術が進展し AR デバイスの軽量化・長稼働時間化が進めば、警備担当者は常時装着も可能と考えられる。

0.5.2 拡張性検証

- AI 精度(転倒・暴力・顔認識):高度な AI モデルは、ハードウェア性能の影響を受けるため、ファーエッジデバイスでのリアルタイム運用には最適化が必要となる。また、カメラ台数や AI 機能の増加に伴い、エッジサーバの負荷や処理遅延が増加する可能性がある。しかし、これらは本構成が持つ拡張性を前提にした強化余地であり、モデルの軽量化・高速化、リソース配分の最適化、負荷条件を踏まえた評価ルール整備により、より大規模環境にも対応できる見込みがある。今後、カメラ台数を増やした高負荷環境での評価を進めることで、オフライン検証からリアルタイム運用への移行をより確実にし、将来の大規模展開に向けた安定性をさらに高めることが期待される。
- 可搬性(照度):低照度環境では撮像品質が検知精度に影響するため、アルゴリズム改善やカメラ設置条件の最適化、運用条件の整理が必要となる。ただし、本実証により課題領域が明確化されたことで、暗所向けモデル強化・撮像条件の最適化といった改善方向が具体化し、将来的な夜間運用への発展可能性が広がった。
- 可搬性(設置/撤去):ケーブル配線の課題については、本ソリューションを無線化し、モバイルネットワーク通信や Wi-Fi を介して通信できれば、ケーブル配線の手間を解消し、設置時間を大幅に短縮することが見込める。これにより、本ソリューションの迅速性と可搬性がさらに向上し、イベント・臨時施設・災害時など、より幅広い場面での即時展開が実現できる可能性が高い。

0.5.3 効果検証

- コスト削減効果(総コスト):監視カメラの設置範囲が広く、カメラ間の距離が長い場合、有線ケーブルの配線には多大な時間と労力を要する。今後は、有線配線に伴う設置時間と業務負荷の課題を軽減できる無線化などの手段を検討する必要がある。
- 業務負荷軽減効果の検証:本ソリューション導入で業務時間削減が見込めるため、引き続き導入に向けてより実務に近づけた検証内容で実証や導入への検討を重ねる。
- カメラ設置の柔軟性向上の検証:可搬式であることから、さまざまな施設や状況に柔軟に配置が可能となる。今後の導入に向けて配置を変更しての実証や試合以外でのイベントでの活用も検討していく。

- 消費電力削減効果:本ソリューションがエッジ処理を重視する一方で、将来的に AI モデルの学習や高度な分析のためにクラウドを活用する場面が増えることが想定される。その場合、クラウド側のデータ転送量やコンピューティングリソースの消費電力も考慮に入れた、システム全体での消費電力最適化の計算モデルと評価が必要となる。

0.6 AI×通信の社会実装に向けた課題と解決の方向性

本実証実験は、スタジアムという高密度かつ環境変動の激しい実フィールドにおいて、エッジ AI 技術と通信技術を融合させた監視ソリューションの技術的実現性とビジネス価値を検証するものであった。

技術的側面においては、カメラに近い装置であるファーエッジ側での「超高圧縮」等のデータ処理とエッジ側でのデータ統合と二段階でデータを圧縮することで、通信帯域が混雑する場合でも事象に対してリアルタイムでの検知および初期対応が可能であることを実証した。これは、通信網が脆弱な環境や災害時においても、必要最小限のデータ量で状況把握が可能であることを示唆しており、社会インフラとしての強靱性を示すものである。

社会的・ビジネス的側面においては、深刻化する警備業界の人手不足という課題に対し、AI による「人の目の代替」と「業務の自動化」で警備業務経験の浅い従事者でも本ソリューションを活用することで熟練者とのスキル差を埋めることができ、有効な解決策となり得ることが定量的に確認された。また、大幅なコスト削減効果と迅速な投資回収見込みは、ユーザとなる自治体や民間企業による DX 推進を後押しする強力な材料となる。

微細な認識タスクにおける精度向上や、設置運用のさらなる省力化などの課題は残るものの、これらはハイブリッドアーキテクチャへの進化や無線技術の活用により解決可能なものである。無線技術においては、将来的に RIC プラットフォームと連携したリアルタイムの圧縮アルゴリズム制御や、ネットワークスライシング技術や QoS 制御による高リスクイベント映像の専用帯域による配信なども想定する。

よって、本ソリューションは日本の社会インフラにおける安全性向上とデジタル変革(DX)を支える基盤技術として、高い実用性と将来性を有していると結論付けられる。

本取り組みを通じて、今後は、深刻化する警備業界の労働力不足という社会課題に対し、様々な施設、環境において本ソリューションが強力な解決策となるよう推進する。無線化技術との融合により「工事不要・即時設置」を実現することで導入ハードルをさらに下げ、通信量削減とコストメリットを両立させた次世代の AI 監視ソリューションとして、事業の横展開や社会実装を目指していく。

1. 実証の目的および内容等

1.1 実証の背景・取り組むべき課題

現代社会では労働力不足が深刻化し、特に警備分野でその影響が顕著である。厚生労働省のデータによれば、令和 7 年 10 月時点の保安職業従事者業の有効求人倍率²は全国平均で 6.66 倍に達し、これは全産業平均の 1.10 倍を大きく上回る水準であり、警備要員の確保が極めて困難であることを示している。サッカーやラグビーの試合の開催やコンサートにも転用できるスタジアム施設を都市公園法に基づく管理運営許可制度により運営している楽天ヴィッセル神戸(以下「ヴィッセル神戸」という。)では、上記の人員不足および最低賃金の上昇に伴う人件費の高騰(令和 2 年度からの 5 年間で 24%増³)も相まって警備人員が不足しているため、他の業務を兼任しながらの警備が行われており、結果として監視が不十分な状況が安全上のリスクを高めている。固定回線を利用した既存の監視システムの更新や機能強化は大規模な施設改修を伴い、非常に費用を要する。現在は、既存システムによる監視が行えない領域が存在し、監視カメラが設置されていない。そのような場所では人力での巡回警備が必要となるが、先述の理由により十分な警備リソースが確保できず、十分な監視が担保できない時間帯や場所が生じている。

労働力不足に対し、AI 技術を活用した解決策が模索されている。特に警備分野では、コンピュータビジョン AI を搭載した監視カメラの利用が進んでいるが、クラウド上での AI 運用はデータをインターネット経由で送信する必要があり、社会性の高いトラヒックの逼迫を招く要因となっている。2024 年時点の全世界のインターネットトラフィックは、月間 522 エクサバイトに達すると予測される(出典:IBIS World internet traffic volume)。また、日本のデータ流通量が 2005 年から 2014 年の 9 年間で約 10 倍に増加した推移を踏まえて試算すると、監視カメラのデータ流通量は、2014 年の約 8.5 エクサバイト(出典:総務省:平成 27 年度情報通信白書)から 2024 年には 85 エクサバイトに拡大すると推計される。

また、多用途化が進む施設では、警備すべき場所や条件が頻繁に変わるため、固定カメラよりも設置場所を柔軟に変更できる可搬式カメラの方が効果的である。可動性の重要な要件としてワイヤレスでのデータ伝送も挙げられるが、集客を重視する施設では、多数の来場者が携帯電話を高頻度に利用するため、施設運営における携帯電波周波数帯の利用が制限される課題もある。特に、サッカーの試合などでは、来場者が携帯電話を使用する時間帯が集中するため、通信が困難になることが想定される。Wi-Fi で広範囲にまたがる通信を確立するには慎重な設計が必要となり、また比較的広範囲で通信可能なローカル 5G は初期コストが高額になる。

これらの背景を踏まえ、取り組むべき課題は以下である。

² 厚生労働省 一般職業紹介状況(令和7年 10 月) 参考統計表
<https://www.mhlw.go.jp/content/11602000/001608689.pdf> 常用(パート含む)

³ 厚生労働省 地域別最低賃金の全国一覧(過去 5 年分) 兵庫県 [令和 2 年～令和 6 年](https://saiteichingin.mhlw.go.jp/table/page_list_past.html)
https://saiteichingin.mhlw.go.jp/table/page_list_past.html
厚生労働省 地域別最低賃金全国一覧 [令和 7 年](https://saiteichingin.mhlw.go.jp/table/page_list_nationallist.php)
https://saiteichingin.mhlw.go.jp/table/page_list_nationallist.php

- ① 労働力不足が招くセキュリティリスクの対処
- ② 大規模・多用途施設での警備・監視システムの可搬性向上による導入・横展開コストの削減
- ③ 同システムのネットワーク利用量および電力消費量削減による運用コスト削減および帯域の確保

本実証においては、監視カメラとエッジ端末上で動作する AI、それらのアウトプットを生成 AI で統合して配信するソリューションの有効性を実証し、将来的には以下の社会価値の提供を目指す。

- ① 超人口減社会において労働力を要しない監視ソリューションの実現による監視能力の向上
- ② 可搬式監視システムという新規産業の創出
- ③ 次世代通信技術と連携した動的な通信資源・計算資源の最適化

1.2 実証の目的

本実証において提案するソリューションは、カメラ入力映像をエッジ(ファーフエッジ:本実証ではカメラと対で動作する情報処理デバイス)で動作する AI で一次処理を行い、ケースに応じて映像の一部切り出し、画像、およびメタデータを抽出する。さらに、生成 AI である SLM(小規模言語モデル)によってメタデータを自然言語の要約レポートへテキスト化し、これらの情報を、警備担当者に配信するものである。このシステムは単独で動作するのではなく、複数カメラ・エッジで処理された情報をエッジサーバで統合し、ファーフエッジの一次処理およびエッジサーバの二次処理で高度に圧縮したデータを、ユーザ側のデバイスにヒューマンフレンドリーな形式で通知することにより、常時張り付きでの監視よりも効率よく警備担当者に状況を通知することを想定する。本ソリューションにより、1.1 節で示した課題に対して以下の効果を期待する。

- ① 労働力不足が招くセキュリティリスクの対処
現場への巡回や常駐をすることなく、遠隔からの監視や不審事象の検知を可能にすることで、少ない労働力でも人力かつ現場で監視している場合と同等以上の監視能力を担保する。
- ② 大規模・多用途施設での警備・監視システムの可搬性向上による導入・横展開コストの削減
用途に応じて監視対象となる場所が異なる大規模施設運営において、可搬性のあるソリューションにより、監視装置を都度最適な配置に変更することで施設全域への固定設置型の大規模監視設備導入が不要とする。それにより、初期導入コストを削減する。加えて、可搬型ソリューションの他施設への流用も容易となる。
- ③ 同システムが利用するネットワーク利用量および電力消費量を削減することで、運用コスト削減し、帯域・電力を確保する。

ファーフエッジ・エッジサーバの二段階でデータ量を圧縮することで、映像をそのまま配信するケースに対して大幅にデータ通信量を圧縮できる。また、ネットワークの混雑度や検知された事象のリスク度合いによって圧縮アルゴリズムを動的に変更することで、ネットワークが輻輳状態のときは非常に少ないデータ量での配信を行い、重要な事象を検知した場合は高い解像度で映像を配信することを可能にする。これにより一般のネットワークへの影響を最小限に留めながら、安全性の高い監視を行うことができる。ま

た、AI は非常に電力消費量が多いが、AI 機能をファーエッジ・エッジサーバ・ユーザ端末のそれぞれに適切に配置することで省電力での運用も目指すことができる。

これらの検証を通じて、実際に運用可能なソリューションの在り方を明らかにし、労働力不足やネットワーク利用量の課題に対する具体的な解決策を提供することを目指す。

1.3 最終目標・構想イメージ

本実証においては、1.1 節で述べた成果目標①超人口減社会において労働力を要しない監視ソリューションの実現による監視能力の向上、②可搬式監視システムという新規産業の創出、③次世代通信技術と連携した動的な通信資源・計算資源の最適化を踏まえ、単独の導入施設における運用効率改善に留まらず、社会実装されることでのセキュリティ・電波などの公共インフラの効率的利用・地域社会の安全確保・ひいては新産業創出による日本全体の活性化を目指すところを最終目標として想定する。具体的には以下の最終目標に対して、本ソリューションによる貢献を段階的に目指していく。

1. 安全性の向上: 効率的な監視システムにより、犯罪や事故の発生を未然に防ぐことが可能となる。特に、超高齢化社会においては、地域の安全を確保することが重要であり、AI による監視がその実現に寄与する。可搬性の高いソリューションや動的にネットワーク使用量が最適化されるソリューションは、常時フルスペックでの監視が必要とはいえない過疎化地域においても有用と考えられる。ただし、本ソリューションによる、犯罪や事故の抑制効果は今後要検証である。
2. 労働力の最適化: 労働力不足が深刻な問題となっている中、常時担当者が能動的に監視を行うのではなく、AI 技術を活用することで、限られた人材をより効率的に活用できるようになる。また、最適な学習を経た AI が異常を検知・通知することで、熟練者とのスキルの差を解消し、対応できる人材の幅を広げることができる。これにより、警備業務の質を維持しつつ、他の業務とのリソースの最適配置が可能となる。
監視業務は監視による検知と、有事を検知した際の対応に分類することができる。前工程である監視を熟練者が能動的に行う際には、明文化されていないノウハウにより注視すべき場所を把握し、危険を事前に察知・予測していることが予想されるが、経験に基づく感覚は継承することが難しい。今後 AI の学習において、出力結果に対してフィードバックすること等を通じて検知精度を向上させ、熟練者の水準に近づけば、未経験の人材がこれを活用することで熟練者と同じ前工程の成果を獲得でき、後工程である有事対応に注力することができるため、単発・短期雇用従事者・未経験者でも対応ができるようになることが期待される。
3. 経済的な効率性: 大規模施設に監視システムを導入するためには、電源工事・配線工事・カメラ設備設置などの大規模な初期投資が必要となる。初期投資だけでなく、工事を伴う導入は施設が商用利用できない期間を発生させることともなり、機会損失にも繋がる。可搬型で設置に時間を要しないソリューションは初期投資コストを抑え、施設の稼働率を向上させることで運営者の経済効率

を向上させることができる。

4. 汎用性:映像処理に基づく AI システムは、通常、特定の物体や状況を認識するために大量のデータ収集と学習プロセスを必要とする。映像が撮影される環境に応じて、AI モデルの最適なチューニングは異なるが、将来的な汎用性を考慮すると、事前に学習したモデルが簡単なカスタマイズで広汎な環境下においても利用できることが望ましい。
5. 拡張性:導入する地域や施設の特性により、AI に期待される機能は異なるが、エッジの特性上処理能力には限界があるため、全ての機能をエッジに搭載することは現実的ではない。施設の特性・要件に応じた AI モデルを柔軟にエッジに搭載する拡張性についても、今後は検討される必要がある。
6. ビジネスの創出と横展開: このソリューションは、他の施設や業界への横展開が可能であり、新たなビジネスモデルの創出につながる。特に、可搬式監視システムは、これまで有線環境が準備できないなどの理由で監視システムが導入できなかった場所への導入が、携帯電話の電波が届く範囲内であれば可能となるため、イベントや催事が開催できなかった施設を利用できることになり地域振興にも繋げることができる。
7. 社会資源の有効利用: ネットワーク利用量が現地のネットワークの状況に合わせて動的に削減されることで、一般の利用者のネットワーク利用に影響を及ぼさずに社会インフラである電波を有効利用できる。将来的には RAN Intelligent Controller (以下 RIC という。) プラットフォームと連携したりリアルタイムの圧縮アルゴリズム制御や、ネットワークスライシングによる高リスクイベント映像の専用帯域による配信なども想定する。

1.4 本実証の位置づけ・目標

将来的に、1.3 節で示した構想イメージを実現するために、本年は以下の内容についての検証を行う。なお、本年は社会実装の事前の検証の位置づけとなり、安全性については検証対象外とする。

1. 安全性:本実証では社会実装までをスコープとせず、事前の検証を行うためこの項目については検証を行わない。本実証では社会実装の事前の検証を行うため、対象外とする。
2. 労働力の最適化:将来的には熟練者の持つ経験に裏付けされた検証や判断をする部分についても AI が補い、初心者でも高いレベルの監視が行えることを期待するが、本実証においては監視業務の補助として、本ソリューションがどのくらい実用的であり、既存の工数削減にどのくらい貢献するかを、プロトタイプ利用者へのインタビューによって検証する。
3. 経済的効率性:本実証を通して、必要な費用(初期投資・運用コスト)を既存ソリューションと比較して導入コストの経済的効率性、監視にかかる人件費の効率性を検証する。
4. 汎用性:本実証においては場所をスタジアム内・研究施設内の様々な照明条件の場所することで

汎用的な環境で利用可能か検証する。また複数の AI モデルをファールエッジで動作させることで、汎用的なリスクに対しての可用性を検証する。また、将来的に必要性が予測される AI の精度検証をオフラインで行い、オフラインでの動作とファールエッジ上での動作の間にある困難を検討する。

5. 拡張性:本実証においては、AI をファールエッジに搭載する際のボトルネックについての机上検討を行う。
6. ビジネス創出および横展開:本実証においてはその事前段階となる費用感の検証を 3.経済的効率性で実施し、横展開の前提条件となる 4.汎用性についても一部の検証を行う。
7. 社会資源の有効利用:本検証においては RIC アプリケーションを仮想した、疑似的なネットワーク輻輳状況を通知する API を用いて、状況に応じた圧縮アルゴリズムの動的な選択が電波の有効活用に有用であることを検証する。

具体的な検証目標は以下とする。

1. 技術的可用性の検証:提案する AI 監視システムの技術的な可用性を検証し、実際の運用環境での精度・パフォーマンスを評価する。本実証においては実際に施設運営を行うヴィッセル神戸が提示した監視項目・監視基準の一部を、本実証内でエッジ AI ソリューションを開発する AWL 株式会社(以下 AWL という。)と楽天モバイル株式会社(以下楽天モバイルという。)が連携して開発する AI の出力結果が満たすことができているか、また精度が十分であることを検証する。

監視業務の性質上、異常時の過剰検出は許容されるが、検出漏れは許容されるものではない。本実証のスコープにおいては、①本来人がいないはずのところに人がいる状況の検出および検出された人物の映像的特徴によるリスク度判定(マスク着用有無⁴)、②人物検出および属性検出(年齢推定)による迷子の検知、③炎・煙を検知することによる火災検知をファールエッジ上での検出対象とする。この検知結果に基づいて、動的に圧縮アルゴリズムの組み合わせを選択するが、その圧縮や切り抜きの効率・精度についても同じく検証を行う。また、将来的な AI の網羅性を目指し、オフライン下での④人物の転倒検知 ⑤暴力検知 ⑥特定人物の顔認証の精度検証も行う。①～⑥においてはその検出漏れが 1%以下であることを目標とする。検出漏れの精度と誤検出の精度はトレードオフだが、並行して 10%以内の誤検出を目標とする。併せて、この目標の数字の妥当性についても検証を行う。①～③の後工程としての画像切り抜き・圧縮については、切り抜きの精度(想定されている領域が正しく切り抜かれているか)と圧縮の効率性を検証項目とする。

2. 本ソリューションの効果の検証:

- (1) ネットワーク利用量削減効果の検証:既存システムや競合システムに対し、本システムで削減できるネットワーク利用量を検証する。本実証においては周囲のネットワークの状況に応じて、以下①～③の圧縮方針をカメラと直結したファールエッジにおいて使い分け、それぞれのファールエッジから送信されたデータをエッジサーバで統合して配信する。図 1.4-1 および図 1.4-2 にシステム概要および圧縮方針を示す。

①超高圧縮:映像をテキスト化

⁴ 前提条件:立ち入り制限のあるエリアにマスク着用で顔を隠している人物を、不審人物と想定する。

- ②高圧縮:映像を切り出し画像化
- ③中圧縮:映像の必要な部分だけを切り出す

ファーエッジにおいて①～③の処理を行うが、その段階でのデータ利用量削減効果(元の映像が必要とした帯域量との比較において)はそれぞれ以下を目標とする。

- ①99%以上削減 ②97%以上削減 ③94%以上削減

(1080p, H.264, bitrate : 3Mbps, 15fps で映像を送信した場合と比較)

また、エッジサーバでレポートデータを統合することで、各ファーエッジが直接基地局に接続する際にはそれぞれが UE としてセルに接続する必要があるが、本ソリューションにおいては 1 つにまとめることができる。これにより(1/ファーエッジ数)に接続数を削減することができる。本実証においては、図 1.4-2 に示すように、10 台のカメラとファーエッジを 1 台のエッジサーバに接続し、接続数を 90%減らすことを目標とする。

- (2) コスト分析:機材・設営などの導入コストや電気使用量・通信料・設営人件費などの運用コストを詳細に分析し、当実証ソリューションの経済的な優位性を示す。既存ソリューションにおいて施設全域をカバーする拡張を行った際の初期費用は、ローカル 5G などを敷設した場合は数百万円規模の初期投資が必要となり、更に監視カメラのソリューション費用を追加で投資する必要がある。施設全域を新規の監視カメラソリューションでカバーする拡張を行った際の初期費用はカメラの費用に加えて設置コストが 1 台あたり 5 万円程度となり、また必要な領域をカバーするために可搬式に比較して 2～3 倍のカメラ数が必要となる。今回は既存ソリューションでカバーできていないエリアや、通常は監視対象ではないが別用途での利用の際に柔軟に監視を導入したいエリアに絞った初期費用として、監視カメラ 10 台で 500 万円以内の費用を想定する。稼働する人件費も本ソリューションの場合は最小限に抑えることが可能である。
- (3) オペレーションの検証:可搬式カメラの設置にあたり、通常人流が発生する箇所であるため盗難・破損・機材による転倒などのリスクがある。リスクを避けるための配置や設営・オペレーションにかかるコストについて検証する。これは実際に監視を担当しているヴィッセル神戸における検証参加・アンケート収集・インタビュー等によって定性評価を行う。
- (4) 拡張性の検証:将来的な他業種・他用途への展開を見据え、AI 機能やカメラ数、エッジ数を増やした際の拡張しやすさを検証する。本年度は、拡張性を見据えたシステム設計を行い、同一施設において配置を変更しての検証に留める。無線品質や通信の混雑状況により、必要となる削減量が異なるため、将来的には RIC プラットフォームと連携したリアルタイムの圧縮アルゴリズム制御を実現することに、通信利用者への影響を最大限抑止した形で、ファーエッジからエッジサーバの間の無線化を実現していく。

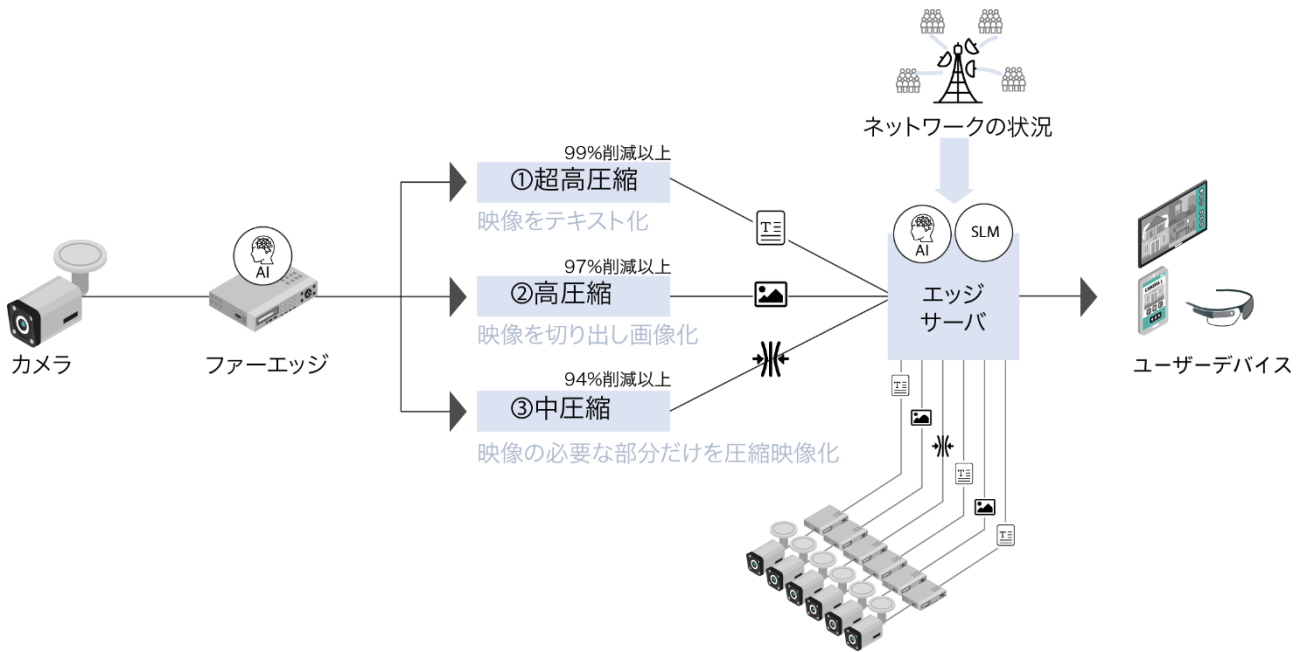


図 1.4-1 システム概要および圧縮方針

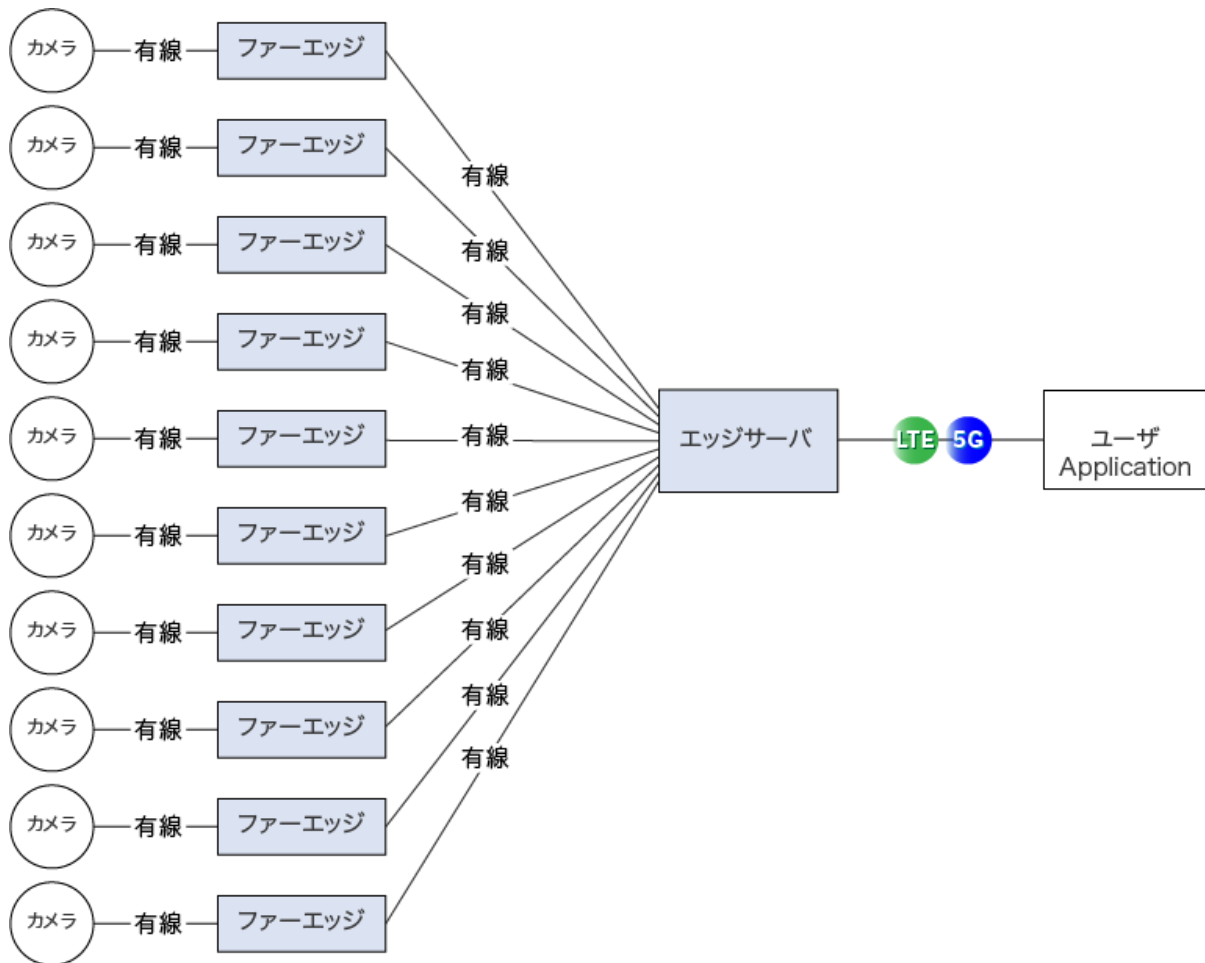


図 1.4-2 システム概要図および圧縮方針

1.5 社会実装に向けたロードマップ・取り組みの発展性

以下は本年度の実証結果を踏まえ、最終目標を見据えた際に想定される検証である。

AI の最適配置および通信の最適化の検討:本実証で想定しているシステムにおいては、ファーエッジとエッジサーバの 2 か所で AI による画像処理・レポート生成を行う。ファーエッジは軽量・安価だが計算資源に乏しいため簡易な処理に適しており、エッジサーバは比較的複雑な計算に適する。また、ファーエッジとエッジサーバの接続において、安全性や設営箇所のフレキシビリティの面からは無線接続が望ましいが、周囲のネットワークの混雑度によって接続が困難であったり、干渉したりするケースが想定される。有線接続の場合は安定的な接続と十分なデータ伝送幅が確保できるが、線の引き回しなどで運用コストが嵩む。将来的にはネットワークスライスの割り当てなどにより、一般の回線利用者に影響を出さないファーエッジ・エッジサーバ間の通信網活用も検討する。また、ユーザデバイス(スマートフォン・スマートグラス)に処理を分散し、より高圧縮のデータを送信しデバイス側の AI でデコードするなど、AI 配置の最適化により更なる通信量削減も目指すことができる。

先にも述べたように、本実証において検証されたプロトタイプを、携帯電話網を活用して横展開するためには、導入する施設におけるテレコムネットワークの状況との連携が必須なものとなる。楽天モバイルでは、現在展開している大規模 Open RAN 商用ネットワークへ 2025 年 5 月に RIC プラットフォームを導入しており、当 RIC プラットフォーム上で動作するアプリケーションでモニターしたネットワークの状況をソリューション側に連携することで、本ソリューションに割り当てられる帯域を動的に制御する・あるいはソリューション側で圧縮アルゴリズムを変更することなどの対応が可能となる。これらの対応を行うことで対応可能なユースケース(施設面・ネットワーク面)の幅が広がり、今後のソリューションとしての外販も検討可能となる。

また、AI が検知したイベントがクリティカルである場合は、ネットワークが混雑していても高解像度の映像を安定的に送信する必要がある。その場合はネットワークスライシング技術を活用し、映像配信に必要な帯域を RIC アプリケーション経由で動的に異なるサービスレベルを本ソリューションに割り当てることで、高いセキュリティレベルを維持することができる。

事業としての展開は以下のようなことが考えられる。

本ソリューションを将来的にプロダクトとして展開する際の販路として、代表提案者である楽天モバイルにおける販売ソリューションのひとつとして運営していくことが想定される。また、共同提案者であるヴィッセル神戸は神戸市より指定を受けたスタジアム運営事業者であり、スタジアムの効率的な運用を業務として遂行している。本実証期間中に得られたノウハウを活かして今後もシステムを運用することで、更に重要なユースケースを探索し、その結果を楽天モバイルにフィードバックすることで、継続的にソリューションの改善を目指していく。また、ソリューションが商用化した際には、ヴィッセル神戸のスポーツ事業における強いリレーションを活かし、本ソリューションの販売窓口・代理店としての機能も期待できる。

本実証の中で、監視管理業務従事者を想定とした非開発者であるヴィッセル神戸担当者自身によって、カメラ、ファーエッジサーバの設置とケーブル配線、本システムの起動までの一連の流れを、作成し

たセットアップマニュアルを元を実施した。この時のフィードバックを元、ソリューションのプロダクト化にあたっての課題を解決する取り組みを継続して行う。

AWL はこれまで固定カメラでの高精度エッジ AI ソリューションに特化してきたが、本事業では新たに可搬式で多様な環境で利用可能なセキュリティ監視システムを構築する。これにより既設ネットワークカメラがない環境でも、短期間で大規模かつ高精度な監視が可能となり、「柔軟な混雑状況における監視業務最適化」という価値を生み出す。今後は、AIモデルの高度化やリアルタイム解析等の新技術開発を進め、事業を拡大していく。

2. 業務実施体制

2.1 実証機関

実証機関について表 2.1-1 に示す。

表 2.1-1 実証機関

代表機関	法人名	楽天モバイル株式会社
	代表者氏名	矢澤 俊介
	所在地	〒158-0094 東京都世田谷区玉川 1-14-1 楽天クリームゾンハウス
	業務の概要	電気通信事業法に基づく電気通信事業その他通信に関する事業
構成員	法人名	AWL 株式会社
	代表者氏名	北出 宗治
	所在地	〒141-0031 東京都品川区西五反田 2 丁目 24 番 4 号 THE CROSS GOTANDA 8 階
	業務の概要	ソフトウェア開発、AI ソリューション提供
	構成員とした理由	実証にむけた画像処理 AI 技術実装部分の協業のため
構成員	法人名	楽天ヴィッセル神戸株式会社
	代表者氏名	千布 勇氣
	所在地	神戸市中央区海岸通 1-2-31
	業務の概要	サッカー競技およびその他スポーツの興行の企画・実施
	構成員とした理由	本件で定義する人手不足によるセキュリティリスクという課題の当事者であり、また通信の実証実験の経験を豊富に持つため

2.2 実施体制図

実施体制図について図 2.2-1 に示す。

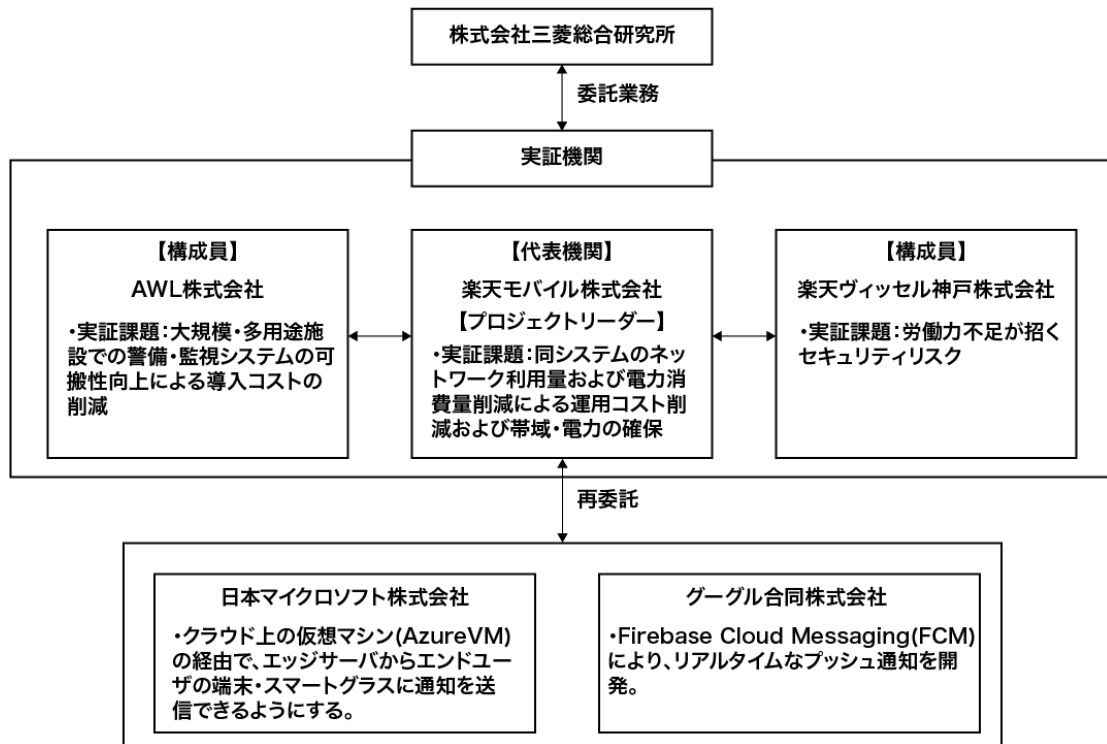


図 2.2-1 実施体制図

3. 通信システムおよび AI システムの構築

3.1 通信システムおよび AI システムの全体像

本実証では、ネットワークと AI 技術を融合し、リアルタイムデータ伝送の最適化ソリューションを構築した。これは、他地域でも再現可能であることを目標に設計されている。特に、LTE エリアが整備されている地域やイベント施設など、LTE 通信混雑時におけるデータ伝送負荷の軽減に主眼を置き、送信データ量を動的に削減する仕組みを導入する。

本検証で実装した通信システムおよび AI 監視カメラシステムの概要を、図 3.1-1 に示すシステム構成図に基づいて以下に説明する。各システムのコンポーネントは表 3.1-1 に示す。

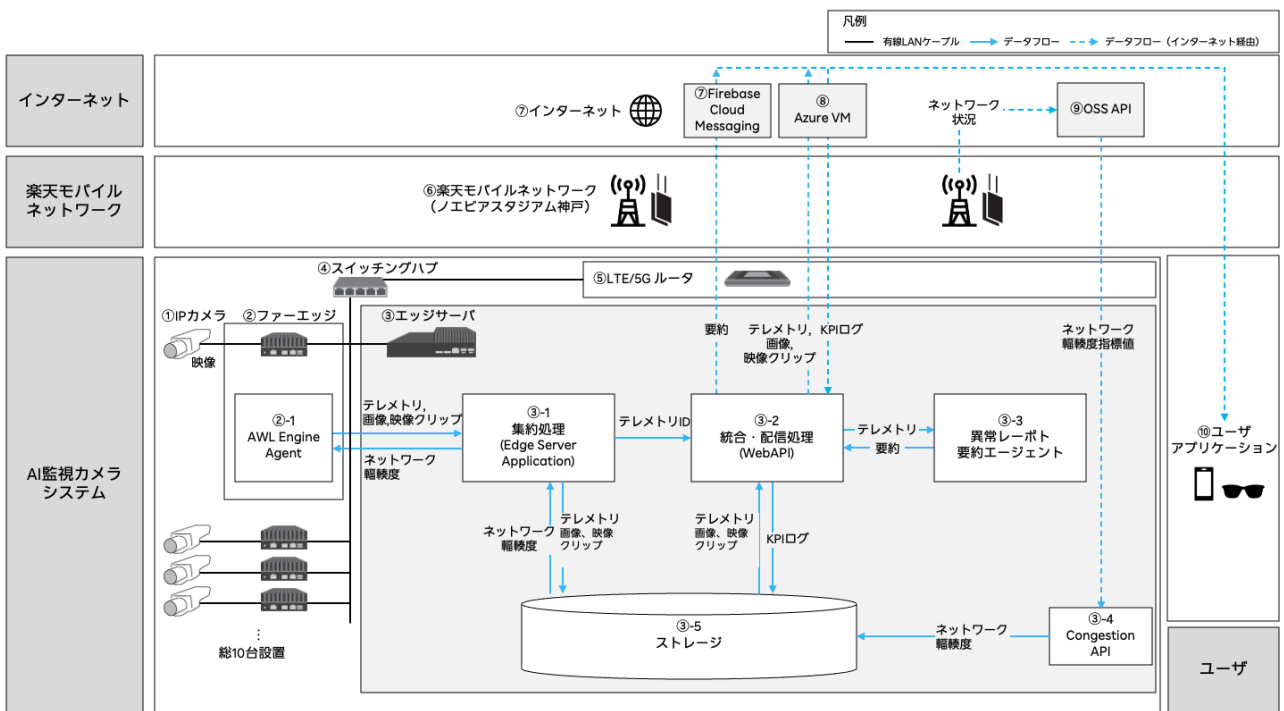


図 3.1-1 通信システムおよび AI カメラシステム構成図

表 3.1-1 システムコンポーネント一覧

項目	番号	コンポーネント	仕様
AI 監視システム	①	IP カメラ	10 台
	②	ファーエッジ	10 台
	③	エッジサーバ	1 台
	↳③-1	エッジサーバ Application	API
	↳③-2	統合・配信処理 (Web API)	API
	↳③-3	異常レポート要約エージェント	API
	↳③-4	Congestion API	API
	↳③-5	ストレージ	サーバストレージ
	④	スイッチングハブ	11 台
⑤	LTE/5G ルータ	1 台	
ネットワーク	⑥	楽天モバイルネットワーク	LTE
インターネット	⑦	Firebase Cloud Messaging	クラウドサービス

	⑧	Azure VM	クラウドサービス
	⑨	OSS (Operations Support System) API	API
ユーザ	⑩	ユーザアプリケーション	モバイルアプリ スマートグラスアプリ

- AI 監視カメラシステム

AI 監視システムは、①IP カメラの映像から侵入、マスク着用、火災などを検知する。映像データは②ファアエッジにてテキスト、クリップ画像、クリップ映像の形式に圧縮されておおよび③エッジサーバにて保存し、AI が集約した通知がユーザアプリへ送信される。また、⑨OSS から取得したデータに基づき、ネットワークの混雑を予測する。

- ①IP カメラ:10 台
- ②ファアエッジ:10 台
 - スタジアム内 IP カメラに接続してリアルタイムでカメラ映像を解析し、リスク状況を監視。リスク度とネットワーク輻輳に応じて、帯域幅に適した形式でデータを送信する。
- エッジサーバ:1 台
 - エッジサーバは複数のファアエッジから収集したデータを一元管理してユーザ端末に送信する仕組みを実現するため以下を搭載する。
- ③-1 エッジサーバ Application
- ③-2 統合・配信処理 (Web API)
- ③-3 異常レポート要約エージェント
- ③-4 ネットワーク輻輳度取得コンポーネント(Congestion API)
- ③-5 ストレージ
- ④スイッチングハブ: 11 台
 - LAN ケーブル中継用として設置する。
- ⑤LTE/5G ルータ:1 台(楽天モバイル回線)

- ネットワーク

ネットワークは、スタジアム既設の基地局および屋内スモールセルを利用する。

- ⑥楽天モバイルネットワーク

- インターネット

エッジサーバとユーザアプリの接続には、インターネット上のクラウドサービスを利用する。また、インターネット経由で OSS サーバに接続し、ネットワーク側の状況データを受信する。

- ⑦Firebase Cloud Messaging:送信側・受信側の OS を問わずプッシュ通知を低遅延で配信できる
- ⑧Azure VM:パブリック IP アドレスを持つ Azure VM 上のポートにフォワーディングすることにより、Azure VM 経由でユーザアプリケーションからアクセスできるようにする。
- ⑨OSS (Operations Support System) API:楽天モバイルネットワークのツールとしてネットワークの状態指標(ネットワーク KPI)を取得し、③-4 ネットワーク輻輳度取得コンポーネント(Congestion API)に送信する。

- ユーザ
 - ⑩ユーザアプリケーションは、エッジサーバから分析済みリスクイベントデータや画像をリアルタイム取得し、警備員へ通知する。

※前述の各システムのコンポーネントおよび機材の仕様等については、8.3「使用機器・ソフトウェア一覧」を参照。

3.2 通信システムおよび AI システムの設置場所

3.2.1 通信システムおよび送受信場所

本実証におけるネットワーク環境、およびエッジサーバからユーザへ通知を伝送した際の送信・受信場所を以下の図 3.2-1 に示す。

- LTE/5G 基地局
 - スタジアム外に既設の基地局を利用する。
- Indoor スモールセル(LTE)
 - スタジアム屋内に既設の Indoor 向けスモールセルを利用する。
- サーバの場所
 - サーバはノエビアスタジアムの1階に設置され、10台のカメラと有線LANケーブルで接続される。
 - また、サーバは屋内の Indoor スモールセルに繋がって各拠点のカメラでイベントが発生するとLTEルータを経由してユーザに通知を送信する。
- ユーザの場所
 - 本検証では、ユーザをヴィッセル神戸の警備員またはスタッフと定義し、ユーザの場所は試合日における各の業務担当者の位置を想定する。
 - また、試合日にネットワークの混雑が発生する可能性が高い場所として、南エンタランスのエリアを選定した。この場所は図 3.2-1 に示すようにスタジアムの外の基地局と連携される。



図 3.2-1 通信システムおよび送受信
「地理院地図」(<https://maps.gsi.go.jp>)を加工して作成

3.2.2 AI 監視カメラシステム設置場所

(1) AI 監視カメラ設置場所

図 3.1-1 で示した AI 監視カメラシステムの設置場所について以下の図 3.2-2 に示す。ノエビアスタジアム神戸の 1 階各場所に①IP カメラ 10 台とその近傍に②ファアーエッジデバイスを配置。①IP カメラおよび②ファアーエッジを一式とした各コンポーネントは、有線 LAN でエッジサーバに接続。本検証では配線を効率化するため、図 3 1 に示すように、④スイッチングハブを用いて比較的近いコンポーネントの LAN ケーブルを集約、最終的に 3 本のケーブルを介して③エッジサーバに接続する。

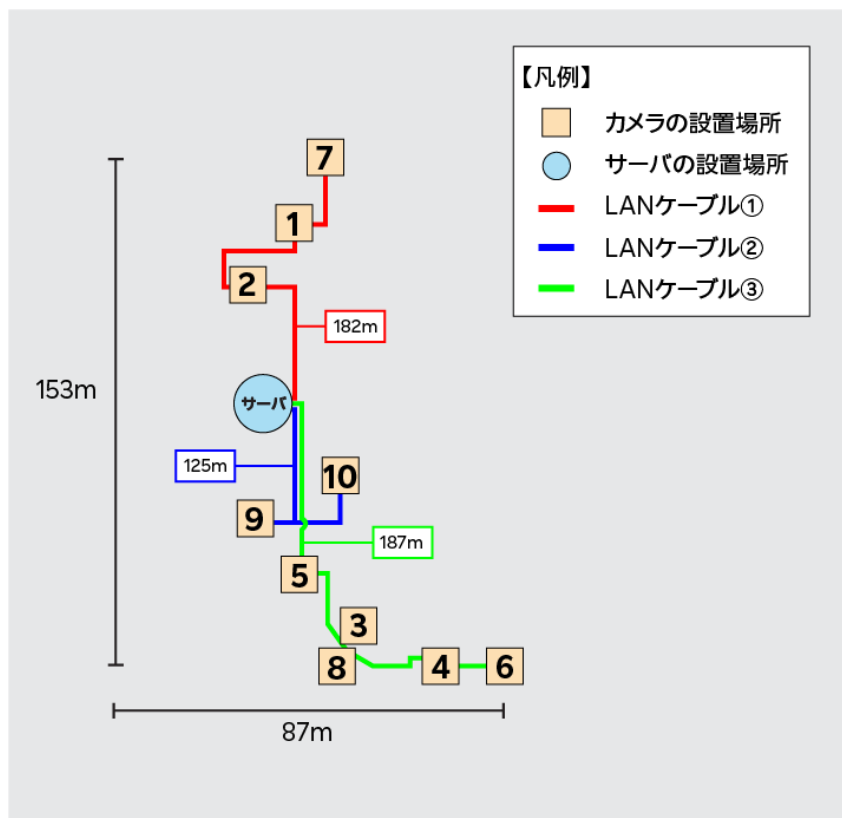


図 3.2-2 AI カメラ設置場所<※スタジアム内構成図はセキュリティ上公開不可>

(2) AI 監視カメラおよびサーバ設置写真

図 3.1-1 の AI 監視カメラシステムを構成するそれぞれのコンポーネントの実設置状況を写真とともに解説する。

- AI 監視カメラの写真を以下の図 3.2-3 に示す。

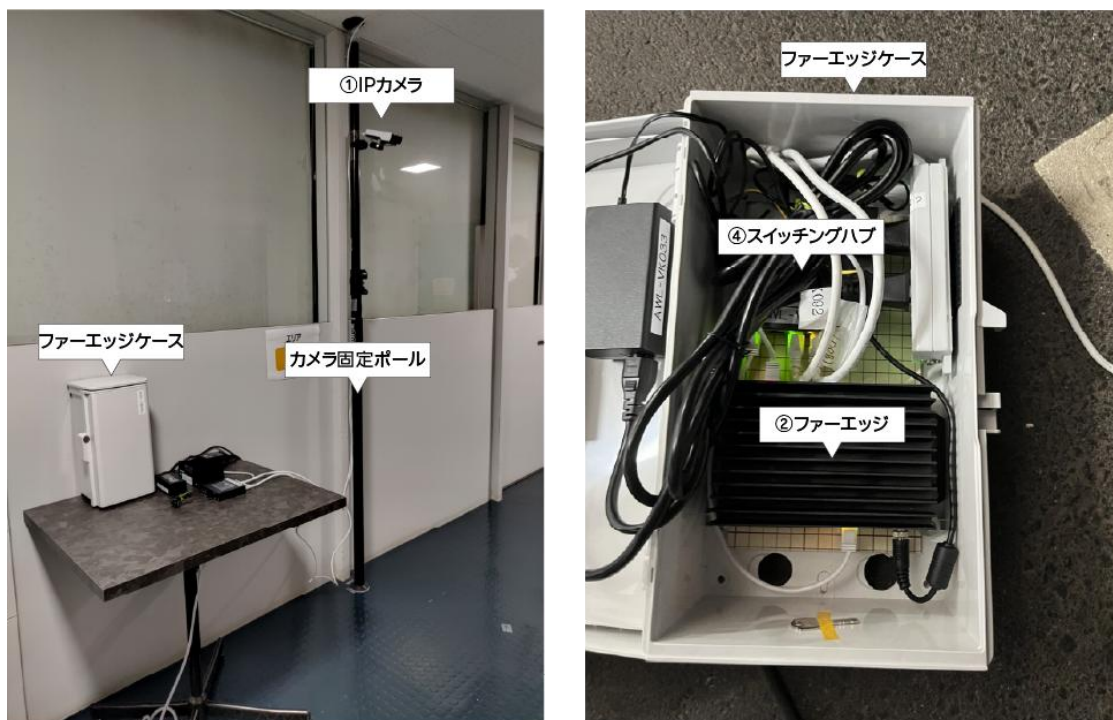


図 3.2-3 AI 監視カメラの写真

- エッジサーバの写真を以下の図 3.2-4 に示す。



図 3.2-4 エッジサーバの写真

(3) 設置場所の選定理由および監視エリア

本検証における AI カメラ設置場所の条件は、試合日であってもスタジアム内で原則人が立ち入らない箇所を想定している。設置場所は、サッカーの試合日にスタジアム外部および観客席からの侵入のリスクがある箇所を効率的に監視するために、選定した。また、エッジサーバは LAN ケーブルの配線作業が簡単簡易であり、集約場所に適している全域の中央に配置した。

本検証でノエビアスタジアム神戸内に設置した 10 箇所のカメラにより監視できたエリアの写真を以下の図 3.2-5 に示す。スタジアムのセキュリティ上、一部のエリアを除き、場所の詳細が特定できないよう画像処理を行う。



図 3.2-5 監視エリアの写真

3.3 通信システムおよび AI システムの構築・運用に要した費用

本検証中で構築した通信システムおよび AI システムの構築・運用に要した費用は以下の表 3.3-1 に示す。

表 3.3-1 AI 監視カメラ構築・運用の費用

コスト	中項目	番号	小項目	数量	金額(円)
初期導入	基地局の設置	-	不要	-	0
	AI カメラシステム (設備・機器費用)	①	IP カメラ	10 台	640,000
		②	ファアエツジ	10 台	1,120,000
		③	エツジサーバ(GPU 込み)	1 台	486,775
		④	スイッチングハブ(5 ポート)	10 台	45,859
			スイッチングハブ(8 ポート)	1 台	8,000
		⑤	LTE/5G ルータ	1 台	200,000
		-	機器収納ボックス	10 台	29,458

		-	カメラポールマウント	10台	154,168
		-	SDカード(映像保存)	10台	143,455
		-	LANケーブル(300m)	2個	103,960
運営	通信量	⑥	通信量	1年	40,000
	AIカメラシステム	⑦	Firebase Cloud Messaging	-	0
		⑧	Azure VM(クラウド)	1年	80,000
		-	ソフトウェアライセンス	1年	738,000
			合計		3,789,675

※表中 ①②③④⑤⑥⑦⑧は、表 3.1-1 において提示されているコンポーネント。

※設計・設置・運用に係る人件費等は別途必要

※記載の金額は実証中における参考価格であり実装時は諸条件に応じて大きく変動する可能性がある。

3.4 通信システムおよび AI システムの構築にあたっての留意事項等

3.4.1 有線 LAN ケーブルの選定時、長さが速度に影響

本検証では画像や映像の伝送において、安定性を確保するため 10Gbps まで高速伝送が可能な CAT.6A を選定した。一般的に、監視カメラなどの動画の高速伝送には、CAT.6A 以上の製品が推奨される。

ただし、CAT.6A は配線時、ケーブルの長さについて規格により制限が定められている。ケーブルが長くなるほど、電気信号は伝送中にエネルギーを失い、減衰する。通信エラーや速度低下の原因となるため、表 3.4-1 の通り、100m で制限される。ケーブルを 100m 以上に延長する際、図 3.4-1 に示すようにスイッチングハブやリピーターなどの機器を用いて信号を増幅・中継する必要がある。

本検証では、これらの条件を踏まえ、伝送距離が 100m を超える箇所ではスイッチングハブを用いて信号を中継した。接続後、映像データのアップロードおよびダウンロード時間を測定し、伝送の安定性を確保した。

表 3.4-1 CAT.6, CAT.6A, CAT.7, CAT.8 の違い

カテゴリ	最大伝送速度	最大帯域幅	最大ケーブル長	シールド	コネクタ
CAT.6	1 Gbps	250 MHz	55m (10G) 100m (1G)	UTP	RJ45
CAT.6A	10 Gbps	500 MHz	100m	UTP¹⁾/STP²⁾	RJ45
CAT.7	10 Gbps	600 MHz	100m	STP	GG23, TERA
CAT.8	25-40 Gbps	2000 MHz	30m	STP	RJ45

1) UTP : Unshielded Twisted Pair (シールド処理無し)

2) STP: Shielded Twisted Pair (シールド処理)




図 3.4-1 延長スイッチングハブの設置

4. AI モデルの開発・学習

4.1 AI モデルの全体像

動的な環境における公共の安全確保と運用効率の最適化に対する要請の高まりは、リアルタイムなデータ分析と知的な意思決定を可能にする革新的ソリューションを不可欠のものとしている。従来のビデオ分析システムは、過大な通信帯域幅要件、遅延の増大、拡張性の高い展開の難しさといった深刻な制約に直面する。これらの課題に対処するため、本実証では、可搬型ファアーエッジデバイスおよびエッジサーバへの展開を前提に設計した、堅牢なリスク検出と異常報告のための新しいインテリジェント警備監視システムを構築した。

本章では、当システムを支える中核的 AI アーキテクチャを詳述する。このアーキテクチャは、主に「① AWL Engine Agent」と「② AI 異常レポート要約エージェント」の二つの主要コンポーネントから構成される。図 4.1-1 に示すとおり、分散する監視映像データをファアーエッジで圧縮し、最後に単一のエッジサーバに集約することで、データ転送量を最小化し、インシデント検出を加速する。これにより、本システムの中核価値である高い可搬性と低通信量・低計算リソースでの運用を実現している。

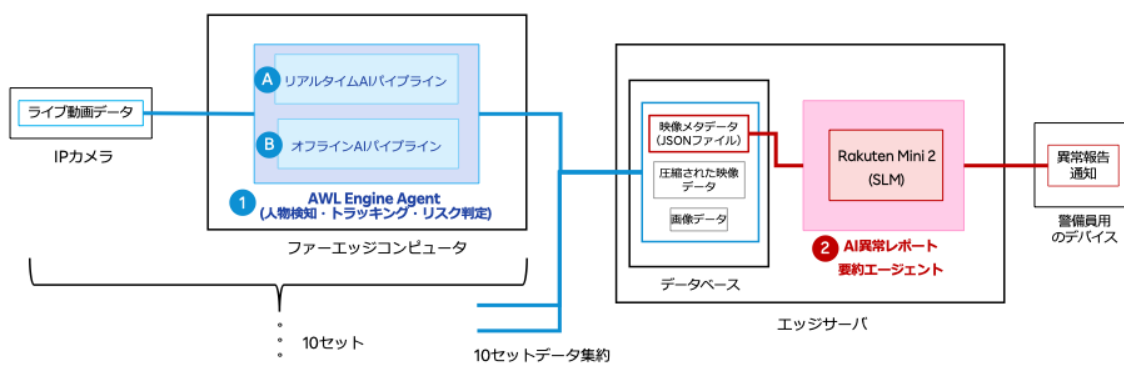


図 4.1-1 本検証のシステムにおいて AI モデルの全体像

以下に主要コンポーネントである「AWL Engine Agent」および「AI 異常レポート要約エージェント」について記載する。

① AWL Engine Agent:

即時の現場分析のために設計された多機能な AI 処理ユニットである。データソース上で直接、即時の検出とリスク評価を行う「リアルタイム AI パイプライン」(A)と、転倒・暴力・顔認識などの複雑なイベントに対する詳細な事後分析に特化した「オフライン AI パイプライン」(B)から成る。このローカル処理パラダイムは、ネットワーク負荷の軽減とタイムリーな知見の獲得に寄与する。

② AI 異常レポート要約エージェント:

小規模言語モデル(SLM)を搭載し、エッジサーバ上にホストされる「AI 異常レポート要約エージェント」は、中央インテリジェンスハブとして機能する。複数の AWL Engine Agent から送られる映

像メタデータを統合し、簡潔で実用的な異常報告へ要約する。要約通知は必要最小限の情報のみを警備用のアプリケーションに配信し、データ量の削減に加えて、緊急状況の即時把握を可能にする。

このように分散型と集中型の AI 機能を戦略的に組み合わせることで、当システムは高い拡張性と優れた運用効率を備えたフレームワークを実現する。本章では、各 AI コンポーネントの設計原則、アルゴリズム基盤、性能特性をさらに詳述し、本アーキテクチャが大規模な環境監視の課題に包括的に対処し、類似の環境および運用条件下で他地域へ容易に展開可能で、より安全な公共空間の実現に大きく寄与することを示す。

4.1.1 AWL Engine Agent (ファーフエッジ上のアプリケーション)

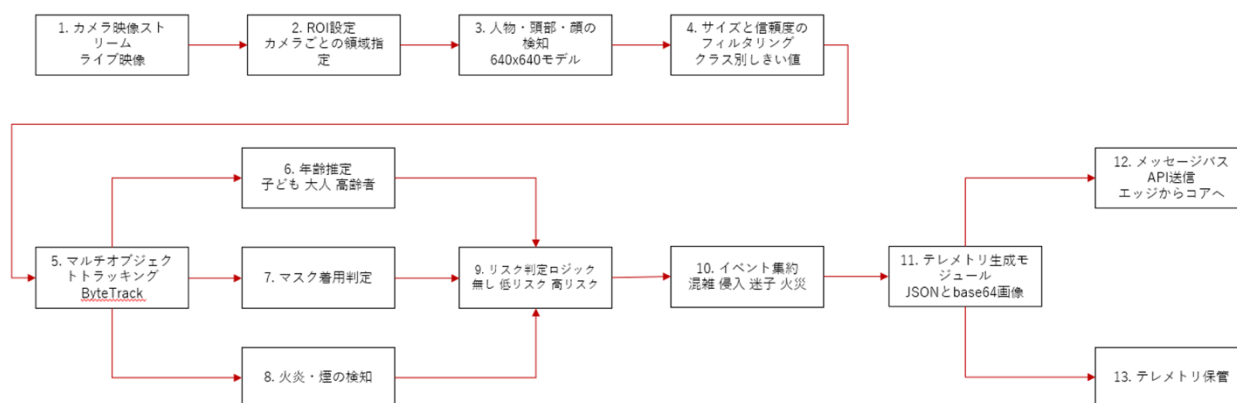


図 4.1-2 リアルタイム AI パイプライン

リアルタイム AI パイプライン(図 4.1-2 を参照)はファーフエッジ上でライブカメラ映像を処理し、人物検出・追跡・リスク分類を行う(ブロック 1-5, 9)。検出モデルは Qualcomm SNPE 実行向けに最適化された軽量 640×640 アーキテクチャを採用し、設定可能な閾値とバウンディングボックス制約に基づき成人・子ども・顔部・顔を識別する(ブロック 3, 4, 6)。

追跡には ByteTrack⁵のマルチオブジェクト追跡アルゴリズムを採用(ブロック 5)。交差率(IoU)ベースのマッチングとカルマンフィルタリング⁶を組み合わせることで、部分的な遮蔽下でも安定した連続的な追跡 ID を維持する(ブロック 5)。

検出と追跡の出力に基づき、システムはルールベースのロジックを適用し、イベントを「低リスク」または「高リスク」の各種タイプ(マスク着用、侵入時間、混雑、年齢推定、火災・煙検知など)に分類する(ブロック 7, 8, 9, 10)。このパイプラインは、検出の詳細、信頼度スコア、可視化されたフレームデータを含む統一されたテレメトリ出力を生成し、導入環境を問わず一貫した下流分析を可能にする(ブロック 11-13)。

⁵ ByteTrack:最先端のトラッカー(Zhang et al., 2022)は、二段階マッチング戦略を用いて検出スコアが弱いオブジェクトを復元する。

⁶ SORT アルゴリズム(Bewley et al., 2016)によって普及したデータアソシエーション手法であり、運動推定と境界ボックスの重なりをバランスさせる。

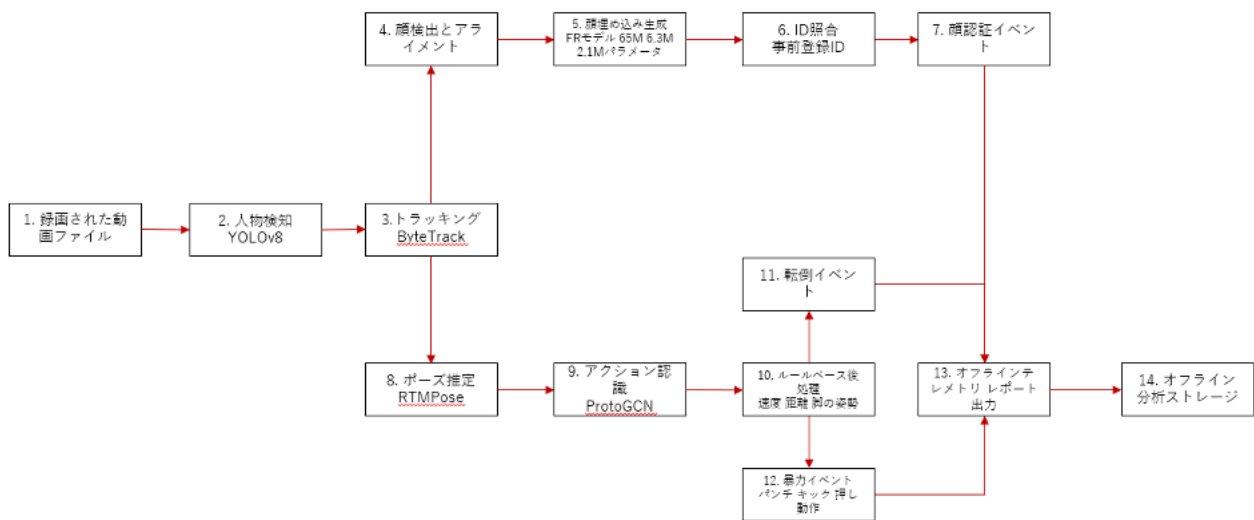


図 4.1-3 オフライン AI パイプライン

並行して、複雑な行動には深い時間的理解が必要なため、オフライン AI モデル(図 4.1-3 を参照)は記録映像を分析するよう設計された(ブロック 1)。転倒検知と暴力検知には多段階アーキテクチャを採用し、人物検知に YOLOv8⁷(ブロック 2)、身元保持追跡に ByteTrack(ブロック 3)、骨格キーポイント推定に RTMPose⁸(ブロック 8)、行動認識に ProtoGCN⁹(ブロック 9)を組み合わせている。

堅牢性を高め誤検知を防ぐため、ルールベースの条件を適用している(ブロック 10)。例えば、転倒検知は体がまっすぐ立てなくなった状態を示す脚の姿勢に限定し(ブロック 11)、またパンチ・キック・押し行為については特定の速度や距離の閾値を満たす場合のみ検知対象とする(ブロック 12)。これらの組み合わせ手法により、スタジアム環境に典型的な変動の激しいシーンにおけるモデルの信頼性が大幅に向上した。

顔認識モデルは、顔検出、追跡、位置合わせ、埋め込み、本人照合という構造化されたパイプラインに従う(ブロック 4-7)。当初、システムは認識性能を検証するために 6500 万パラメータのモデルを採用した(ブロック 5)。エッジ展開を支援するため、その後 210 万パラメータと 630 万パラメータの軽量代替モデルを評価した(ブロック 5)。いずれも対象人物の十分な認識精度を達成しつつ計算負荷を低減した。これにより、その他の地域でも、Qualcomm QCS シリーズデバイスを含む市販のエッジプロセッサ上で、認識信頼性を損なうことなく本システムを再現できる(ブロック 13-14)

4.1.2 AI 異常レポート要約エージェント

AI 異常レポート要約エージェントは、SLM¹⁰を用いた異常報告の要約タスクに特化したエージェント

⁷ Ultralytics 社が開発した最先端のリアルタイム物体検出モデル(Jocher et al., 2023)。様々なビジョンタスクにおいて速度と精度で知られる。

⁸ 低遅延でリアルタイムの複数人物キーポイント検出を目的として設計された高性能姿勢推定フレームワーク(Jiang et al., 2023)。

⁹ プロトタイプ学習を活用し、骨格ベースの動作認識のための微細な動きの詳細を捉える新規グラフ畳み込みネットワーク(Liu et al., 2025)。

¹⁰ 本実証で用いる SLM(小規模言語モデル)は LLM(大規模言語モデル)とは名称が異なるが、多くのオープン LLM で同じく、Transformer アーキテクチャで学習された言語モデルであり、動作原理は他の LLM と共通している。モデルサイズ・パラメータ数が一般的な

である。Web API アプリケーションに組み込み、エッジサーバ上で動作し、すべてのファアエッジから送信された異常イベントのメタデータ(人数、移動方向、滞在時間など)および定期集約データをプロンプトの一部として受け取り、それらを要約してレポートを生成する。

本エージェントで使用する SLM は「Rakuten AI 2.0 Mini」である。同モデルは 15 億パラメータの基盤モデルであり、実際にはインストラクションチューニング済みの「Rakuten AI 2.0 Mini Instruction」¹¹を採用した。インストラクションチューニングにより汎用的な指示理解能力を獲得し、コンテンツ要約、質問応答、各種テキスト生成タスクに対応可能である。さらに、本モデルは既に MT-Bench による日本語 LLM 評価を受けており、複数のインストラクションチューニング済み日本語対応オープン LLM と比較して高いスコアを獲得した(詳細は 6.2.2(9)2)a)を参照)。リソース制約環境向けのコンパクト設計により、幅広いハードウェアで低遅延なテキスト生成が可能であり、本実証に適した選択肢と考えた。

本実証における AI 異常レポート要約エージェントの開発・検証は、主に二つの手法に大別される。ひとつは、実証計画どおり追加学習を行わず、プロンプトエンジニアリングを中心に検証する手法であり、もうひとつは、異常報告タスクに特化させるために SLM をファインチューニングする手法である。

(1) プロンプトエンジニアリングを使用した手法:

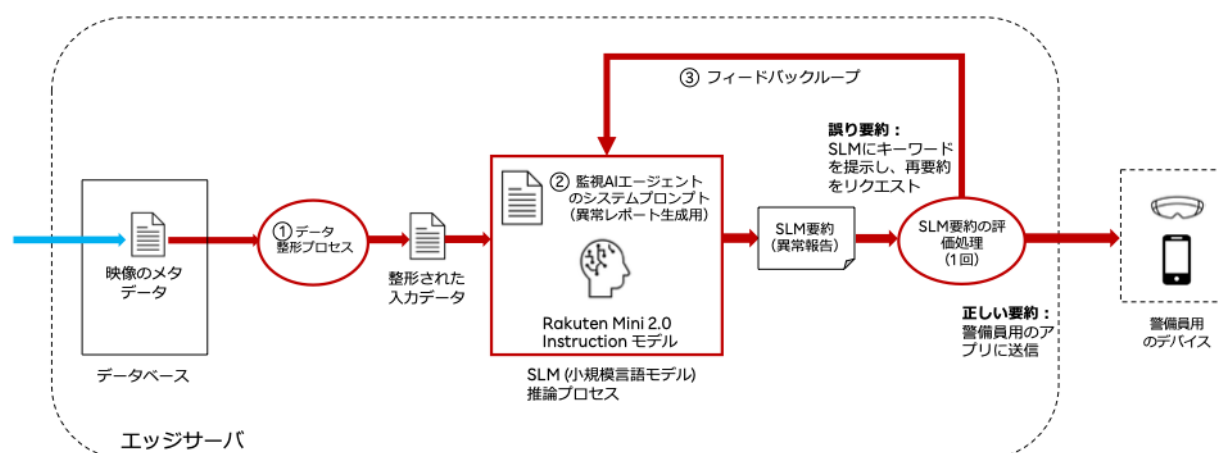


図 4.1-4 プロンプトエンジニアリングにより設計した AI 異常レポート要約エージェント

図 4.1-4 に本手法の概要を示す。本手法をスタジアムでの実証で用いた。主に以下の三つのプロンプトエンジニアリング手法により、SLM の要約精度を向上させた。

① 入力データの整形:

映像のメタデータを整形し、SLM に必要なデータのみを入力する。例えば、子どもが検知された場合、他の高齢者やマスクに関する属性情報を削除し、子ども属性のみを残すことで、LLM/SLM でしばしば見られる幻覚現象(ハルシネーション)の発生を抑制する。

LLM より小さく軽量化されているため、SLM と呼称している。本報告の文章に SLM と LLM を共に使用する場合がある。参考資料:[LLM の選び方-パラメータ数と性能から考える](https://zenn.dev/hellorusk/books/e56548029b391f/viewer/intro5):<https://zenn.dev/hellorusk/books/e56548029b391f/viewer/intro5>

¹¹ 出典:[Rakuten AI 2.0 Mini Instruction の公式サイト](https://huggingface.co/Rakuten/RakutenAI-2.0-mini-instruct):<https://huggingface.co/Rakuten/RakutenAI-2.0-mini-instruct>

- ② システムプロンプトの最適化:
- 条件分岐や計算が必要な推論は、入力前にデータ整形スクリプトで前処理し、SLM 側のシステムプロンプトにおける要約タスクのルールを簡素化する。
 - 複数の要約例(Few-shot prompting¹²)を提供することで、SLM が正しい要約を生成できるように誘導する。
- ③ フィードバックループ(反復プロンプト)の実装¹³:
- 簡易な要約評価機能を実装し、初期出力の異常レポート要約を、事実の正確性や書式ルールの遵守など事前定義した基準に照らして評価する。誤った要約が出力された場合は SLM にフィードバックプロンプトを入力し、再生成を要求する。無限ループを避けるため、試行回数に上限を設ける。

(2) SLM のファインチューニング手法:

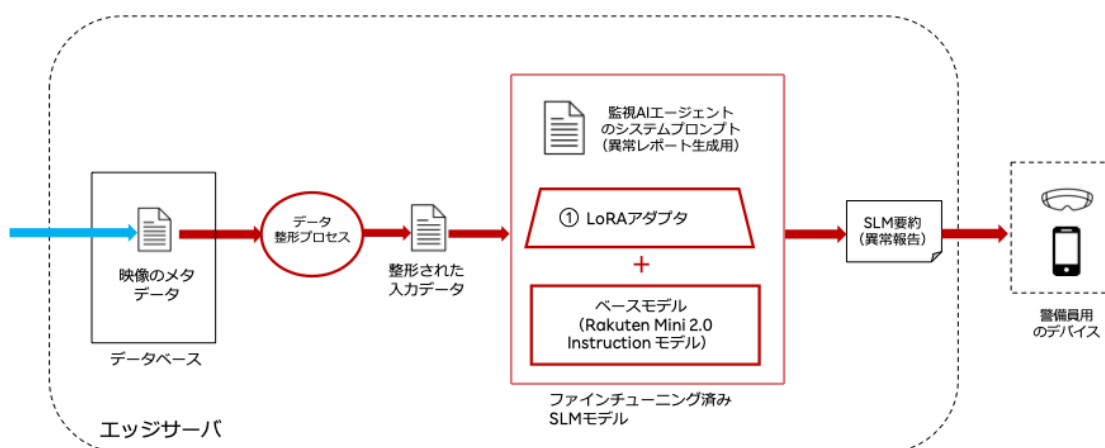


図 4.1-5 ファインチューニングのみの手法で設計した AI 異常レポート要約エージェント

上記の手法におけるループエージェントは、キーワードヒントの検索ロジックや全ての異常イベントケースを網羅的に点検する必要があるため、実装コストがやや高くなる課題があった。これに対し、十分な精度のファインチューニング済みモデルを提供することで、ループエージェントの実装を不要とすることが可能であると考えた。図 4.1-5 に本手法の概要を示す。

本 SLM のファインチューニングには、PEFT(Parameter-Efficient Fine-Tuning)の一種である LoRA(Low-Rank Adaptation)を採用した。Attention 層の重み行列(例:クエリ/バリューの行列 W_q, W_v)に対し、低ランク更新 $\Delta W = BA$ (A, B は低ランク ΔW 分解の学習可能行列)を適用して学習することで、学習すべきパラメータの増加を抑えつつ、ベースモデルと同等以上の性能を目

¹² Few-shot prompting : AI モデルにタスクの実行を指示する際に、複数の具体例(例)を提示することで、AI がタスクのパターンや出力形式を理解しやすくする手法 [参考資料リンク](https://www.promptingguide.ai/jp/techniques/fewshot) : <https://www.promptingguide.ai/jp/techniques/fewshot>

¹³ フィードバックループは反復プロンプト手法とループエージェントパターンを参考にして設計した機能。[参考資料リンク:①反復プロンプトプロセス:<https://docs.cloud.google.com/vertex-ai/generative-ai/docs/learn/prompts/prompt-iteration?hl=ja>, ②ループエージェントパターン:<https://docs.cloud.google.com/architecture/choose-design-pattern-agent-ai-system?hl=ja>]

指す¹⁴。今回は、特定タスク(異常レポート作成)への特化と計算資源・ストレージコストの節約を目的に本手法を選定した。しかし、推論時にはアダプタ由来のオーバーヘッドによりメモリ使用量が増える場合があり、実証環境ではベースモデル比で負荷が増加したため、本番運用では採用しなかった。したがって、本稿ではオフライン評価で得られた精度のみを提示する(詳細は 6.2.2(9)4)項参照)。

結論として、本実証における AI 異常レポート要約エージェントは、既存の軽量言語モデル(SLM)である「Rakuten AI 2.0 Mini Instruction」を基盤とし、独自のプロンプトエンジニアリングおよびフィードバックループ機構を実装することで開発された。本手法により、エッジサーバのリソース制約下において、日本語による異常報告の要約タスクを、低遅延かつ高いロバスト性で出力できる。一方、LoRAを用いたファインチューニングもオフラインテストで評価し、特定タスクへの適応能力を確認した。しかし、システム安定性の観点から、実証内容を達成するうえで最も効率的なのはプロンプトエンジニアリング手法と判断した。以上が AI 異常レポート要約エージェントのアーキテクチャおよびアルゴリズムの概要である。AWL Engine Agent が生成する監視映像メタデータを入力とする本 AI 要約エージェントは、可搬性の高いエッジシステムの一部としてデプロイしており、他地域や類似環境でも高い再現性が期待できる。

4.1.3 本実証 AI モデル全体像のまとめ

本システムの AI モデル設計は、効率的で拡張性が高くかつ技術的な透明性を備えたアーキテクチャを提供することで、異なる展開環境でも再現性のある導入、容易な保守、柔軟な拡張を可能にし、本実証の目的を満たしている。ファーエッジ AI パイプラインでは、軽量なリアルタイムモデルと高精度なオフラインモデルを組み合わせ、通信および計算コストを最小化しつつ検知精度を最大化する、バランスの取れたアプローチを実現した。さらに、AI 要約エージェントに軽量な SLM を導入することで、高性能なクラウド GPU に頼ることなく、オンデバイスで低遅延の要約推論を実行可能とした。これらのアプローチにより、本システムは本実証の要件を満たすうえで最も効率的な構成であると判断した。加えて、高い可搬性および通信データ削減の設計により設置場所や通信帯域の制約に左右されず、さまざまな地域・施設での持続的かつ実用的な導入を支援できる。

4.2 取得したデータ

4.2.1 取得したデータ一覧

表 4.2-1 に本システムで取得したデータ項目等を示す。

表 4.2-1 データ項目・用途等

項番	用途	データ取得機器名	稼働場所	データ項目	データ収集期間	データ形式
1	AI 評価・テストデータ(リアルタイム)	遠端デバイスカメラ(Axis M1135 Mk II ボックスカメラ)	ノエビアスタジアム神戸	リアルタイムリスクシナリオ用テスト動画	2025年6月15日から	MP4

¹⁴ 参考資料:①[LLM を効率的に再学習する手法\(PEFT\)を解説](#)、②[PEFT: Parameter-Efficient Fine-Tuning Methods for LLMs](#)

				<ul style="list-style-type: none"> ● 侵入 ● 群衆 ● 定期イベント ● マスク 	2025年 6月16 日まで	
2	AI 評価・テストデータ(オフライン)	遠端デバイスカメラ(Axis M1135 Mk II ボックスカメラ)	ノエビアスタジアム神戸	リアルタイムリスクシナリオ用テスト動画 <ul style="list-style-type: none"> ● 暴力 ● 転倒 ● 顔認識 	2025年 8月19 日から 2025年 8月20 日まで	MP4
3	AI 評価・テストデータ - 顔認識プロファイル	スマートフォンカメラ	個人	7人のプロフィール写真を収集した	2025年 6月20 日	JPEG
4	火災/煙トレーニングデータセット	公開データセット (DFireDataset, Kaggle 1 & 2, DFS_Fire_Smoke, T2I 経由の合成データおよび Deep Image Composition)		訓練用火災・煙画像		JPG/PNG
5	マスク検出 トレーニングデータセット	マスク検出用 AWL 内部データセット		マスク画像と非マスク画像		JPG/PNG
6	人物、頭部、顔検出 トレーニングデータセット	公開データセット(COCO など)+独自ラベリングデータセット		人物、頭部、顔のトレーニング画像		JPG/PNG
7	頭部方向データセット	内部頭部向きデータセット + 厳選されたスタジアムサンプル		頭部方向画像		JPG/PNG
8	SLM のファインチューニング用のデータセット	Macbook Pro	楽天モバイル社内オフィス	想定した映像メタデータとサマリテキスト	2025年 9月	JSONL ¹⁵
9	SLM の要約タスクを定義するプロンプト	Macbook Pro	楽天モバイル社内オフィス	SLM のシステムプロンプト	2025年 8月	TXT

4.2.2 データセット作成に係る処理

(1) AWL Engine Agent

本実証で使用したデータセットは、ノエビアスタジアム神戸にて現地収集した動画・画像データから作成された。楽天モバイルおよび AWL のスタッフは、AI モデル評価に必要な各種シナリオを積極的にロールプレイした。これらのシナリオはプロジェクト提案書で定義されたりリスクカテゴリーに対応し、侵入、群衆形成、転倒事象、暴力、行方不明者パターン、マスク着用/非着用行動を含む。顔認識評価用に追加データが収集され、7名の個人が本人確認登録用の横顔画像を提供した。

収集した全動画は、元の MP4(動画)および JPEG(画像)形式のまま取り込まれ、標準化されたデータセット作成ワークフローで処理された。このプロセスは表 4.2-2 に示すステップで構成される。

¹⁵ JSONL(JSON Lines)は、1行に1つの独立したJSONオブジェクトを記述するファイル形式である。大規模な学習データの形式として適している。

- データセット作成ワークフロー:

表 4.2-2 データ作成ワークフロー

No.	処理項目	内容
1	データ整合性検証	記録された各ファイルについて完全性を確認し、キャプチャ中にフレームの破損や不連続が発生していないことを保証した。
2	時間同期とメタデータ注釈	動画ファイルを記録タイムスタンプと整合させ、カメラ識別子、シナリオタイプ、参加者情報(匿名化済み)と関連付けた。侵入、群衆、暴力、転倒、通常行動の各シナリオカテゴリごとにメタデータラベルを付与した。
3	シナリオクリップへの分割	長時間の記録データを、効率的な評価を可能にするため、シナリオ固有の短いクリップに分割した。各クリップは単一の主要イベントタイプのみを含み、明確な正解データ(グランドトゥールズ・データ)参照を確保した。
4	品質フィルタリング	過度なモーションブラー、不十分な照明、またはアノテーションを妨げる遮蔽が存在するクリップを除外し、最低限の視覚的品質基準を満たすデータのみを採用した。
5	顔認識データセットの準備	顔認識用途として、携帯電話カメラで撮影した横顔画像を統一された解像度およびアスペクト比に正規化し、必要に応じて照明条件のばらつきを補正した。
6	データセキュリティと匿名化	全ての個人情報情報を削除し、顔認識 ID を仮名識別子に置き換えた。データセットは内部評価専用とし、外部への開示は行わない。

- データセット選定条件:

データセットが現実的なスタジアム環境を反映し、再現性のある AI 評価を支援するため、データ選定時には表 4.2-3 の基準を適用した。

表 4.2-3 データセット選定条件

No.	処理項目	内容
1	シナリオの信頼性	AWL および楽天モバイルのスタッフが、事前に定義されたシナリオに正確に合致する動作を行った記録のみを含めた。これにより、運用上のユースケースとの整合性を確保した。
2	環境の代表性	モデルの頑健性を検証するため、スタジアム内の様々な照明条件(日光、日陰のコンコース、屋内/屋外の混合照明、暗闇)にわたるデータを選定した。
3	対象物の明確な可視性	姿勢推定および追跡モデルが十分な視覚情報を受け取れるよう、最小バウンディングボックスサイズと非遮蔽閾値を適用した
4	シナリオのバランスある網羅性	評価時のラベルの不均衡を避けるため、侵入、群衆、暴力、転倒、通常の流れという全必須カテゴリに十分な分布が確保された。
5	顔認識要件	顔の特徴が明確に視認でき、遮蔽されていない(サングラス、マスク、極端な角度なし)横顔画像のみを埋め込み登録に使用した

- リアルタイム AI パイプラインのためのデータセット作成と利用:

リアルタイムパイプラインでは、ファーエッジデバイス上で直接、人物、頭部、顔、年齢、性別、マスク、火災・煙の検出を行うため、複数の AI モデルが使用された。各モデルは、スタジアム環境下での精度と堅牢性を確保するため、慎重に選定されたトレーニングおよび検証データセットに依存している。以下では、各コンポーネントに使用されたデータセットとデータ作成プロセスについて説明する。

- ① 人物・頭部・顔検出モデル




図 4.2-1 人物・頭部・顔検出の例

リアルタイムパイプラインで使用される人物・頭部・顔検出モデルは、公開データセットと独自にアノテーションを施したデータの組み合わせを用いて訓練された。これらのデータセットは多様な環境、複数の視点、様々な人間の姿勢を含み、開放的なスタジアム空間での信頼性の高い検出を保証する。スタジアムのカメラ高さや視野角への適合性を確保するため、データセット作成時には追加のフィルタリング閾値とバウンディングボックス制約が適用された。データセットの構成では、実運用で頻繁に遭遇する身体サイズの差異、頭部の可視性、部分的な遮蔽、照明の変化といった要素の変化を重視している。図 4.2-1 に人物・頭部・顔検出の例を示す。

② 火災・煙検知モデル

火災・煙検知モデルは、堅牢性を高めるため、公開データセットと合成生成画像の混合を用いて訓練された。訓練ソースは以下の通りである：

■ DFire-Dataset:

出典- <https://github.com/gaia-solutions-on-demand/DFireDataset>



図 4.2-2 DFire-Dataset の例

■ Kaggle の火災データセット



図 4.2-3 Kaggle の火災データセットの例

- DFS 火災・煙データセット - (出典 <https://github.com/siyuanwu/DFS-FIRE-SMOKE-Dataset>)




図 4.2-4 DFS-FIRE-SMOKE データセットのサンプル

- テキストから画像を生成する編集手法で作成された合成火災・煙画像
- Deep Image Composition を用いて作成された合成火災・煙画像。以下を含む：
 - 画像調和
 - 画像合成
 - ノエビアスタジアム神戸で撮影された背景画像を使用

合成生成技術を用いて、階段付近の煙、コンコースエリア、座席ゾーン、屋内と半屋外の境界部など、スタジアム特有の現実的な状況をデータセットに確実に反映させた。このスタジアム環境の合成は極めて重要である。一般的な火災データセットには、当該施設の構造、色彩、照明条件に合致するシーンがほとんど含まれていないためである。

③ 頭部方向推定

頭部方向モデルは、複数の角度(正面、左、右、下方など)にわたる頭部方位ラベルが付与されたデー

タセットを用いて訓練された。データセット作成時には、頭部が明確に視認でき姿勢が安定した画像のみが選択された。これにより、監視環境下で微妙な頭部動作が注意や意図の変化を示す状況において、視線方向を正確に推定するモデルの能力が向上した。

④ 児童の年齢・性別推定(頭部ベース)

児童の年齢・性別推定モデルは、様々な年齢層の児童の頭部クロップに焦点を当てたデータセットを用いて構築された。データセットのフィルタリングにより、クリーンで遮蔽されていないサンプルのみが使用され、分類の信頼性が向上した。年齢層はプロジェクトのリスクカテゴリー(例:行方不明児童検知のための10歳未満)に整合させた。

⑤ 成人年齢・性別推定(頭部ベース)

成人年齢・性別推定モデルは、複数の年齢層を代表する多様な成人データセットを使用し、通常の成人と高リスク高齢者カテゴリー(70歳以上)を区別した。評価サンプルは、照明や角度の変動にもかかわらず、主要な顔と頭部の特徴が一貫して可視化されるようフィルタリングされた。

⑥ マスク検出



図 4.2-5 マスク着用検出データセットの例¹⁶

マスク検出データセットは、「マスク着用」「マスク未着用」とラベル付けされた画像サンプルで構成され、部分的に覆われたマスク、不適切に着用されたマスク、着色されたマスクを含む。データセット作成では、Axis M1135 Mk II カメラで想定される条件に合致するよう、自然な遮蔽、スタジアムのような照明、様々なカメラ角度のサンプルを優先的に選択した。

- オフライン AI パイプラインのためのデータセット作成と利用:

オフラインパイプラインでは、転倒検知モデルと暴力検知モデルを、スタジアムの安全シナリオに最も関連性の高い動作パターンに合致するよう慎重に選別した公開動作認識データセットを組み合わせる訓練した。主に使用したデータセットは NTU RGB+D 120、Le2i および公開パンチングデータセット¹⁷である。

① 転倒と暴力の検出

NTU RGB+D 120 データセットの訓練データは、転倒、攻撃的な身体的接触、または一般的な姿勢

¹⁶ 出典:<https://www.kaggle.com/datasets/ashishjangra27/face-mask-12k-images-dataset>

¹⁷ 包括的な動作認識ベンチマーク。NTU RGB+D 120(Liu et al., 2019)、Le2i 転倒検出データセット(Charfi et al., 2013)、およびパンチング/暴力検出専用の公開データセットを含む。

変化に対応する動作のみを含むよう選択的にフィルタリングされた。完全なデータセットには 120 の動作カテゴリが含まれるが、その多くは安全監視とは無関係である(日常活動や物体との相互作用など)。したがって、以下の動作のみを含むサブセットが採用された:

- 急激なバランス喪失
- 倒れ込む動作
- パンチ、キック、押す動作
- 打撃動作
- 威嚇的または攻撃的なジェスチャー
- 座ったり立ったりする自然な動作



図 4.2-6 転倒および暴力検知の例

これらの選択されたカテゴリは、スタジアム環境における転倒や暴力のシナリオで発生する可能性が最も高い動作を反映している。

パンチング公開データセットでは、明示的にパンチングシーケンスとラベル付けされたサンプルのみを使用した。データセットに含まれる他の無関係な動作は除外し、ノイズを防ぎ、モデルが攻撃的な上半身の相互作用のクリーンな表現を学習できるようにした。

Le2i 転倒データセットは、日常的な屋内環境で捉えられた現実的な転倒パターンを提供するために組み込まれた。これらの映像クリップには、滑る、横倒しになる、前倒しや後倒しになるといったバリエーションが含まれており、モデルが様々な体型、衣服の種類、運動力学に一般化することを助ける。



図 4.2-7 転倒検知の例

安全検知に関連する動作パターンにデータセットを限定することで、オフライン動作認識モデルは焦点を絞った高品質なデータセットを用いて訓練された。このアプローチは誤検知を減らし、分類精度を向上させ、同様のオフライン解析パイプラインを導入する際の再現性を保証する。

(2) AI 異常レポート要約エージェント - SLM ファインチューニング用データセット

(ア) データセットの仕様

本データセットは、インストラクションチューニングのための教師あり微調整(SFT: Supervised Fine-Tuning)に用いる目的で作成した。学習には、パラメータ効率化手法(PEFT)の一種であるLoRA(Low-Rank Adaptation)を採用した。インストラクションチューニングは、「指示→応答」のペアデータを用いる SFT として実施した。本手法のデータセットは、モデルへの入力となる指示プロンプト(prompt)と、モデルが生成すべき正解出力(completion)のペアで構成されている¹⁸。

(イ) データフォーマット

学習データは、以下の構造を持つ JSON 形式の文字列として定義する。プロンプト部分は、Hugging Face のライブラリで一般的に用いられる指示(Instruction)形式のテンプレートに従う。以下はデータセットのフォーマットを示す:

```
data_entry = {
  "prompt": f"以下は、タスクを説明する指示と、さらなるコンテキストを提供する入力の組み合わせです。要求を適切に完了する応答を記述してください。" ¥
  f"### 指示:{system_prompt}" ¥
  f"### 入力:{input_data}" ¥
  f"### 応答:",
  "completion": completion_data
}
```

(ウ) 構成要素の詳細:

- ① system_prompt: SLM の役割や振る舞いを制御する指示文。実際の運用で用いるシステムプロンプトをそのまま使用する。タスクに応じて以下の2種類を使い分ける(実際のデータは8.4の参加資料に参照)。
 - (ア) 異常レポート要約用: 検知したリスクイベントを簡潔に要点報告させるためのプロンプト。
 - (イ) 定期レポート要約用: 15分ごとに定期的に監視対象エリアに異常がないことを報告するように設計した指示プロンプト。
- ② json_input_data: 映像解析システムから出力される JSON 形式のメタデータ、そして既に整形され、要約に必要な情報のみ(検知事象の種類、場所、詳細情報)残っている。
- ③ completion_data: モデルが生成すべき正解出力データである。system_prompt の指示に基づき、json_input_data の内容を正確に要約した文章とする。これがファインチューニングに

¹⁸ 参考資料:[LLM 開発の全体像:Pre-training から Instruction Tuning への道のり](https://note.com/ai_driven/n/nd13684b1de30):
https://note.com/ai_driven/n/nd13684b1de30

おける教師データとなる。

(エ) データセットの採用条件と具体例:

実際に JSONL ファイルのデータセットに保存した各 JSON オブジェクトは三つの変数 (prompt type json_input data, completion data) で、prompt type は相応のタイプに応じて「異常レポート要約用」または「定期レポート用」のシステムプロンプト(上記の system_prompt)に変換し、json_input data, completion data はそのまま上記の学習データのテキスト(data_entry)に反映する。また、JSONL ファイル内に採用する各データは、実際の運用シナリオに適すもの、入力と出力の整合性も取れている。

以下はイベント種別ごとのデータ作成例を示す。

① 異常検知(低リスクイベント):

```
{
  "prompt_type": "risk",
  "json_input_data": "{\"type\": \"single_person\", \"location_id\": \"area_6\", \"details\": {}}",
  "completion": "エリア 6 に人物が検知されました。"
}
```

- プロンプト種別(prompt_type): 異常レポート(後ほどの処理で異常レポート要約用のシステムプロンプトに変換する)
- 入力データ(json_input_data): {"type": "single_person", "location_id": "area_5", "details": {}}
- 正解出力データ(completion_data): エリア 6 に人物が検知されました。

② 異常検知(高リスクイベント - マスク):

```
{
  "prompt_type": "risk",
  "json_input_data": "{\"type\": \"single_person\", \"location_id\": \"area_2\", \"details\": {\"mask\": true}}",
  "completion": "エリア 5 にマスクを着用した人物が検知されました。"
}
```

- プロンプト種別(prompt_type): 異常レポート(後ほどの処理で異常レポート要約用のシステムプロンプトに変換する)
- 入力データ(json_input_data): {"type": "single_person", "location_id": "area_2", "details": {"mask": true}}
- 正解出力データ(completion_data): エリア 2 にマスクを着用した人物が検知されました。

③ 定期レポート:

```
{"prompt_type": "regular",
  "json_input_data": "{\"location_id\": \"area_1, area_4, area_5, area_6, area_7, area_8\"}",
  "completion": "エリア 1, 4, 5, 6, 7, 8:異常はありません。"}
```

- プロンプト種別(prompt_type): 定期レポート(後ほどの処理で異常レポート要約用のシステムプロンプトに変換する)
- 入力データ(json_input_data): ”{¥”location_id¥”: ¥”area_1, area_4, area_5, area_6, area_7, area_8¥”}
- 正解出力データ (completion_data): エリア 1, 4, 5, 6, 7, 8:異常はありません。

以上は、AI 異常レポート要約エージェントにおけるファインチューニング用データセットの概要と、その一部の例である。教師データである正解出力(completion)は、自ら設計したシステムプロンプトのルールに基づいて作成した。したがって、あらゆる異常イベントおよび多数の定期レポートのバリエーションを網羅するデータセットを生成でき、効果的な追加学習(ファインチューニング)を容易に行える。

4.2.3 システム全体のデータフロー図

(1) システム全体のデータフロー図:

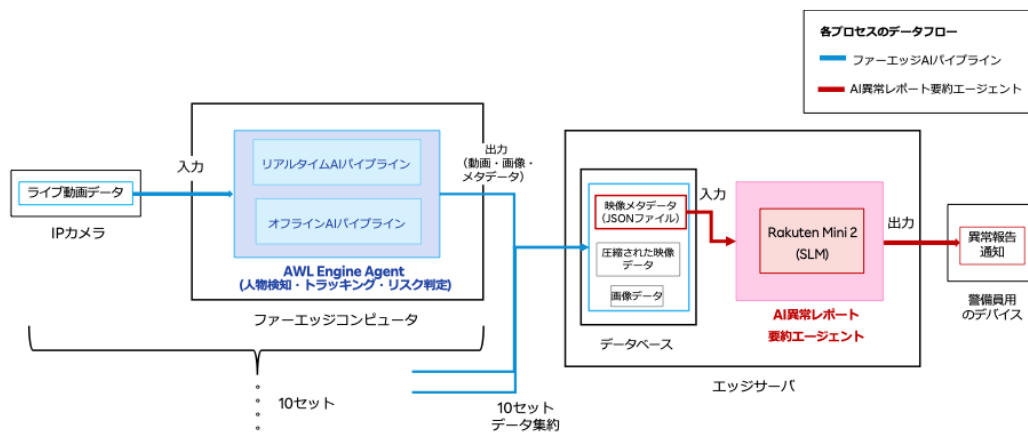


図 4.2-8 本実証システム全体のデータフロー

図 4.2-8 は、AI モデルプロセスを基に簡略化したデータフローとシステムアーキテクチャを示す。青の矢印はファァーエッジ AI パイプラインのデータフロー、赤の矢印は AI 異常レポート要約エージェントのデータフローを表す。なお、以下に両 AI コンポーネントの内部データパイプラインの図と説明を示す。

(2) AWL Engine Agent のデータフロー図:

(ア) リアルタイム AI パイプライン




図 4.2-9 リアルタイム AI パイプラインのデータフロー



図 4.2-10 リアルタイムのマスク着用を推定する

図 4.2-9 に示したリアルタイムパイプラインは、スタジアムのカメラで撮影された各入力画像を一連のオンデバイス AI モジュールで処理し、すべての検知とリスク評価をファーエッジデバイス上でローカルに実行する(ブロック 6, ブロック 1-5, ブロック 7)。フレームを受信すると、同時に 2 つの主要検知分岐にルーティングされる:1 つは人物・頭部・顔検知用、もう 1 つは火災・煙検知用である(ブロック 1, ブロック 7)。

人物・頭部・顔検出ブランチは、視認可能な全個人とその対応する関心領域を識別する(ブロック 1)。一方、火災・煙ブランチは、煙の柱や火などの危険をフレームから独立して評価する(ブロック 7)。

人物検出ブランチの出力は、フレーム間で同一性を保持し、滞在時間の計算や移動の連続性といった時間的推論を可能にするマルチオブジェクト追跡モジュールを通過する(ブロック 2)。追跡対象となる各人物について、追加の分類器が検出された頭部または顔領域に基づき、頭部の方向、年齢層(子どもか大人か)、マスク着用状況を推定する(ブロック 3, ブロック 4, ブロック 5)。

一方、火災・煙検出結果は即時高リスク事象と指定されているため、並行してテレメトリ段階へ直接転送される(ブロック 7, ブロック 8)。

全ての推論段階が完了すると、パイプラインは人物検出結果、人口統計推定値、頭部方向、マスク着用状況、火災・煙検知結果を統合し、バウンディングボックス、イベントカテゴリ、信頼度スコア、オプションの Base64 エンコード画像を含む統一テレメトリメッセージを生成する(ブロック 8)。

デバッグと監視を支援するため、システムは検出結果とイベント情報をオーバーレイ表示した注釈付きフレームも生成する(ブロック 9)。これはオペレータが閲覧できるようビジュアライザーに渡される(ブロック 10)。

このパイプライン設計により、フルビデオストリームではなくコンパクトなテレメトリのみがサーバに送信されるため、リアルタイムの状況認識を維持しつつ通信負荷を大幅に削減できる(ブロック 8-10)。

(ア) オフライン AI パイプライン

- 顔認識フロー




図 4.2-11 オフライン AI パイプラインのデータフロー (1): 顔認識フロー

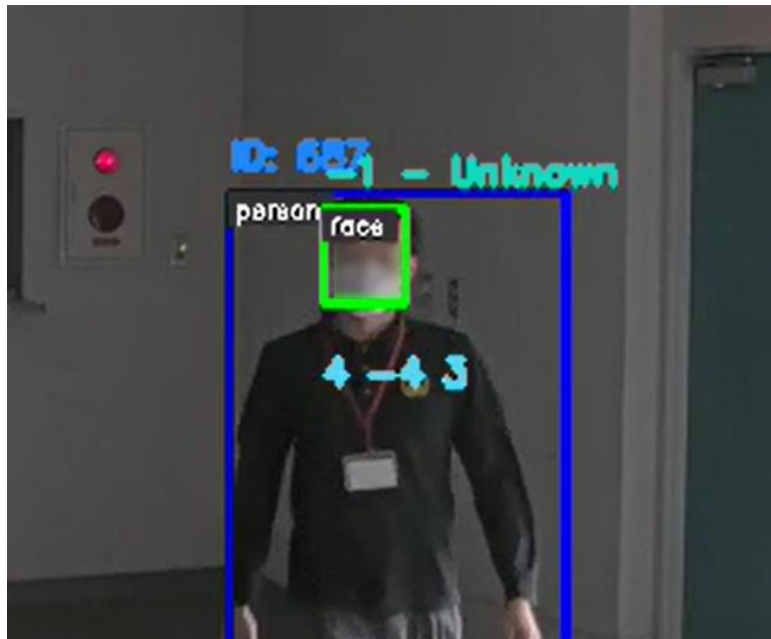


図 4.2-12 オフラインの顔認識

図 4.2-11 に示した顔認識パイプラインは、スタジアム環境下での信頼性の高い識別を確保するため、各入力動画フレームを一連の緊密に連携したモジュールで処理する(ブロック 1)。フレームを受信すると、システムはまず顔検出モデルを適用し、視認可能な全顔領域を特定して各候補顔に境界ボックスを生成する(ブロック 2)。これらの検出結果はトラッカーに渡され、連続フレーム間で顔を関連付けて安定した識別追跡を維持し、冗長な処理を削減する(ブロック 3)。

追跡対象の各顔には、最小サイズ、アスペクト比、明るさ、鮮明度などの社内フィルタリング条件が適用され、低品質または信頼性の低いサンプルを排除した上で下流工程へ進む(ブロック 4)。残った高品質な追跡データは顔ランドマーク検出モジュールに渡され、目・鼻・口の周囲から精密なキーポイントを抽出する(ブロック 5)。これらのランドマークは後続の頭部姿勢推定プロセスを支え、顔が正面向きか斜め向きか、あるいは認識に不向きな状態かを判定する(ブロック 6, ブロック 7)。

続いて、検出されたランドマークと姿勢情報を使用して顔アライメントを実行し、正確な埋め込み抽出に適した一貫した向きに各顔を正規化する(ブロック 8)。このアライメント工程により、様々な頭部角度、照明条件、カメラ視点にわたる均一性が確保される。アライメント後、顔は顔埋め込みモデルに投入され、各顔トラックに対して数値ベクトル表現が生成される(ブロック 9)。これらの埋め込みデータはトラック ID(人物識別子)と組み合わせられ、マッチングモジュールに送られる。マッチングモジュールでは、既存の既知埋め込みデータギャラリーとの比較が行われる(ブロック 10)。マッチングモジュールは類似性閾値に基づいて個人を識別するか、新規または改良された埋め込みデータが利用可能な場合にギャラ

リーを更新する(ブロック 10)。

このプロセス全体を通じて、パイプラインは最終的な姿勢ベースのフィルターを適用し、認識やギャラリー更新に高信頼性の正面向きのサンプルのみが使用されるようにする(ブロック 7, ブロック 10)。検出、追跡、ランドマーク設定、姿勢推定、位置合わせ、埋め込み抽出、適応型マッチングを組み合わせたこの多段階アプローチにより、照明、動き、群衆密度が変化する動的なスタジアム環境においても、堅牢な顔認識が可能となる。

○ 転倒および暴力検知フロー

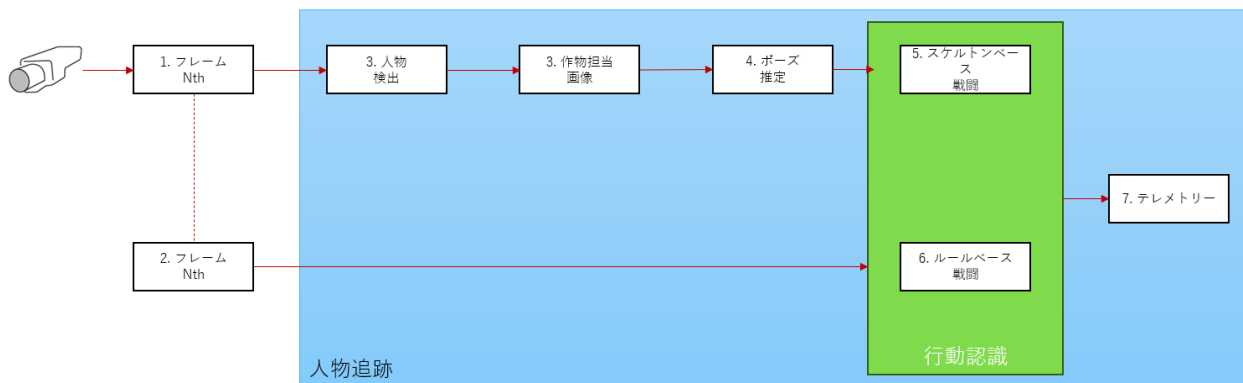


図 4.2-13 オフライン AI パイプラインのデータフロー (2): 転倒および暴力検知フロー



図 4.2-14 転倒の参考図



図 4.2-15 暴力検知の参考図

図 4.2-13 に示した転倒と暴力検知パイプラインは、人物追跡、姿勢推定、動作認識を統合したワークフローにより連続する動画フレームを処理する(ブロック 1, ブロック 2, ブロック 3-6)。スタジアムに設置したカメラが捉えた各フレームに対し、システムはまず人物検出を行い、視認可能な全個人を特定する(ブロック 3)。検出された人物領域は切り取られ追跡モジュールに渡され、フレーム間で同一性を維持する(ブロック 3)。これにより動きを孤立したスナップショットではなく時間軸に沿って分析可能となる。

これらの追跡対象人物領域を用い、姿勢推定モジュールは各個人の四肢・胴体・頭部の構造的構成を捉える人体骨格キーポイントを生成する(ブロック 4)。これらのキーポイントは下流の動作認識段階の基盤となり、二つの補完的アプローチを統合する。グラフベースニューラルモデル(ProtoGCN)を用いた骨格ベース動作認識(ブロック 5)と、関節速度・骨間距離・姿勢遷移などの運動手がかりに依存するルールベース動作分類である(ブロック 6)。

骨格ベースの推論は攻撃的行動や転倒行動の高次時系列モデリングを提供する一方、ルールベースのロジックはドメイン固有の閾値を適用することで誤検知を低減する(ブロック 5, ブロック 6)。例えば転倒には脚折り曲げの最小基準値、パンチやキックには手首・足首速度の閾値を設定する。

両認識経路からの出力は統合され、テレメトリモジュールに転送される(ブロック 7)。同モジュールは動作タイプ、信頼度、タイムスタンプ、影響を受けたトラック ID を含む構造化イベントレポートを生成する。この設計により、システムは学習済み動作パターンと明示的行動ルールの両方を活用し、複雑なスタジアム環境における正常な動作、転倒イベント、暴力的な相互作用を確実に区別し、精度と堅牢性を最大化する。

(3) AI 異常レポート要約エージェントのデータフロー図:

4.1.2 項と同様に、AI 異常レポート要約エージェントについては、プロンプトエンジニアリング手法とファインチューニング手法に分けて説明する。本節では、データフローを中心に、各データ処理プロセスの詳細を解説する。

(ア) プロンプトエンジニアリング手法による AI 要約エージェントのデータフロー:

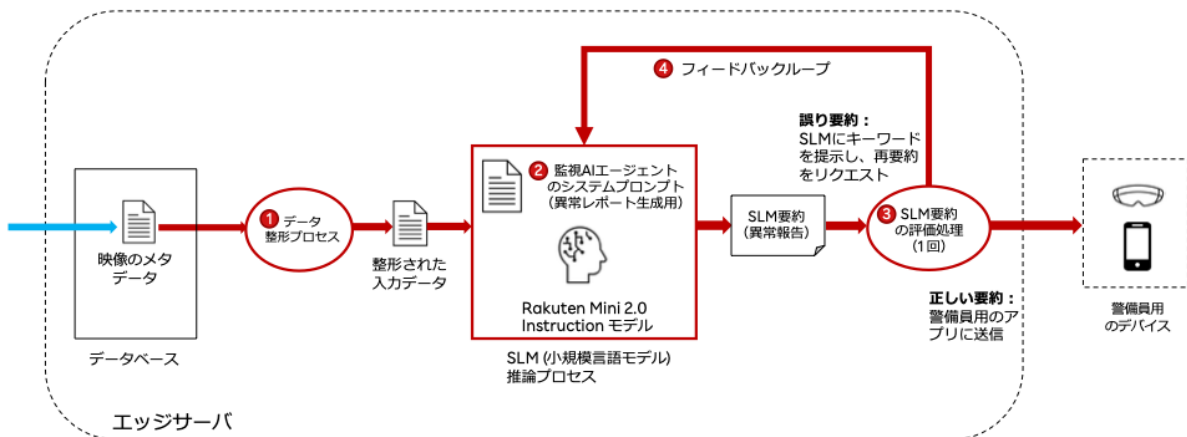


図 4.2-16 プロンプトエンジニアリング手法による異常レポート生成のデータフロー

図 4.2-16 では実証実験で実際に使用したプロンプトエンジニアリングを主とするアプローチを示す。既存の SLM「Rakuten AI 2.0 Mini Instruction」をそのまま使用し、プロンプトエンジニアリング(入力データの整形、システムプロンプトの最適化、フィードバックループ)のみで異常レポートの要約精度の向上を図る。以下に、図 4.2-16 に付与された番号順にデータフロープロセスとその説明を記述する。

① データ整形プロセス:

AWL Engine Agent がデータベースに保存された映像メタデータを取得し、必要な情報のみを抽出するとともに、条件分岐や計算が必要な処理もこの段階で実施する。整形済みデータを入力プロンプトとして SLM に与える。

② SLM 推論プロセス:

前述の処理で得た整形済みデータをプロンプトとして SLM に与え、異常報告の要約文を生成する。SLM に適用するシステムプロンプトは、整形済みデータに合わせた簡易なルール指示と複数の要約例で構成する。

③ 要約の評価プロセス:

SLM が生成した異常報告の要約文は、ユーザアプリケーションへ送信する前に評価プロセスで検査する。評価指標として、所定の異常イベントに対応するキーワード(例:マスク、10 秒以上、70 歳以上など)および場所名が要約文に含まれているかを確認する。

④ フィードバックループ:

要約の評価プロセスで誤りが確認された場合は、フィードバックループに移行し、映像メタデータとの不一致箇所を明示したヒントプロンプトを付与して再要約を要求する。以下に例を示す:

- 入力映像メタデータ例(JSON 形式):

```
{
  "type": "single_person",
  "location_id": "area_7",
  "details": {"mask": true}
}
```

- 正解の要約例:

「エリア 7 にマスクを着用した人物が検知されました。」

- 実際に生成された誤りの要約: (ハルシネーション)

「エリア 1 に 10 歳未満と見られる人物が検知されました。」

- ヒントプロンプト例:

「JSON データに mask が true です。「マスクを着用した」の情報を入れて再要約してください。」

上記のヒントプロンプトを SLM に入力し、再要約をリクエストすることで、正しい要約を得られる。なお、無限ループを防ぐため、リトライ回数は 1 回に制限する(2 回以上は効果が薄く、1 回が最も効率的と判断している)。最後に、評価を通過した要約は、ユーザアプリケーションの異常報告通知として送信する。

(イ) ファインチューニング手法による AI 要約エージェントのデータフロー:

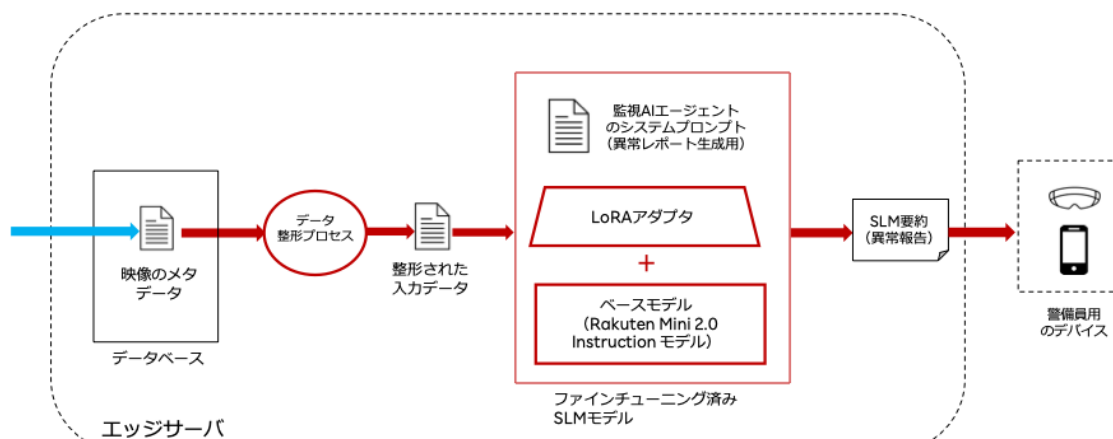


図 4.2-17 ファインチューニング手法による異常レポート生成のデータ処理フロー

図 4.2-17 は、本実証の予備的手法として、ファインチューニング済み SLM を用いて異常レポートの要約を生成するエージェントのデータフローを示す。図 4.2-16 に示したプロンプトエンジニアリング手法のデータ整形工程と SLM の推論プロセスを維持しつつ、フィードバックループを省略することで実装を一層簡素化した。本手法は十分な精度が見込めると判断したため、SLM が要約文を出力し次第、直ちにユーザアプリケーションへ送信する運用とした。一方で、4.1.2 項で述べたとおり、当該ファインチューニング済み SLM はベースの SLM に比べてエッジサーバへの処理負荷(アダプタ適用に伴うメモリオーバーヘッド)が大きく、平均約 5 分間隔でクラッシュが多発したため、本番運用では採用しなかった。なお、プロンプトエンジニアリング手法のみで運用した場合は、短時間に多数の推論が発生しない限り同様の問題は観測されなかった。

4.2.4 データの適切さ

(1) AWL Engine Agent

本実証のために収集したデータは、リアルタイムおよびオフラインの両パイプラインで使用される AI モデルの性能、頑健性、再現性を評価するのに適切かつ十分であると考えられる。なぜならば、本データセットはノエビアスタジアム神戸における現実的な運用条件を反映し、侵入検知、群衆識別、転倒・暴力認識、顔認識を検証するために必要な全シナリオを網羅している。代表性と適切性に関するデータセットの妥当性は以下の点に要約される。

第一に、本データセットはシステムが稼働する実際の環境を代表している。全てのリアルタイムおよび

オフライン試験動画は、本番構成で導入されているのと同様の Axis M1135 Mk II カメラを用いて、ノエビアスタジアム神戸内で直接記録された。これにより、照明条件、カメラ角度、背景構造、視認距離が実際の運用環境とほぼ一致することが保証される。これらの環境要素は検知精度と追跡精度に強く影響するため、実際の導入条件下でデータを取得することは、評価結果の関連性と信頼性を高めることに繋がる。

第二に、本データセットはプロジェクト提案書の AI パイプライン仕様で要求される全ての重要シナリオカテゴリを含み、各イベントタイプの十分なカバレッジを確保している。リアルタイム評価データには侵入検知、群衆形成、通常背景活動が含まれ、オフライン評価データには転倒イベント、複数種類の暴力行為(パンチ、キック、押し)、顔認識シナリオが含まれる。このバランスの取れたシナリオタイプ構成により、特定のイベントクラスへの偏りなくモデル評価を徹底的に行える。さらに、楽天モバイルと AWL の担当者がロールプレイしたシナリオを使用することで、データセットが現実的な人間の動きや相互作用を反映し、実用的な妥当性をさらに強化している。

第三に、本データセットは全カテゴリにおいて十分な視覚的明瞭性と測定可能な真値を提供する。選定された動画クリップは、被写体可視性、バウンディングボックスサイズ、非遮蔽性に関する最低閾値を満たしており、人物検出、追跡、姿勢推定、行動認識の正確な検証を可能にする。顔認識プロフィール画像は携帯電話カメラを用いて制御された条件下で撮影されており、識別用に使用される顔埋め込みが複数のテスト動画間で安定かつ一貫していることを保証する。

第四に、本データセットは再現性と比較可能性に十分対応している。収集期間(リアルタイムイベント: 2025年6月15日~16日、オフラインイベント: 2025年8月19日~20日)は、複数回にわたる変動性を捉えつつ、将来の展開や追跡評価における結果再現を可能にする十分な制御性を確保している。標準フォーマット(動画はMP4、プロフィール画像はJPEG)の使用は、システムの再現を望む他の地域やインテグレーターによる再処理、再アノテーション、再評価を容易にする。

最後に、本データセットはモデル堅牢性テストの要件を満たす。スタジアム内の環境変動(屋内対半屋外エリア、日陰のコンコース、自然光の変化)は、異なる照明条件下でのモデル安定性評価を可能にする。低強度動作(ゆっくり歩行、静止)と動的動作(走行、転倒、押す動作、急なジェスチャー)の両方を包含することで、姿勢推定と動作認識に対する意味のある負荷条件を提供する。

以上の観点から、本データセットは本実証で使用される AI モデルの精度、再現性、運用可能性を検証するのに十分であると判断される。システム性能評価のための現実的で均衡の取れた再現可能な基盤を提供し、同等の条件下にある他の地域への展開を可能にするという広範な目標を支援する。

(2) AI 異常レポート要約エージェント

本実証では、既存の SLM「Rakuten Mini 2.0 Instruction」を使用した。Rakuten Mini 2.0 の基盤モデルは、内製の多段階データフィルタリングとアノテーションプロセスを通じて構築された高品質で多様な日本語・英語のテキストデータによりゼロから学習されている。実証で使用するインストラク

シオンチューニング済みモデルは、指示形式データで基盤モデルをファインチューニングしたものである。

一方、予備的手法では、上記インストラクションモデルを本実証の要約タスク向けにさらにファインチューニングした SLM を作成した。学習用データセットは 4.2.2 項で述べたとおり、システムプロンプトで定義した異常要約ルールに即した簡潔・可読かつ正確な例で構成されており、当該タスクに適合すると考えられる。また、データセットはすべて自作で、要約例も本実証専用の内容であるため、著作権侵害や個人情報を含むことによるプライバシー上のリスクは低く、倫理的観点からも適切と判断できる。

4.3 AI モデルの学習プロセス

4.3.1 AWL Engine Agent

本実証では、対象環境への適合性と他の地域での再現性を確保するため、複数の AI モデルを評価・適応・部分的な再学習を行った。学習プロセスはモデルカテゴリ(エッジデバイスに展開されるリアルタイムモデル、転倒検知・暴力検知・顔認識に用いられるオフラインモデル)によって異なった。

リアルタイム検知モデル(人物、頭部、顔検知)については、主に Qualcomm SNPE 実行向けに最適化された事前学習済みモデルに依存した。実証期間中に完全な再学習は行われなかったが、閾値パラメータ、フィルタリングルール、ROI 設定は現場検証結果に基づき反復的に調整された。これらの調整は GPU を用いた再学習を必要とせず、エッジデバイス上でのパラメータ調整によって完了した。

オフラインモデルでは、転倒検出と暴力検出のパイプラインに、キーポイント推定用に RTMPose を、動作認識用に ProtoGCN を採用した。これらのモデルは各研究機関が提供する事前学習済みモデルに基づいている。実証実験では、完全な教師あり再学習を行わず、これらの事前学習済みモデルを流用した。ただし、速度閾値、姿勢制約、相互作用に基づくルールを含む後処理ロジックは、実証現場で収集した動画を用いて複数回の評価サイクルで改良を加えた。

顔認識パイプラインは最も大幅なモデル適応が行われた。6500 万パラメータのベースラインモデルと、210 万パラメータおよび 630 万パラメータの軽量モデル、計 3 つの顔認識モデルが評価対象となった。軽量モデルは、スタジオ照明、動き、カメラ配置条件下での頑健性を検証するため、実証サイトの動画データでテストされた。基盤となるネットワーク重みは事前学習済みであったが、誤検知を減らし認識精度の一貫性を確保するため、マッチング閾値と埋め込み正規化戦略は実証中に微調整された。

本プロジェクトでは大規模なラベル付きデータを用いた本格的な教師あり学習を含んでいなかったため、この実証実験中にエンドツーエンドの GPU トレーニングセッションは実行されなかった。透明性と将来の再現性を考慮し、後続フェーズで追加の微調整が実施される場合に備え、トレーニング関連パラメータのプレースホルダーを以下に示す：

- トレーニングに使用した GPU 仕様:NVIDIA GeForce RTX 2080 Ti 4 基、NVIDIA A100 1 基
- トレーニング期間:リアルタイムモデルとオフラインモデル合わせて合計 3 日間

全体として、本デモは計算負荷の高いトレーニングではなく、モデル評価、パラメータ調整による適応、実運用環境下での検証に主眼を置いた。このアプローチは、大規模なトレーニングインフラを必要とせず、地域異なる間で再現可能な AI 展開を実現するというプロジェクト目標に沿うものである。

4.3.2 Rakuten Mini 2.0 のファインチューニングプロセス

効率的な開発のため、生成 AI や LLM 推論ワークロードに適した NVIDIA H100 を使用した。学習は、フルファインチューニングではなく LoRA (Low-Rank Adaptation) を採用し、一部パラメータのみを更新して事前学習済みモデルの汎用知識を保ったまま特定タスクへ適応させた。

LoRA は計算コストと GPU メモリ使用量を大幅に削減でき、学習時間も短縮できる。ただし所要時間は最終的に学習率やエポック数などの学習設定に依存する。評価では、正解テキストとの厳密一致文字列マッチを要件とする評価基準で実施した。一部の異常レポートが不正解と判定されるケースが生じたため、学習率やエポック数を増やして再学習・調整した。1 回の LoRA アダプタ (ファインチューニング後の差分モデル) の学習時間は約 5~10 分である。

学習パラメータやデータセットの組み合わせ検証に加え、フルファインチューニングとの比較も行い、試行回数は約 30 回である。また、フォーマット済みの映像メタデータを用い、想定される入力データをすべてデータセットに含めたため未見データは発生しない。この条件下では、LoRA のランク、エポック数、学習率などを大きめに設定するなど学習を強めた方が、高精度になることが分かった。

表 4.3-1 学習プロセスに関する情報のまとめ

フルファインチューニング手法	LoRA (Low-Rank Adaptation)
使用した GPU	NVIDIA H100
総計試行回数	約 30 回
一回学習の所要時間 (学習パラメータの設定によって変わる)	平均 5~10 分

表 4.3-2 ファインチューニング用のパラメータ設定[*¹⁹] (メインパラメータのみを提示する)

LoRA のランク	32
LoRA のスケール係数	32
エポック数	10
バッチサイズ	10
グラデーションアキュムレーション	16
学習率	5×10^{-4}

¹⁹ 各パラメータの説明と用途はこちらの資料に参照: [実験パラメータの調整](https://dataplatform.cloud.ibm.com/docs/content/wsj/analyze-data/fm-tuning-parameters.html?context=wx&audience=wdp&locale=ja#params-common):

<https://dataplatform.cloud.ibm.com/docs/content/wsj/analyze-data/fm-tuning-parameters.html?context=wx&audience=wdp&locale=ja#params-common>

4.4 AIモデルの開発・学習にあたっての留意事項等

4.4.1 AWL Engine Agent

本実証で用いた AI モデルの開発・評価過程において、設計上の考慮事項、実装調整、当初計画からの逸脱が複数確認された。これらの考慮事項は、現地テストで観察された実用上の制約と、類似のインフラ条件を持つ他地域でも再現性のあるシステム展開を保証するための対策を反映している。

まず、当初計画では特定のモデルに微調整や部分的な再学習が必要となる可能性を想定していたが、現場評価では事前学習済みモデルの使用—特に人物検出、姿勢推定、動作認識、顔埋め込み生成において—が要求される性能レベルを達成するのに十分であることが示された。その結果、開発プロセスでは計算負荷の高い再学習よりも、パラメータ最適化とルールベースの改良を優先した。この変更により開発期間が短縮され、大規模なラベル付きデータセットの準備に伴う遅延を回避できた。主な要因は、実証現場における環境変動（照明、カメラ角度、被写体までの距離）が、閾値調整、ROI 調整、後処理ルールによって対処可能であり、基盤となる重みを変更する必要がないことが判明したことである。

第二に、オフラインの転倒・暴力検知モジュールは、当初の計画と比較して決定ロジックの変更が必要となった。初期評価では、動作分類をモデル出力のみに依存すると、非暴力的な身体接触や転倒と無関係の急激な動作において誤検知が発生することが判明した。これに対処するため、最小姿勢変化時間、速度閾値、骨長一貫性チェックなどの追加ルール制約を導入した。これらの調整はスケジュールに大きな影響を与えなかったが、検証計画には影響し、更新されたロジックがノイズを低減しつつ再現率を維持することを確認するための追加評価サイクルが必要となった。

第三に、顔認識モジュールは照明条件や動的な群衆の動きに対する頑健性を確保するため反復テストを実施した。当初計画では単一の高パラメータモデルの使用を想定していたが、追加評価により軽量モデル（210 万パラメータと 630 万パラメータ）が同等の認識精度を提供しつつ、計算量とメモリ要件を大幅に削減できることが判明した。この変更によりハードウェア仕様が異なる他地域へのシステムの移植性が向上するが、3 モデル全ての性能比較を行うため検証スケジュールを更新する必要が生じた。

これらの経験から、本システムの再現や拡張を目指す際の実践的な留意点がいくつか得られた：

- ① 可能な限り事前学習済みモデルから開始し、パラメータ調整後も重大な性能差が残る場合にのみ完全な再学習を検討すること。
- ② AIモデルを補完するルールベースフィルタを設計すること。特に暴力や転倒検知といった複雑な行動では、文脈的手がかりが精度向上に寄与する。
- ③ 照明条件、カメラ角度、動作パターンについて、正式なモデル評価前に必要な調整を特定するため、早期に現場テストを実施すること。
- ④ モジュール式パイプライン（検出→追跡→分析）を採用し、ファーエッジシステムの更新を運用に影響を与えず、あるいは 中断させずに可能とする。
- ⑤ すべての設定パラメータを文書化し、導入先やオペレータを問わず再現性を確保する。

今後の展望として、本システムにおける AI 性能は、頑健性の向上、汎化能力の拡大、そしてスタジアム施設等多様な環境下での運用信頼性の強化に焦点を当てる。実証実験を通じて得られた知見とモデル開発手法を基盤とし、拡張計画ではより広範で代表性の高いデータセットを用いたリアルタイムモデルとオフラインモデルの反復的改良を重視する。

主要なユースケースは、急速に変化する照明、部分的に妨げられた視野、密集した群衆といったコンピュータビジョンにとって本質的に困難な状況でも一貫した性能を発揮できるよう、ファーエッジの検知モジュールを強化することである。頭部方向の推定、年齢推定、マスク認識、そして火災・煙を検知する各モデルは、スタジアムで収集された映像と高品質な合成データを組み合わせた拡張データセットを用いて再調整(リキャリブレーション)が行われる。特に火災・煙の認識においては、小さな煙や炎、反射、屋内外が混在するシナリオなどの視覚的にリアルな事例を数多く提供するため、深層学習による画像合成や拡散モデルによる画像編集といった高度な合成生成技術を積極的に活用する。これらの強化により、誤検知の削減と、フィールドテストで確認された特殊な状況における安定性の向上を目指す。

継続的に精度向上を実現するため、「スタジアムデータセット」はシステム稼働中においても、データ収集を続ける。定期的な微調整サイクルでは、検知しにくい身体の向きや姿勢、逆光被写体、異常な動作パターンを含む、正常・異常状況双方から新たに収集した事例を組み込む。モデル更新は AWL のセキュアなインフラ内で実施され、同様のシステムを採用する施設や地域でも改善が再現可能となる。

モーションブラー、輝度変動、色調歪み、群衆密度擾乱などの変動を体系的に導入することで、モデルの環境の不整合に対する耐性を強化する。転倒・暴力検知においては、拡張された動作シーケンスにより、モデルが認識可能な移動パターンの多様性を増やし、危険行動と無害な動作をより効果的に区別できるようにする。

顔認識においては、長期的な方向性として、エッジデバイスへの実装に適した最適化された軽量モデルへの移行を目指す。既存の 210 万パラメータモデルと 630 万パラメータモデルは、頭部姿勢変動・動作・照明変化に対する安定性を高めるために、追加での調整が必要である。埋め込みマッチング戦略は、姿勢に基づくフィルタリングを改良し、ギャラリー管理手順を更新することで改善され、混雑したイベント中でもシステムが一貫して正確な身元追跡を維持できるようになる。

運用面では、これらの技術的改善を構造化されたモデルライフサイクル管理フレームワークで支援する。これには定期的な再学習スケジュール、データセットのバージョン管理、精度回帰テスト、更新時の円滑な引き継ぎを保証する標準化された展開手順が含まれる。これらのプロセスを形式化することで、AI システムは、異なる地域や展開環境間で互換性を維持しつつ、確実に進化できる。同時に、プロセスを合理化することで、システム管理に必要な複雑さと労力を削減する。

4.4.2 AI 異常レポート要約エージェント関連の開発について

当初、SLM は追加学習を行わない方針とし、プロンプトエンジニアリングのみに依拠して検証を進めた。そのため、SLMに異常レポート要約エージェントとしての役割を与えるシステムプロンプトを設計し、入力データ(映像メタデータ)の整形・改善に注力した。さらに、複数の要約例(Few-shot prompting)の提示、条件分岐や軽微な計算の削減、不要データの排除などの工夫を施したが、要約精度は約 47%にとどまった(6.2.2(9)3)の全要約結果を参照)。そこで、自動評価処理とフィードバックループを実装し、初期要約が評価条件を満たさない場合には、メタデータとの不一致点を明示したヒントプロンプトを付与して再要約を指示する方式とした。その結果、オンライン検証環境における最終要約の精度は 99%以上へ大幅に向上した。

一方で、各種プロンプトエンジニアリング手法(図 4.1-4)により高精度を実現できた反面、実装の複雑性が増した。特にフィードバックループでは、キーワードや必須項目を抽出する検索ロジックが必要となり、異常イベントの全ケースを網羅的に点検する必要があった。その結果、実装工数が増えるだけでなく、ルールベース処理への依存度が高まり、SLM 活用の意義が相対的に薄れる懸念が生じた。今後、複合イベントや複雑化した要約ルールに対応する際は、分岐条件が爆発的に増加するリスクがある。

以上より、プロンプトエンジニアリングのみでは限界があると判断し、SLM 自体のファインチューニングも実施した。前述のデータセット作成手順と学習プロセスに従いモデルを学習し、オフラインで全テストデータを用いて評価したところ、(自動評価・フィードバックなしの単発推論における)要約精度は 95.5%を達成した(6.2.2(9)4)参照)。

当初計画からの変更点として、単純なプロンプト設計だけでは本実証の要約タスクに不十分であることが判明したため、(1) 自動評価+フィードバックループの実装、(2) タスク特化の追加学習(ファインチューニング)という 2 項目を追加した。その結果、開発スケジュールは当初計画より延伸した。

追加学習以外にも、SLM の計算効率の最適化が必要であることが実証実験中に判明した。短時間に異なるエリアで異常イベントが多発し、エッジサーバに同時に多数の SLM 推論リクエストが集中すると、メモリエラーが発生する場合があった。対処として、メモリ断片化²⁰の抑制やキャッシュの解放を行い、メモリエラーの発生率を最小限に抑制できた。しかし、ファインチューニング済みの SLM では、これらの対処を施してもメモリ関連のエラーが頻発したため、本実証では使用を断念した。特に、ベースモデル(Rakuten AI 2.0 Mini Instruction)に LoRA アダプタをマージしていること(図 4.1-5)により、推論中のメモリ処理が一段と複雑化している点が影響したと考えられる。以上の問題点によって本実証はメモリエラー発生が少ないプロンプトエンジニアリングの手法をベースの AI 異常レポート要約エージェントで実施した。

今後のエッジ AI 運用において、SLM の最適化も重要な課題である。AI の精度のみならず、限られたリソース環境下で負荷に耐えうるロバスト性の確保も重要となる。実証終了後に行った詳細調査およびテストにおいて、モデルの処理負荷を低減させる手段として SLM の量子化²¹を適用した。その結果、

²⁰ メモリ断片化:メモリの確保と解放を繰り返すことで、連続した大きな空き領域が少なくなり、必要なサイズのメモリを確保できなくなる状態です。参考ソース:[メモリのフラグメンテーションとは](#)

²¹ 量子化は、大規模言語モデル(LLM)内で利用される手法で、通常は 32 ビット浮動小数点(FP32)または 16 ビット浮動小

メモリ不足は一定程度緩和されたものの、要約精度の低下に加えてメモリエラーも完全には解消しなかった。

これらの結果から、根本原因はモデル単体の処理負荷ではなく、Web API 連携時における大量リクエストの同時処理プロセスにあると推測された。さらなる調査の結果、要約リクエストごとに短い間隔でモデルをリロードしていた点が、メモリ問題の主因であると特定された。各リクエストにおけるメモリ解放の不全や断片化の進行により、最終的に新規モデルのロードに必要な連続メモリ領域が不足したのである。対策として、SLM を初回のみロードし、GPU メモリ上の同一インスタンスを再利用する方式へ変更した。これによりメモリの新規確保が不要となり、GPU リソースの利用効率および推論サービスの安定性が向上した。

ただし、メモリエラー解消後も、大量のリクエストが同時発生した際の処理待機とそれに伴う通知遅延は課題として残った。SLM の推論時間は 1 回あたり約 1～3 秒であるが、短時間に処理が集中した場合、最大で約 1 分の遅延が発生することを確認した。本実証により、現状の SLM は単体では低遅延の推論性能を有するものの、リアルタイムかつ大量の同時推論には適さない可能性が示唆された。

今後の実証設計においては、リスクイベント通知の仕様改善およびテストシナリオの再考が不可欠である。具体的には、単純な人検知ではなく、条件に合致した人物のみ通知へ絞り込む等、前段のフィルタリングによって SLM への推論リクエスト数を削減し、遅延および負荷を緩和する対策が求められる。また、人通りが少なく立ち入りが厳密に制限された場所にシステムを展開することで、通知処理の待機時間は解消されると見込まれる。あるいは、より高性能な GPU エッジサーバを導入することで、処理時間に関する課題の解消も期待される。

5. 実証の手法

5.1 ユースケース①:エッジ AI による通信量の低減

5.1.1 実証内容の詳細

本実証では、監視カメラに近いファアーエッジ上で動作する AI が、カメラ映像から検知されたイベントのリスクレベルと設置場所のネットワーク混雑度に応じてカメラ映像を圧縮されたデータ形式(JSON テキスト化/画像化/映像の一部抽出)に変換・送信することで従来のシステムと比較して通信量の削減を行う。

更に複数のファアーエッジを統括するエッジサーバにおいて、生成 AI(SLM)により JSON テキストを要約してレポートを生成することにより、更なる通信量削減を狙う。

この節では、エッジ AI による通信量の低減を実現するための実証の手法の詳細について述べる。また、図 5.1 1 に、本実証の概要を示す。

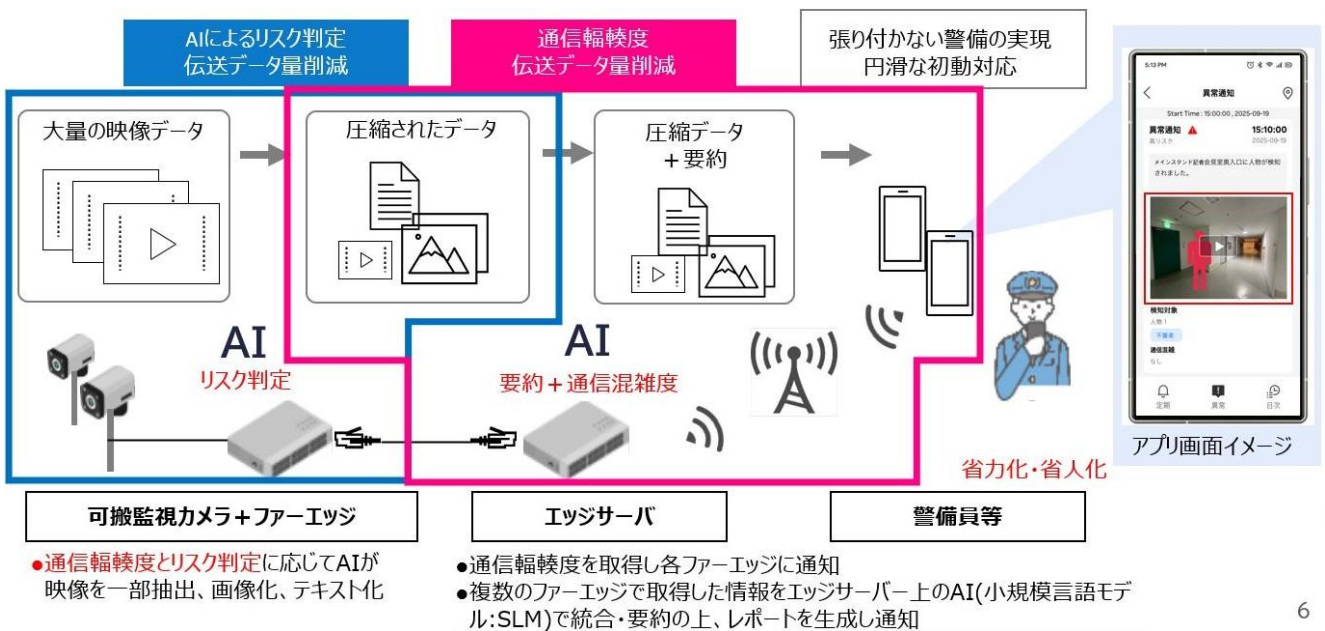


図 5.1-1 実証構成図

(1) システムの特色

ノエビアスタジアム神戸に 3 章で示した構成で AI システムを構築する。

このシステムでは、ファアーエッジ上で動作する AI が、カメラ映像から検知されたイベントのリスクレベルと設置場所のネットワーク混雑度に応じて、カメラ映像を圧縮されたデータ形式(メタデータ JSON テキスト化/画像化/映像の一部抽出)に変換・送信する。更に複数のファアーエッジを統括するエッジサーバにおいて、生成 AI(SLM)によりメタデータ JSON テキストを要約してレポートを生成することにより、更なる通信量削減を狙う。

SLM により生成された要約レポートは、エッジサーバから楽天モバイルネットワーク(LTE/5G)を介してプッシュ通知により即座に警備担当者のユーザデバイス(スマートフォン・スマートグラス)に配信され、警備担当者はユーザデバイス上のヒューマンフレンドリーなアプリでイベントの詳細情報・画像・映像を確認できる。

(2) システムの長所・利点

本システムでは、ファーエッジ・エッジサーバの二段階でデータ量を圧縮することにより、大容量のカメラ映像をそのまま集中型サーバやクラウド環境に配信するシステムと比較して、大幅なデータ通信量の圧縮が可能である。また、ネットワークの混雑度や検知されたイベントのリスクレベルによって圧縮アルゴリズムを動的に変更することで、クリティカルなイベントを検知した場合のみ映像を配信し、ネットワークが輻輳状態のときは非常に少ないデータ量での配信が可能である。また IP カメラ→ファーエッジ→エッジサーバ間のデータ送信は有線で行われるため、エッジサーバ→ユーザデバイス間を除き、モバイルネットワーク(LTE/5G)やインターネットへ抜けるデータ通信は発生しない。これらの特徴により、公共のネットワークへの影響を最小限に留めながら、安全性の高い監視を行うことができる。

また警備担当者は、現場への巡回や常駐をすることなく、遠隔からリアルタイムでのインシデントの検知、状況確認が可能なため、少ない労働力でも人力で監視しているときと同等以上のセキュリティレベルを担保することができる。

(3) 実証手順

システム構築後に、ノエビアスタジアム神戸で実証実験を実施し、データ送信量の削減率、AI の精度、エンドユーザ(警備員に業務を委託する責任者であるノエビアスタジアム神戸従業員)によるイベントへの反応時間を測定、また使用したエンドユーザからのフィードバックを収集する。収集したデータを元に、データ削減効果と、遠隔からのリアルタイムでの監視オペレーションが正確かつ効率的に行えるかについて、AI 精度・データ削減率・ユーザ満足度などの KPI・KGI の目標値と実績値の比較を通じて評価を行い、実証中に発生した課題の特定と、社会実装に向けた対応策の検討を行う。

5.1.2 利用技術・データ

このシステムでは、IP カメラの映像フィードをファーエッジ上で動作するリアルタイム AI パイプラインにより継続的に分析し、イベント検出時のみ、軽量の圧縮データをエッジサーバに送信する。これにより、継続的に高帯域幅の映像ストリームを送信する必要がなくなるため、通信量を大幅に削減しつつ、異常をリアルタイムで検出・報告できる。

ファーエッジでの映像の圧縮方式(メタデータ JSON テキスト化/画像化/映像の一部抽出)の組み合わせは、検出されたリスクレベルと、エッジサーバからファーエッジに配信されたネットワーク輻輳度に応じて選択される。例えば、リスクレベルの低いイベントの場合やネットワークが混雑している場合は、データサイズの大きい映像クリップの送信は行われない。これにより、帯域幅の可用性が変動する環境での通信を最適化することができる。

またイベント情報 JSON は、エッジサーバ上で動作する SLM(Rakuten AI 2.0 Mini Instruct)により、エンドユーザによる理解が容易な要約レポートに変換され、エンドユーザアプリケーションにプッ

シュ通知により配信される。これにより、さらにデータ量が削減され、また警備担当者はリアルタイムで異常の検知、状況の把握ができる。

このシステムは、通信量の最小化と重要なイベントのタイムリーかつ正確な検出・通知という二重の目的を達成する。従って、このアーキテクチャは、帯域幅が制約された環境で拡張可能な導入を必要とする自治体・施設等にとって適している。

図 5.1-2 にシステム構成図と、それに続いて各構成要素の内容・特徴・重要性を示す。

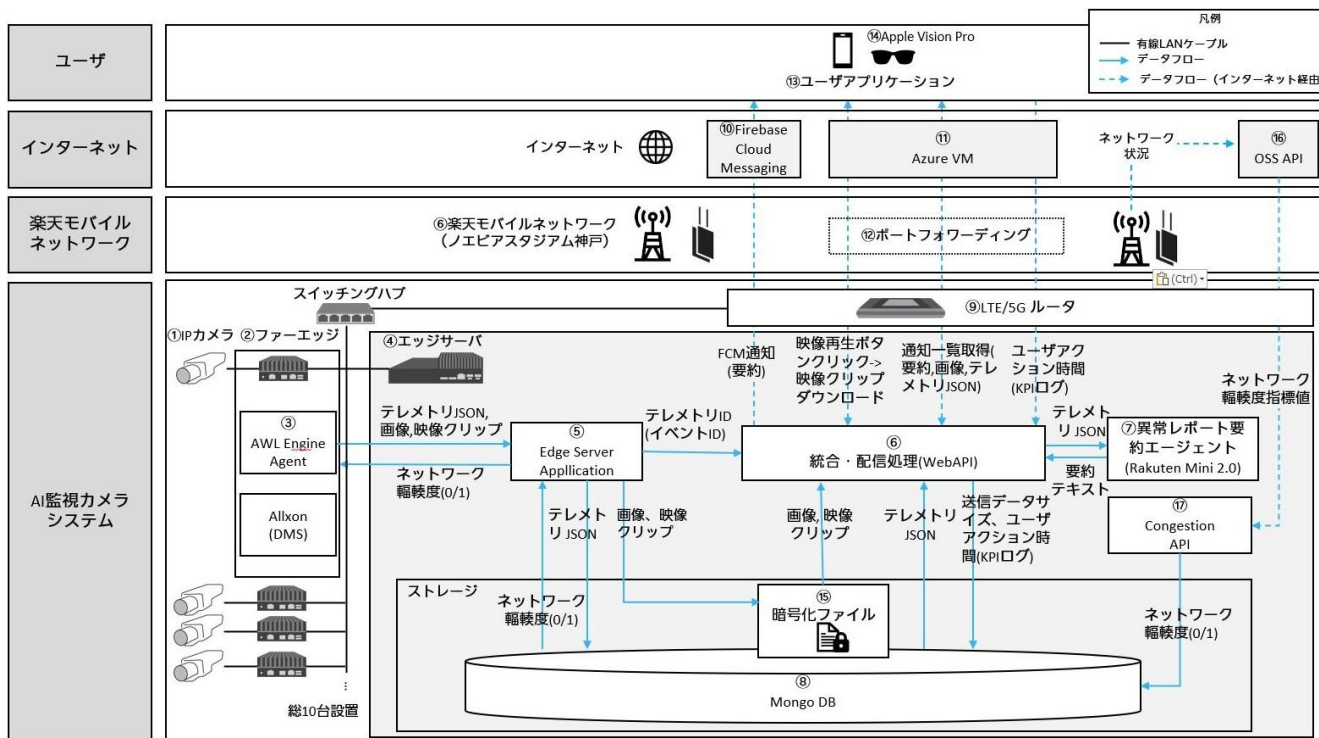


図 5.1-2 全体システム構成図

(1) IP カメラ(Axis M1135-E Mk II)

- 使用台数: 10 台
- 主な特徴:
 - イメージセンサ解像度: 5MP(500 万画素)
被写体が遠く離れている場合や部分的に隠れている場合でも、人物、頭部、顔の検出に適した詳細な画像を提供する。
 - ライトファインダーと WDR(ワイドダイナミックレンジ)
スタジアムの通路、日陰のスタンド、屋内外が混在する場所など、照明条件の厳しい環境でも安定した画質を確保する。
 - 統合型赤外線照明
追加の外部照明を必要とせず、夜間や低照度でも動作し、常に高い検出精度を保証する。
 - 低遅延ストリーミング
ファアエッジデバイスでのリアルタイム AI 推論に適した、安定したフレーム配信を提供す

る。

- 重要性・選定理由：
 - 信頼性、高画質性能、そしてスタジアムなどの複雑な環境におけるエッジ AI ベースの映像分析への適合性から、本実証のメインカメラとして選定された。様々な照明条件や天候下でも鮮明で安定した映像ストリームを提供できるため、人物検知、頭部・顔検知、火災・煙検知、人口統計分析といったリアルタイム検知タスクにおいて特に効果的である。
 - カメラのハードウェア特性により、フレームロスを最小限に抑えた安定した動作が保証される。これは、追跡、姿勢推定、行動認識を担うモジュールにとって非常に重要である。さらに、オープンスタンダードに対応し、ファーエッジコンピューティングデバイスとの統合が容易なため、専用のプロトコルを必要とせずに効率的なデータ取得が可能である。

詳細については 8.3「使用機器・ソフトウェア一覧」参照。

(2) ファーエッジ端末 (AVerMedia QL601 Box PC)

- 使用台数: 10 台(1 台の IP カメラに 1 台のファーエッジが対応する)。
- 主な特徴：
 - OS: Ubuntu 22.04 LTS
 - コンテナ化された AI サービスに適した Ubuntu 22.04 LTS 環境上で、AWL のリアルタイム AI パイプラインを再現性のある形で展開できる。
- CPU: Qualcomm® QCS6490 プロセッサ
 - 低遅延なエッジ推論を複数モデルで同時に実行できる。
- 8GB LPDDR4 メモリと 128GB UFS 2.2 ストレージ
 - 連続処理でも安定したパフォーマンスを提供し、ローカルでのビデオバッファリングとログ記録を可能にする。
- 重要性・選定理由：
 - スタジアムでの導入に必要な AI 推論能力、耐久性、そして統合柔軟性のバランスを備えているため、ファーエッジコンピューティングプラットフォームとして選定された。最大 12.5 TOPS の AI コンピューティング性能を提供する Qualcomm® QCS6490 プロセッサを搭載しており、人物検知、追跡、頭部分析、火災・煙検知、マスク検知など、複数のリアルタイムモデルを低遅延で同時に実行できる。
 - またコンパクトでファンレスな設計により、継続的な稼働が求められ、メンテナンスのための物理的なアクセスが制限される環境でも安定した運用を実現する。

詳細については 8.3「使用機器・ソフトウェア一覧」参照。

(3) ファーエッジ上 ソフトウェア(AWL Engine Agent)

- 概要：
 - AWL Engine Agent は、AI パイプラインと連携して動作する(2)ファーエッジ側の制

御・通信レイヤとして機能する。

- IP カメラ (AXIS M1135-E Mk II) の映像フィードをファールエッジ上で AI パイプラインを使用してローカル分析し、AI の推論結果を標準化されたテレメトリ JSON 形式に整形し、イベント検出時のみ圧縮データ (テレメトリ JSON/画像/映像クリップ) を (4) エッジサーバに送信する。映像の圧縮方法の組み合わせは、検出されたリスクレベルと、エッジサーバで取得され、ファールエッジに配信されたネットワーク輻輳度に応じて選択される。

表 5.1-1 圧縮方法の選択ルール

イベント重大度	定義	輻輳度:低	輻輳度:高
イベントなし(定期報告)	0 人	①	①
低リスクイベント	1 人(マスクなし、かつ 10-70 歳) < 5 秒	① ②	① ②
高リスクイベント	2 人以上 1 人 > 5 秒 1 人かつマスクあり 1 人かつ 10 歳未満、または 70 歳を超える 煙・または炎あり	① ② ③	① ②

①:超高圧縮(イベント情報テレメトリ JSON)、②:高圧縮(画像)、③:中圧縮(映像クリップ)

- 超高圧縮 - 映像をテキスト(イベント情報テレメトリ JSON)に変換する
- 高圧縮 - 映像を静止画像に変換する
- 中圧縮 - 継続的な映像ストリームの代わりに、リスクイベント前後 10 秒間のシーンだけを切り出した、短い映像クリップのみを送信する
- また 15 分ごと(00:00, 00:15, 00:30, 00:45)に定期的に、過去 15 分間に異常が発生しなかった場合は定期通知 JSON をエッジサーバに送信する。
- また、失敗や不完全なイベントについても記録・送信することで、後続の分析におけるトレーサビリティを確保する。
- 加えて、AWL Engine Agent はエッジサーバとの間で永続的な TCP 通信を管理し、メッセージのフレーミング、応答確認、再送制御を行う。さらに、KPI 評価のためのシステム活動ログを送信し、ネットワーク輻輳状況に応じて送信動作を調整することで、通信状況が変動する環境下でも安定した運用を実現する。
- データの特徴:
 - テレメトリ JSON にはリスクレベル、タイムスタンプ、デバイス ID、カメラ ID、イベントカテゴリ、圧縮された Base64 画像などが含まれる。またテレメトリメッセージは、送信前のペイロードサイズをさらに最小化するため、MessagePack を用いてシリアル化される。
- 特徴・重要性:
 - これらの機能により、計算負荷の高い映像に対する推論処理は、全てファールエッジ上で完結する。継続的な高帯域幅の映像ストリーム送信を、イベント情報 JSON を含む軽量の圧縮データ送信に置き換えることで、通信量を大幅に削減しつつ、異常をリアルタイムで検出・報告できる。
 - また、リスクレベルとネットワーク輻輳度に応じて圧縮方法を変更する機能により、帯域幅の可用性が変動する環境での通信を最適化することができる。

以下に AWL Engine Agent のシステム構成図を示す。

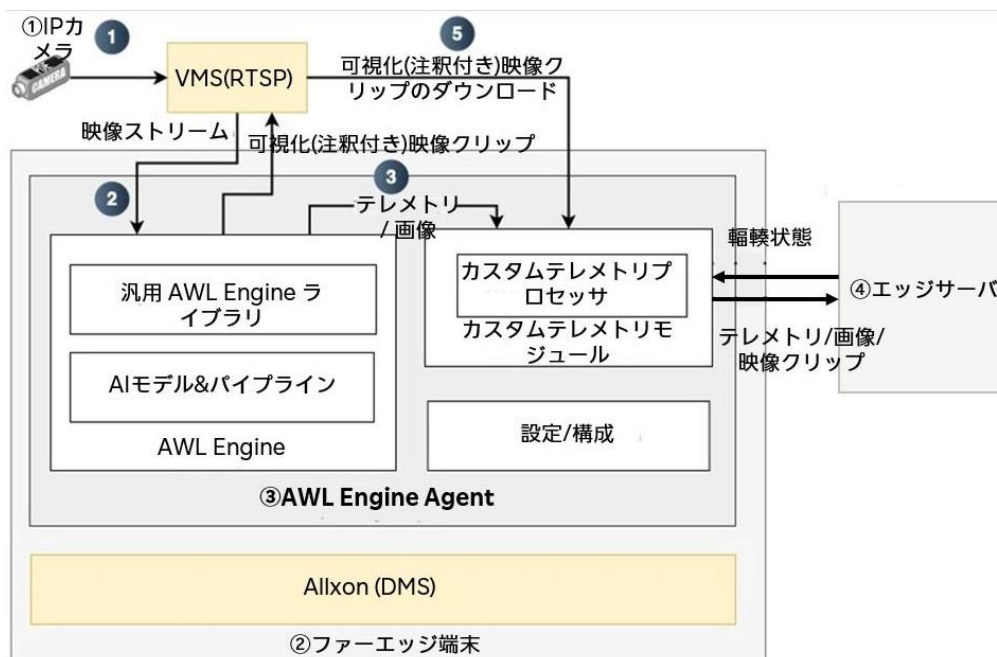


図 5.1-3 AWL Engine Agent システム構成図

(4) エッジサーバ(Lenovo ThinkEdge SE100 + NVIDIA RTX2000E (GPU))

- 使用台数: 1 台
- 主な特徴:
 - GPU: NVIDIA RTX2000E
 - CPU: Intel® Core™ Ultra 5 225H
 - 強力なマルチタスク性能を備えた最新のエッジ最適化マルチコアプロセッサであり、テレメトリの取り込み、データベース操作、分析サービスを同時に実行可能である。
- OS: Ubuntu 24.04.3 LTS
- GPU およびアクセラレータ拡張のサポート:
 - ロープロファイル GPU をサポートし、高負荷なビデオ分析やモデルの再学習タスクに対応するための将来的なアップグレードを可能にする。
- コンパクトで柔軟なフォームファクター:
 - 省スペースと柔軟な設置オプションにより、サーバラックをフルに利用できない場所でも、様々なスタジアム環境に設置できる。
- 重要性・選定理由:
 - 要求の厳しいエッジコンピューティング環境向けに特別に設計されているため、エッジサーバプラットフォームとして選定された。コンパクトなサイズ、堅牢な設計、そして効率的な熱特性により、スタジアムや公共施設など、スペースが限られており、埃、振動、温度変動といった環境変化への耐性が求められる施設への導入に最適である。
 - またこのプラットフォームは、複数の(2) ファーエッジ端末 (AVerMedia QL601

Box PC)からのテレメトリの集約、ローカルイベント処理、データベースサービス、そしてオプションのオフライン分析ワークロードをサポートするのに十分な CPU 性能と拡張機能を備えている。

詳細については 8.3「使用機器・ソフトウェア一覧」参照。

(5) エッジサーバ上集約処理(Edge Server Application)

- 概要:
 - Edge Server Application は、複数のファールエッジデバイスと下位システムを接続する中核的な集約・制御ポイントとして機能する。(3)ファールエッジ上 ソフトウェア(AWL Engine Agent)から TCP を介して受信した MessagePack 形式のペイロードの検証・デコード、(4)エッジサーバへの取り込み⁽²²⁾永続化)や、ネットワーク輻輳度のファールエッジ上 ソフトウェア(AWL Engine Agent)への配信などを行う。
 - また、KPI 計測や監査、性能分析を目的としたシステム活動ログの記録も担う。

- 特徴・重要性:
 - 受信したイベント情報テレメトリ JSON は(8)MongoDB に、関連する画像、映像クリップは AES256-CBC で暗号化した上でローカルまたはマウントされたストレージに保存される。
 - テレメトリ JSON・画像パス・映像クリップパスは処理可能な統一スキーマを用いて MongoDB に保存される。このスキーマは可視化や分析のための高速検索をサポートしつつ、異なるイベントタイプ間の一貫性を保証する。

²² 永続化：データベースやファイルなどの不揮発性ストレージへの保存、の意で使用している。

```
{
  "_id": "f172e20c-31cc-4511-aa69-4a34edb6e2a8",
  "event_id": "000f0100-0b0b-0b07-0e04-02010f0f060d",
  "event_type": "text",
  "event_timestamp": 1762833087381,
  "event_telemetry": {
    "id": "000f0100-0b0b-0b07-0e04-02010f0f060d",
    "timestamp": 1762833087381,
    "device_alias": "D41F150D4264B374594D9AF26E98AD19",
    "system_id": "",
    "camera_id": "",
    "location_id": "area_2",
    "congestion": 0,
    "detection_count": 1,
    "risk": "high",
    "type": "person",
    "confidence": 0.8276353478431702,
    "has_image": true,
    "has_video": true,
    "detection": [ ...
  ]
},
  "event_status": 1
},
{
  "_id": "78096732-a98d-463e-8795-8f356df710f3",
  "event_id": "000f0100-0b0b-0b07-0e04-02010f0f060d",
  "event_type": "image",
  "event_timestamp": 1762833087381,
  "event_media": "/telemetry/images/D41F150D4264B374594D9AF26E98AD19/000f0100-0b0b-0b07-0e04-02010f0f060d.enc",
  "event_status": 1
},
{
  "_id": "15a657d7-e96f-491e-b06d-55b4eed5f5f5",
  "event_id": "000f0100-0b0b-0b07-0e04-02010f0f060d",
  "event_type": "video",
  "event_timestamp": 1762833087381,
  "event_media": "/telemetry/videos/D41F150D4264B374594D9AF26E98AD19/000f0100-0b0b-0b07-0e04-02010f0f060d.enc",
  "event_status": 1
}
]
```

テレメトリJSON

画像パス

映像クリップパス

図 5.1-4 MongoDB に保存されたテレメトリ

- 永続化処理後、当処理は同一サーバ上の(6)エッジサーバ上統合・配信処理(Web API)に HTTP でイベント受信を通知する。これにより、Web API は(13)エンドユーザアプリケーションに、イベント情報テレメトリ JSON の要約をプッシュ通知することができる。また Web API は、エンドユーザアプリケーションから要求があった場合は、永続化されたイベント情報・画像・映像クリップを返すことができる。
- また(17)ネットワーク輻輳度取得コンポーネント(Congestion API)が取得して MongoDB に保存した通信輻輳度を、SignalR を使用してファースト エッジ上 ソフトウェア(AWL Engine Agent)に一斉配信する。これにより、AWL Engine Agent は、ネットワーク輻輳度に応じた圧縮方法の選択が可能となる。

IP カメラから Edge Server Application までのデータフローについては、図 5.1-5 を参照。

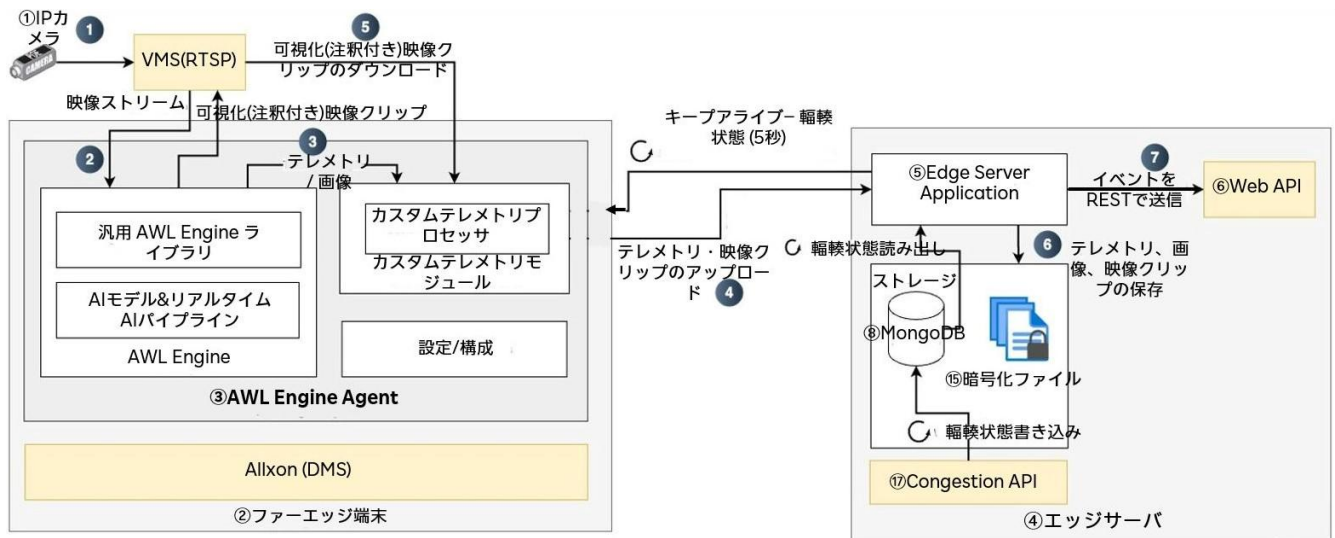


図 5.1-5 エッジサーバまでのシステム構成図・データフロー

(6) エッジサーバ上統合・配信処理(Web API)

- 概要
 - (5)エッジサーバ上集約処理(Edge Server Application)が(3)ファアーエッジ上ソフトウェア(AWL Engine Agent)から受信し、永続化した圧縮データを適宜処理し、(13)エンドユーザアプリケーションからアクセスできるようにするための Web API である。
- 特徴・重要性
 - エッジサーバ上集約処理(Edge Server Application)からのイベント受信通知を受けて、(8)MongoDB からイベント情報テレメトリ JSON を取得し、(7) AI 異常レポート要約エージェント(SLM コンポーネント)を使用して JSON の要約を行い、エンドユーザアプリケーションに、(10)Firebase Cloud Messaging (FCM)を使用して要約レポートをプッシュ配信する。これにより、警備担当者はリアルタイムで異常の検知、状況の把握ができる。
 - またエンドユーザアプリケーションからの要求に応じて、永続化されたイベント情報、画像、映像クリップなどを返す。これにより、警備担当者は異常の詳細を確認し、適切な対応を取ることができる。

(7) AI 異常レポート要約エージェント(SLM コンポーネント)

- SLM(Rakuten AI 2.0 Mini Instruct)
 - Rakuten AI 2.0 Mini は 15 億パラメータの基盤モデルであり、本実証で使用するのには、それに対しインストラクションチューニングを施したモデルである。当モデルは MT-Bench による日本語 LLM 評価において、複数のインストラクションチューニング済み日本語対応オープン LLM と比較して高いスコアを獲得している。
- 概要
 - SLM を使用して、(3)ファアーエッジ上ソフトウェア(AWL Engine Agent)から送信さ

れたイベント情報テレメトリ JSON の要約レポートを生成するコンポーネントである。内部的には、JSON をプロンプトの一部として埋め込み、SLM に要約レポートを生成させている。

- 単独の(2)ファークエッジからの異常通知 JSON を要約する機能と、複数ファークエッジからの定期通知 JSON を統合・要約する機能を持つ。
- 生成される要約は、正しく状況を要約しており、可読性が高いものである必要がある。
- 特徴・重要性
 - 一つのまたは複数のイベント情報テレメトリ JSON を統合・要約し、必要最小限の情報のみを含むテキストにすることで、データ量の削減に加えて、警備担当者による異常の即時把握を可能にしている。またフィードバックループ(反復プロンプト)機構を組み込むことにより、異常レポート生成率を抑え、正確な要約の生成を可能にしている。

詳細は 4.1「AI モデルの全体像」参照。

(8) エッジサーバ上 DBMS(MongoDB)

- 主な特徴・選定理由
 - データ保存場所
ファイルシステム上のファイルをメモリにマッピングするため、プロセスはメモリ上のファイルへの高速アクセスが可能である。
 - データ保存形式
MongoDB は JSON-like な BSON 形式のドキュメントとしてデータ保存を行うが、(2)ファークエッジ - (4)エッジサーバ - (13)エンドユーザアプリケーション間のデータのやり取りは JSON 形式で行われる。そのため、それらのデータをほぼそのまま格納/取り出しすることが可能であり、データ変換処理を実装する必要がない。
 - トランザクション機能
トランザクション機能がないが、このシステムでは単純なデータ登録処理しか行われず、複数のデータ更新を、一貫性をもちつつ行う必要がないためトランザクション機能は必要ではない。
- 重要性
 - DBMS は、以下のようなデータをエッジサーバ上で永続化するために必要である。
 - ファークエッジから受信したイベント情報テレメトリ JSON
 - (6)エッジサーバ上統合・配信処理(Web API)により生成された、イベント要約レポートを含む通知情報
 - データ削減率やユーザ反応時間などの KPI の算出のための、データ送受信量、ユーザアクション時間などのログデータ

(9) LTE/5G ルータ(KYOCERA K5G-C-100A)

- 主な特徴
 - SIM: 楽天モバイル(最強プラン)
 - USB Type-C、Wi-Fi(Wi-Fi6 対応)など、有線・無線で既存の製品と接続可能。
 - 排熱構造に加えて、冷却ファンを搭載しているため、高負荷環境下においても安定した連続通信が可能。
- 重要性
 - (4)エッジサーバと(2)ファアエッジがインターネットへアクセスするために必要である。
 - エッジサーバは、(13)エンドユーザアプリケーションから(6)エッジサーバ上統合・配信処理(Web API)にアクセスできるようにするために、Web API のポートを(11)
 - Azure VM に(12)ポートフォワーディングする必要がある。そのために、エッジサーバは Azure VM にインターネット経由でアクセスする。
 - またエッジサーバとファアエッジは、リスクイベントへの正確なユーザ反応時間を算出するために、NTP による時刻同期が必要である。そのために、インターネット経由で NTP サーバ(ntp.nict.jp)にアクセスする。



図 5.1-6 エッジサーバ・LTE/5G ルータの写真

(10) Firebase Cloud Messaging (FCM)

- 概要
 - Google の提供するクロスプラットフォームメッセージングソリューションであり、送信側・受信側の OS を問わずプッシュ通知を低遅延で配信できる。
- 主な特徴
 - OS を問わず動作するため、本実証ではスマートフォン端末としては Android™のみを使用したが、次年度以降の実証では iPhone、Web アプリなどにプッシュ通知を送信することも可能である。
 - Google のインフラストラクチャを利用しているため、メッセージが確実にユーザに届くよう設計されている。
- 重要性
 - これを使用することにより、ユーザは例え(13)エンドユーザアプリケーションを開いていなくても、重要な通知を即座に受け取ることができる。

(11) Azure VM

- 概要
 - Azure VM は、オンデマンドの仮想化されたコンピューティングリソースであり、数分で仮想マシンをプロビジョニングし、さまざまな OS やソフトウェアを実行可能である。また必要に応じて、数分で VM サイズの変更や、台数の増減が可能である。
- 主な特徴
 - OS : Ubuntu 24.04.3 LTS
 - VM サイズ : B2s (2 Cores, 4 GB RAM)
 - Azure VM の用途は(12)ポートフォワーディングのみであり、高い計算能力や大容量のメモリは不要であるため、VM サイズは B2s で十分である。
 - パブリック IP アドレス : あり
 - 可用性 : 月間 99.5% (Standard SSD の場合)
 - 使用実績 : 過去の楽天モバイルの複数プロジェクトで実績あり
- 重要性
 - (4)エッジサーバはインターネットに公開されていないため、そのままでは(13)エンドユーザアプリケーションからアクセスできない。そこでエッジサーバ上の(6)エッジサーバ上統合・配信処理(Web API)のポートを、パブリック IP アドレスを持つ Azure VM 上のポートにフォワーディングすることにより、Azure VM 経由でユーザアプリケーションからアクセスできるようにする。

(12) ポートフォワーディング

- 概要
 - ポートフォワーディングとは、IP ネットワーク上のある機器が、自らの IP アドレスの特定のポート番号への通信を、別のアドレスの特定のポートへ自動的に転送する機能である。

- 重要性
 - LAN 内に位置する(4)エッジサーバ上の(6)Web API を、インターネット側から、つまり(13)エンドユーザアプリケーションからアクセスできるようにするために必要である。また(11)Azure VM へのポートフォワーディングは、開発用 PC からエッジサーバに ssh や(8)MongoDB クライアントでアクセスするためにも使用される。
- 特徴
 - ポートフォワーディングは、エッジサーバ(Ubuntu 24.04.3)から
 - Azure VMのパブリック IP アドレスを指定して ssh コマンドを実行することにより行う。認証にはパスワードではなくより安全な秘密鍵(pem ファイル)を使用する。またエッジサーバ起動時の自動 ssh 接続や、接続が切れた場合の自動再接続が行われるよう、エッジサーバには autossh をインストールし、autossh を systemd サービスとして登録する。

(13) エンドユーザアプリケーション

- 概要
 - エンドユーザアプリケーションは、スマートフォン(Android)版と(14)スマートグラス(Apple Vision Pro)版を用意する。
 - スマートフォン端末には SHARP AQUOS R5G(Android 11)を使用する。AQUOS R5G は、2020 年発売の機種だが、楽天モバイルの様々な PoC において使用実績が豊富であり、今回の実証では必要十分な性能・機能を備えている(スマートフォン版エンドユーザアプリは 2D UI のみで構成されているため、高い端末スペックや AI・AR などの最新 OS 機能を必要としない)。
 - また最新機種である AQUOS R10 搭載の Snapdragon 7s Gen 3 は日常使用や軽めのゲームに最適化されており、AQUOS R5G 搭載の Snapdragon 865 SM8250 は、単純なベンチマークスコアでは Gen 3 を上回る場合もあり、検証に十分な性能であると判断した。
- 特徴・重要性
 - スマートフォンアプリは、(10)FCM 通知を受信すると、アプリが開かれていない場合、また起動されていない場合でも、バイブレーションや通知音、ポップアップ通知の表示などでユーザに通知する。これにより警備担当者は、常にアプリ画面を確認することなしにリアルタイムで異常の検知、状況の把握ができる。
 - ユーザが FCM 通知をタップすると、対応するイベント情報・画像が(6)エッジサーバ上統合・配信処理(Web API)から取得され、イベント詳細画面に表示される。映像クリップについては、ユーザがイベント詳細画面において映像再生ボタンをタップした場合のみ Web API からダウンロード、表示される。これにより、映像の通信量を必要分だけに抑えることができる。また警備担当者はイベント詳細画面で異常の詳細を確認し、適切な対応を行うことができる。
 - なお、スマートグラスアプリは常時着用を前提としているため FCM 通知受信に対応しておらず、定期的に Web API からイベント情報を取得し、空間内に AR 表示する。

(14) スマートグラス(Apple Vision Pro)

- 概要
 - Apple が開発し、2024 年初頭に発売した空間コンピュータであり、デジタルコンテンツと現実世界をシームレスに融合させることができる。
- 特徴
 - 空間コンピュータ：
単なる VR ヘッドセットや AR グラスとは異なり、「空間コンピュータ」と位置付けられている。これは、デジタルコンテンツが現実世界に存在するよう感じられ、ユーザーが自然な形でデジタル情報とインタラクトできることを意味する。例えば、壁に巨大な仮想スクリーンを投影して映画を観たり、机の上に複数の仮想モニターを並べて作業したりすることが可能である。
 - 超高精細ディスプレイ：
片目解像度 3800×3000 ピクセルを持つ Micro-OLED ディスプレイを搭載し、鮮明でリアルな映像を表示できる。これによりユーザーは表示されるイベント情報・画像・映像クリップを細部まで確認できる。これは警備担当者に対するアプリの使いやすさや、どれだけ業務の役に立つかに関するアンケート結果 KPI に寄与すると考えられる。また本実証では採用していないが、警備担当者に対して様々な情報(異常発生地点への道順など)、異常発生地点への AR ナビゲーションなどを高精細度で AR 表示することが可能である。
 - 高性能チップ：
MacBook Air などにも搭載されている Apple M2 チップが高度な処理能力を提供し、リアルタイムでのセンサー処理と低遅延な映像伝送を行う。加えて、センサー処理等を担う新しい R1 チップのデュアルチップ構成であり、高性能な処理と低遅延な操作体験を可能にしている。
- 重要性
 - スマートフォンアプリは情報を端末のディスプレイ内にしか表示できないが、スマートグラスアプリではユーザー周囲の空間すべてを情報表示に使用することが可能であり、表示できる情報量が格段に増加する。例えば、スマートグラスアプリでは、通知を複数件、スタジアムの 3D View とともに 3D 空間上に AR 表示可能である。これにより、警備担当者は異常通知箇所を立体的、かつ直感的に把握することができる。
 - また警備担当者は、スマートフォンアプリの場合は、作業の手を止めてスマートフォンを手に取り、何が起きているか確認する必要があるのに対し、スマートグラスを常時装着していれば他の作業で忙しい場合も即座にハンズフリーで通知を確認できる。これらの特長により、スマートグラスは警備担当者の負担を軽減し、迅速かつ的確な対応を支援できることが期待される。
 - ただし、Apple Vision Pro の重量は 750~800g とやや重く、また稼働時間は一般的な使用で最大約 2~2.5 時間程度であり、現時点では常時装着は難しい。しかし将来技術が進展し AR デバイスの軽量化・超稼働時間化が進めば、警備担当者は常時装着が可能と考えられるため、本実証で使用する意義は大きいと判断した。

(15) ファーエッジ - エッジサーバ - エンドユーザデバイス間の個人情報の取り扱い

- 概要
 - 個人情報に該当する画像・映像クリップは、(4)エッジサーバ上で暗号化され、また(13)エンドユーザアプリケーションにも暗号化された状態のままインターネット経由で送信される。また復号化された画像・映像クリップはエンドユーザデバイス上に保存されないため、通信経路・各ノードの両方で個人情報の安全性が確保されている。
 - 今後社会実装フェーズに展開する場合は、Web API - エンドユーザアプリケーション間の通信を HTTPS 化するなど、施設やイベント、ユーザの要件に合わせて、よりセキュリティの確保に配慮した対応を行う。
- 特徴・重要性
 - (3)ファーエッジ上 ソフトウェア(AWL Engine Agent)から送信された、個人情報に該当する画像・映像クリップは、(5)エッジサーバ上集約処理(Edge Server Application)によりエッジサーバ上のファイルシステムに AES256-CBC で暗号化された状態で保存される。(6)エッジサーバ上統合・配信処理(Web API)から(13)エンドユーザアプリケーションへの画像・映像クリップの送信も暗号化されたまま行われ、復号化はユーザアプリケーション上で秘密鍵を使用して行われる。
 - そのため、秘密鍵を知らない者は、エッジサーバにアクセスできたとしても、またエッジサーバユーザアプリケーション間の通信を傍受したとしても画像・映像クリップの内容を確認することはできない。
 - またユーザアプリケーションは、復号化された画像・映像クリップをローカルに保存しないため、端末が盗難にあったとしても、ユーザアプリケーションが起動していない限り、画像・映像クリップを閲覧することはできない。またユーザアプリケーションは ID、パスワードを入力しなければ起動することはできない。

■ファーエッジコンピュータデータフロー図

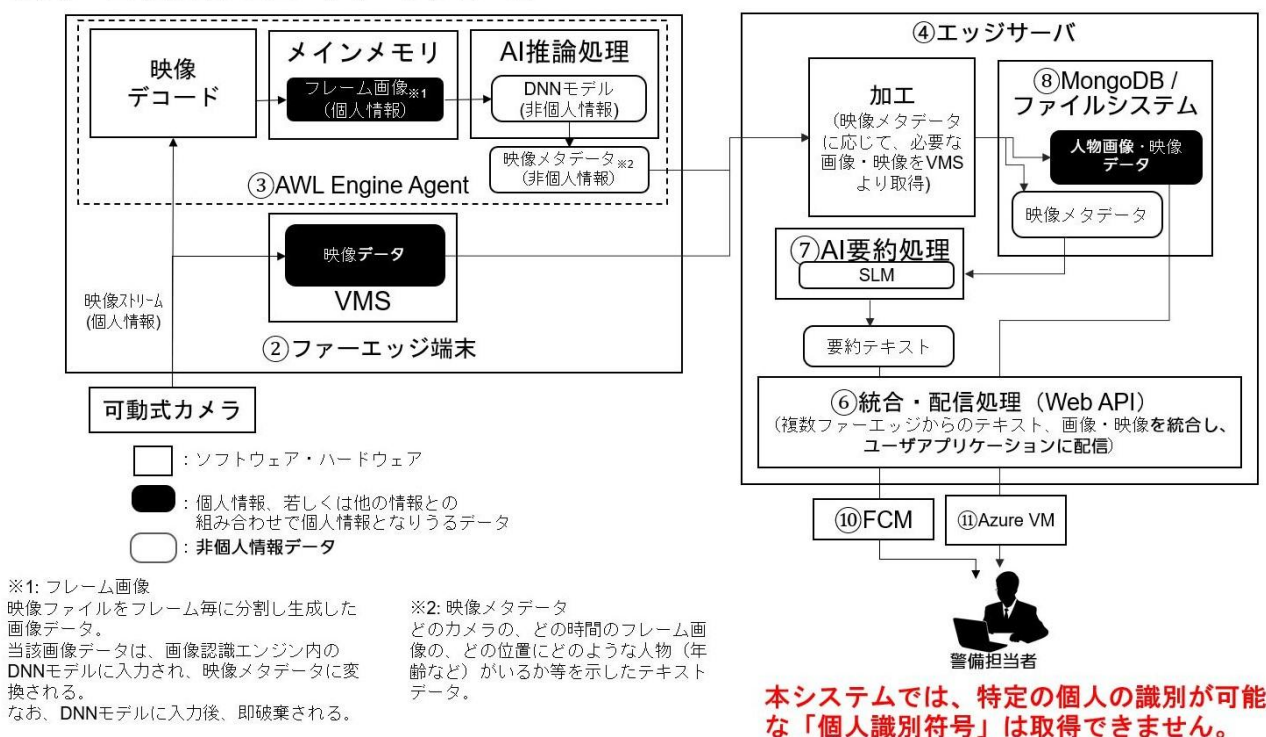


図 5.1-7 個人情報データフロー図

(16) ネットワーク輻輳度の取得・利用

・ 概要

- スタジアム内外の楽天モバイル基地局の輻輳関連指標値は、楽天モバイルのネットワーク運用支援システム（OSS）により定期的に収集される。エッジサーバ上の(17)ネットワーク輻輳度取得コンポーネント(Congestion API)は、OSS API を介して輻輳関連指標値を取得し、ネットワーク輻輳度（輻輳/非輻輳）に変換し、(8)MongoDB に保存する。
- (5)エッジサーバ上集約処理(Edge Server Application)は、定期的(デフォルトでは 5 秒間隔)にエッジサーバ上 DBMS(MongoDB)から輻輳度を取得し、すべての(2)ファーエッジ端末 (AVerMedia QL601 Box PC)に SignalR を使用してブロードキャストする。

・ 重要性

- (3)ファーエッジ上 ソフトウェア(AWL Engine Agent)は、受信したネットワーク輻輳度(とリスクレベル)に応じた圧縮方法の選択が可能となる。これにより、帯域幅の可用性が変動する環境での通信を最適化することができる。

(17) ネットワーク輻輳度取得コンポーネント(Congestion API)

・ 概要

- OSS API から取得したネットワーク輻輳度指標値をネットワーク輻輳度（輻輳/非輻輳）

に変換し、(8)MongoDB に保存する。

- 特徴
 - OSS から取得する指標値には、多くのデータを集約および処理をおこなうため、現在のシステムでは、1時間程度のタイムラグが存在する。そのため、過去の同一基地局で発生したネットワークの様々な情報を輻輳度指標値データとして使用して、現在の輻輳度を予測するアルゴリズムを実装する。
- 重要性
 - 本実証のシステムは、通信の状況と連携し、カメラの映像の圧縮率を動的に変更する必要がある、そのためには楽天モバイルのネットワーク情報を取得し、連携するための本 API が必要となる。

5.1.3 必要性・新規性

このソリューションの必要性は、スタジアムや大規模な公共施設、自治体施設など、継続的な映像監視が必要な環境において一般的に直面する運用上の課題から生じている。従来の監視システムでは、処理のためにフル映像ストリームを集中型サーバやクラウド環境に送信するため、通信コストの高騰、遅延の増加、ネットワーク安定性への依存度の高さが課題となっていた。これに対し、本実証ではエッジ AI を導入し、検知、追跡、リスク分類を含む全ての重要な分析処理を、各カメラ近くに配置されたファーエッジデバイス上で直接実行することで、これらの課題を解決する。この手法は、アップストリーム通信負荷の軽減、リアルタイム対応の実現、ネットワーク混雑時や接続制限時においてもシステムの信頼性を確保するために不可欠である。

またノエビアスタジアム神戸などの大規模施設では、警備員・監視員の不足により発生しうるセキュリティリスクに対して、初期投資などの費用面で監視カメラの導入が進んでいない。また、多用途が進む施設では、警備すべき場所や条件が頻繁に変わるため、固定カメラよりも設置場所を柔軟に変更できる可搬式カメラの方が効果的である。このソリューションを導入することにより、既存の通信回線を利用して初期投資を下げ、また可搬性の高いシステムにすることで必要な場所に必要な時だけの小規模な導入が可能となる。また AI 導入により常時モニタリングの必要がないため、効率的な警備・監視が可能になり、人件費抑制や労働力の最適配置に有用である。生成 AI(SLM)による状況分析レポートの生成で、非熟練人材の警備業務へのアサインも可能となる。AI が消費する電力量が大きいものの、AI 機能をファーエッジ・エッジサーバ・ユーザ端末のそれぞれに適切に配置することで省電力での運用も目指すことができる。

このソリューションの新規性は、リアルタイムのエッジ AI 推論、構造化されたテレメトリ伝送、および輻輳を認識した通信制御を統合した設計にあり、これは既存の市場ソリューションでは一般的に見られないものである。従来のクラウドベースまたは NVR(ネットワークビデオレコーダーや IP カメラの映像を、IP ネットワークを経由して録画する機器)ベースのシステムは、通常、フルビデオストリームを送信するか、AI 処理のために集中型の GPU リソースに依存する。こうしたシステムは高い精度を提供できるが、スケーリングコストが高く、基幹ネットワーク容量への依存度が大きく、帯域幅が制限された環境には不向きな場合が多い。これに対し、このシステムは、モデル最適化エッジデバイス、デバイス上のリスク評価

ロジック、軽量のMessagePack テレメトリを活用し、通信要件を最小限に抑えつつ検知品質を維持する。

サーバがリアルタイムの輻輳レベルをエッジデバイスに一斉配信し、デバイスが送信動作を適応できるようにする動的な輻輳フィードバックループは、商用監視システムでは一般的に実装されていない特徴的な機能である。この通信環境に適応するメカニズムによりシステムの堅牢性が向上し、厳しいネットワーク環境下においても重要な安全イベントが確実に伝送される。

もう一つの差別化要因は、統一されたテレメトリスキーマの採用である。これにより、人物検知、マスク検知、侵入検知、群衆検知、迷子(子ども、高齢者の立ち入り)検知、火災・煙検知といった様々なシナリオにおけるイベント報告が標準化される。既存の市場製品が提供している孤立した形式や独自仕様のイベントフォーマットとは異なり、このスキーマによりイベント間の相互運用性、データ統合の容易化、自治体・施設間での再現性が実現される。

このソリューションは最終的に、拡張性がある自治体・大規模施設向けのアーキテクチャの導入につながる。これにより、高額なクラウド推論を回避し、高スループットの映像リンクの必要性を低減し、さらに、自治体・施設が大規模なデータセンターや専用光ファイバー回線への投資なしに、安全性を高める AI 機能を導入することを可能にする。このシステムは、既存の集中型監視ソリューションに対する実用的かつ将来を見据えた代替案として位置づけられ、技術的な新規性と明確な運用上の必要性の両方を実証している。

(1) 新規性と優位性の根拠

本ソリューションは、ファアエッジでのリアルタイム AI 推論、テレメトリベースのイベント送信、ネットワーク輻輳を考慮した圧縮方式の選択を特徴とする。従来の監視システムがフル動画ストリームを継続的に送信したり、集中型クラウド推論に依存したりするのは異なり、本システムはリスクレベルとネットワーク状況に基づき、最適化された形式(メタデータ JSON テキスト/画像/映像の一部)でイベント関連データのみを送信する。

この設計の有効性は実証実験で確認された。ファアエッジデバイスでのリアルタイムリスク分析は 50～200 ミリ秒で完了し、全体的なリアルタイム推論は想定遅延範囲である 200～5000 ミリ秒内で動作した。これらの結果は、従来のクラウドベースや集中型ソリューションでは達成困難な、ネットワーク負荷の最小化と低遅延・高精度を両立していることを示している。

(2) 従来ソリューションとの比較

本ソリューションと従来のクラウド型 AI 監視ソリューションの比較を以下の表 5.1-2 に示す。この比較結果は、ここに挙げたすべての項目についての、本ソリューションの優越性を示している。

表 5.1-2 従来ソリューションと提案ソリューションの比較

	従来の監視/クラウド AI	本ソリューション
映像伝送	連続フル動画ストリーミング	イベント検出時のみテレメトリ、画像、または映

		像クリップ送信
ネットワーク適応	固定エンコーディング、輻輳フィードバックなし	ネットワーク状態に基づく圧縮方式の選択
リアルタイム遅延	ネットワークとクラウドの負荷に依存する	ファアーエッジリスク分析では 50~200 ミリ秒
拡張性	ハードウェアまたは帯域幅の拡張が必要	ファアーエッジの交換なしにサーバ側で拡張可能
輻輳ネットワークへの適応性	連続的な映像伝送により性能が低下し、イベント配信が遅延する可能性がある	重要イベントは低容量テレメトリで送信される。信頼性維持のため、輻輳時には映像クリップの送信が抑制される

5.1.4 検証条件

- 地理的・空間的条件
 - カメラ設置地点：ノエビアスタジアム神戸の、監視が必要だが、既存の監視カメラではカバーしきれない地点
 - 理由：固定回線を利用した既存の監視システムのアップデートは大規模な施設改修を伴い、非常に費用がかかるためシステムによる監視が行えない領域が存在する。将来的には、警備員の不足や、人員不足等に伴う監視が不十分な状況になる恐れがあり、安全上のリスクを高まることが懸念されている。
 - エンドユーザアプリケーションによる動作確認：ノエビアスタジアム神戸内
 - 理由：ノエビアスタジアム神戸内勤務の警備員による使用を想定しているため
- 時間的条件
 - 10/16(木)、10/17(金)
 - 理由：本システムは楽天モバイル通信ネットワークの輻輳指標値をモニタリングし、それに応じて圧縮方式を使い分けるが、10/17(金)はヴィッセル神戸のホームゲーム開催日であり、多数の観客が来場することから、ネットワーク輻輳の発生が見込まれるため、ネットワーク輻輳時のデータ量削減率の測定に適している。
 - ネットワーク輻輳時のデータ量削減率測定のための試験は、17 日のネットワーク輻輳が見込まれる時間帯(試合開始前と試合終了後)に、それ以外の試験はそれ以外の時間帯に実施する。
 - なお 17 日の試合開始前と試合終了後に、期待したほどのネットワーク輻輳が発生しなかった、またはネットワーク輻輳度取得がうまくいかなかった場合は、エッジサーバ上で(データベース上で)疑似的に輻輳状態を作り出して試験を実施する。
- リスクイベントの再現方法
 - 人のイベント：カメラの視野内でロールプレイを行うことによりリスクイベントを疑似的に発生させる。
 - 理由：本システムは、本来人がいない場所に人がいることを検知し、さらにその状況をリスクレベルに基づいて分類して圧縮方式を選択する。よって、限られた検証時間帯に対象エリアに人物が侵入しない場合が想定されるため。
 - 炎・煙のイベント：カメラの視野内で、炎・煙の動画をラップトップ PC で再生する。
 - 理由：スタジアム内で実際にその状況を発生させることはセキュリティ上問題があるため。

- 警備担当者によるエンドユーザプリの動作確認と使い勝手に関するアンケート回答
 - 実際の警備業務従事者ではなく、警備員に業務を委託する責任者である施設管理部部長を含むヴィッセル神戸従業員複数名により行われる。
 - 理由 :警備業務について深い知識を持ち、かつ警備業務だけでなくシステム導入等の視点でシステムの評価が可能であるため。

5.1.5 開発・評価項目

本実証における開発・評価項目は、以下の表に示す通りである。

表 5.1-3 開発・評価項目一覧

番号	開発・評価項目
1	ファアーエッジ上ソフトウェア(AWL Engine Agent)の開発
2	エッジサーバ上集約処理(Edge Server Application)の開発
3	エッジサーバ上統合・配信処理(Web API)の開発
4	AI 異常レポート要約エージェント(SLM コンポーネント)の開発
5	エッジサーバ上通信輻雑度取得コンポーネント(Congestion API)の開発
6	エンドユーザアプリケーションの開発
7	ファアーエッジ上 AI パイプラインの精度評価(中間) (1.の精度の測定)
8	ファアーエッジ上 AI パイプラインとの精度評価(実証) (1.の精度の測定)
9	エッジサーバ上 AI 異常レポート要約エージェント(SLM)の精度評価 (4.の精度の測定)
10	ファアーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価 (1., 3., 4.によるデータ削減効果の測定)
11	警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定 (1., 2., 3., 4.による処理速度の測定)
12	エンドユーザアプリケーションを使用した警備担当者からのフィードバック収集 (5.の操作しやすさについての評価)

(1) ファアーエッジ上ソフトウェア(AWL Engine Agent)の開発

1) 開発の目的

本実証では、カメラからの大容量の映像ストリームを継続的に送信する代わりに、AI を使用して映像を軽量の圧縮データに変換して送信する機能が必要である。

そのため、IP カメラと接続されたファアーエッジデバイス上で映像ストリームに対する継続的な AI 推論処理を行い、イベント検出時のみ、推論結果のリスクレベルとネットワーク輻雑度に応じて圧縮方式を選択し、圧縮データをエッジサーバへ送信するファアーエッジ上プロセスを開発する。

この機能の開発により、計算負荷の高い映像に対する推論処理が全てファアーエッジ上で完結し、また高帯域幅の映像ストリーム送信を、イベント情報 JSON を含む軽量の圧縮データ送信に置き換えることにより、通信量の大幅な削減と、異常のリアルタイム検出が可能となる。

機能の詳細については「5.1.2 利用技術・データ」の(3)ファアーエッジ上 ソフトウェア(AWL Engine

Agent)参照。

(2) エッジサーバ上集約処理(Edge Server Application)の開発

1) 開発の目的

ファーエッジ上ソフトウェア(AWL Engine Agent)から送信されたすべての圧縮データは、エンドユーザアプリケーションに配信される前に、エッジサーバ上に永続化される必要がある。なぜならば、バックグラウンド状態にある場合、エンドユーザアプリケーションは基本的にデータ通信ができないため、プッシュ通知によるイベントの要約の受信はできるが、イベント情報、画像、映像クリップなどをエッジサーバから取得できないためである。エンドユーザがプッシュ通知をクリックし、フォアグラウンド状態になったタイミングで、エンドユーザアプリケーションは永続化された圧縮データをエッジサーバから取得することができる。

また、ファーエッジ上ソフトウェア(AWL Engine Agent)がネットワーク輻輳度に応じた映像圧縮方法を選択するためには、ファーエッジ上ソフトウェア(AWL Engine Agent)にネットワーク輻輳度を配信する機能が必要となる。そのため、ファーエッジ上ソフトウェア(AWL Engine Agent)から送信されたすべての圧縮データのエッジサーバへの保存、エッジサーバ上統合・配信処理(Web API)へのデータ受信の通知、ファーエッジ上ソフトウェア(AWL Engine Agent)への輻輳度の配信などを行う、エッジサーバ上プロセスを開発する。

この機能の開発により、ネットワーク輻輳度に応じた映像圧縮、圧縮データのエッジサーバへの永続化などが可能となる。

機能の詳細については「5.1.2 利用技術・データ」の(5)エッジサーバ上集約処理(Edge Server Application)参照。

(3) エッジサーバ上統合・配信処理(Web API)の開発

1) 開発の目的

エッジサーバ上の要約レポート、イベント情報、画像、映像クリップは、警備担当者が閲覧できるようにする必要がある。また警備担当者がリアルタイムで状況を把握できるように、要約レポートはイベント発生直後に警備担当者にプッシュ通知で配信される必要がある。そのため、要約レポートをエンドユーザアプリケーションに Firebase Cloud Messaging (FCM)によるプッシュ通知で配信する機能、またイベント情報、画像、映像クリップを、エンドユーザアプリケーションからの要求に応じて返す機能を持つ Web API を開発する。

この機能により、警備担当者は異常レポートの受信と、異常詳細情報の確認ができるようになる。

機能の概要については「5.1.2 利用技術・データ」の(6)エッジサーバ上統合・配信処理(Web API)参照。

2) 検証手順・測定手法・計測項目

各 API は、開発完了後に以下のようにして試験を実施する。

- POST 処理
 - 単体試験：API 呼び出し後の MongoDB 保存データ(と FCM メッセージ)の内容を、API 引数と比較
 - パフォーマンス試験：Postman、Curl コマンドを使用してレスポンス時間を測定
- GET 処理
 - 単体試験：API 呼び出し前の MongoDB データとレスポンス JSON の比較
 - パフォーマンス試験：Curl コマンドを使用してレスポンス時間を測定

3) ユーザアプリケーションへの情報提供方法

システムが検知した状況に応じて、ユーザアプリケーションへの情報提供方法を最適化する。これにより、警備担当者は状況認識能力を向上させ、迅速かつ適切な対応が可能となる。

- 定期通知(リスクなし): 15 分ごとに、システムが検知した状況の概要を SLM で生成し、簡潔にテキスト方式で報告する。これにより、担当者は継続的に状況を把握し、異常の兆候を早期に発見できる。
- 異常通知(低リスクイベント): システムは、即座にイベント状況説明文を SLM で生成し、該当イベントの画像とともに表示する。これにより、担当者は迅速に状況を把握し、円滑な初動対応を実行できる。
- 異常通知(高リスクイベント): 上記に加え、ネットワークの混雑度が低い場合には、警備担当者はエンドユーザアプリケーション上で映像再生ボタンをクリックすることで、エッジサーバからイベントの映像クリップを取得できる。これにより、担当者はより詳細な状況を把握し、的確な判断と対応を行うことができる。

(4) AI 異常レポート要約エージェント(SLM コンポーネント)の開発

1) 開発の目的

本実証では、ファーエッジにおいて映像ストリームから圧縮生成されたイベント情報 JSON に対して第二段階のデータ圧縮を行うため、さらに警備担当者による異常の検知、状況の把握を可能にするために、イベント情報 JSON を、よりデータサイズが小さく、かつエンドユーザの理解が可能な要約レポートに変換する必要がある。

そのため、SLM(Rakuten AI 2.0 Mini Instruct)を使用して、一つまたは複数のイベント情報 JSON の要約レポートを生成する機能を開発する。開発においては、プロンプトエンジニアリングや、データ整形処理、誤り訂正処理(フィードバックループ)などの実装、精度向上のための LoRA による SLM のファインチューニングの実施などを行う。

この機能の開発により、警備担当者は、プッシュ通知で簡潔な異常レポートを確認できるようになる。

機能の詳細については「5.1.2 利用技術・データ」の 5.1.2(7) AI 異常レポート要約エージェント(SLM コンポーネント)参照。

(5) 通信輻輳度取得コンポーネント(Congestion API)の開発

1) 開発の目的

楽天モバイルのネットワーク運用支援システム(OSS)のAPIから取得可能されたネットワーク輻輳指標値は、ネットワーク輻輳度(0/1)に変換した上で、ファアエッジへのブロードキャスト処理で使用可能な状態にする必要がある。また取得された指標値には現在の仕様では約1時間遅延があるため、何らかの方法で実際に近い値に変換する必要がある(詳細は非公開)。

そのため、OSS APIから取得したネットワーク輻輳指標値(1時間遅延値)に基づき、予測アルゴリズムを適用した輻輳判定(0/1)を行い、MongoDBに保存するエッジサーバ上に配置する通信輻輳度取得コンポーネント(Congestion API)を開発する。

これにより、エッジサーバ上集約処理(Edge Server Application)によるファアエッジへのネットワーク輻輳度(0/1)のブロードキャスト処理と、ファアエッジ上ソフトウェア(AWL Engine Agent)による、ネットワーク輻輳度に応じた圧縮方法の選択が可能となる。

2) 前提条件

本プロジェクトにおける課題として、OSS APIから取得可能な指標値が約1時間遅延することがあげられる。スタジアムのような環境では、試合展開等による急激なトラフィック変動や輻輳が発生するため、この遅延に対して、あらかじめ考慮した適切な対策を講じることが必要である。

3) Congestion APIによる指標値の計測

a. 詳細な計測項目

- 1) OSS APIから取得する指標値
 - (ア) ダウンリンク物理リソースブロック利用率
 - (イ) 最大接続ユーザ数
- 2) セクターダウンリンクスループット予測アルゴリズム適用後の予測指標値
 - (ア) 予測ダウンリンク物理リソースブロック利用率
 - (イ) 予測最大接続ユーザ数
 - (ウ) 予測セクターダウンリンクスループット
- 3) 判定項目
 - (ア) 予測輻輳判定結果(0:非輻輳, 1:輻輳)

b. 測定手法・検証手順等:

- 1) 毎時15分毎にOSS APIから指標値を取得し、輻輳判定を行うCongestion APIを開発。
- 2) 取得した指標値を基に予測アルゴリズムを適用した予測指標値を生成

- 3) 生成した予測指標値を基に予測輻輳状態を生成。これらのデータを MongoDB に格納し、WebAPI を通じてアクセスする。

【輻輳値(0/1)生成ロジックの概要】

予測輻輳状態の最終的な 0 または 1 の判定は、以下のロジックに基づいている。

まず、観客数連動型中央値予測によって算出された 3 つの予測指標値が、それぞれ事前に定義された輻輳閾値と比較される。この際、いずれか一つの予測指標値が閾値を超過した場合、システムは「輻輳状態 (1)」と判定する。どの指標値も閾値を超過しない場合は「非輻輳状態 (0)」と判定され、この結果が MongoDB に格納され、格納された値は WebAPI により取得される。

4) 輻輳判定基準の定義と根拠

本プロジェクトにおいては、以下の 3 つの要件の内、一つでも閾値を超過した場合に、「輻輳(1)」と定義している。

- 1) 予測ダウンリンク物理リソースブロック利用率 > 70%
- 2) 予測最大接続ユーザ数 > 150
- 3) 予測セクターダウンリンクスループット < 20Mbps

これらの閾値は、本実証における輻輳指標として使用するのに適するよう、楽天モバイルの実際の性能値から調整されたものである。本 Congestion API は、これらの指標を用いてリアルタイムに近いネットワーク混雑状況を予測し、ファームウェアにおける最適な圧縮方法の選択など、監視システムの自律的な動作決定を支援することを目的としている。

4) 予測アルゴリズムの仕様と観客数連動型中央値予測の優位性

本プロジェクトにおける予測アルゴリズムの選定は、現行のデータ環境と予測対象の特性を評価した結果、「観客数連動型中央値」を用いた予測手法が最も合理的かつ実用的であると結論付けられる。

- 1) 観客数連動型中央値予測採用の論理的根拠と、限られたデータからのアルゴリズム構築アプローチ:

(ア) 限られたデータ環境下での課題と克服戦略:

現行の予測モデル構築において、表 5.1-4 に示す 6 試合分という限定的なデータ量は、高度な時系列予測モデル(例:ARIMA モデル、LSTM、Prophet など)の適用は困難である。これらのモデルは、トレンド、季節性、周期性、自己相関などの複雑なパターンを学習するために、通常、数十から数百、あるいはそれ以上の観測点(試合データや時間ごとの KPI データ)を必要とする。限られたデータでの複雑なモデル学習は、統計的有意性の欠如や過学習のリスクを高め、信頼性の低い予測を生成する可能性が高い。

この課題に対し、本プロジェクトでは以下の観点により、予測アルゴリズムの生成とシミュレーション可能な状態を追求した。

(イ) 指標値の粒度向上とアクティブユーザ数に着目:

6 試合という試合単位のデータが限定的である一方で、各試合における時間帯ごとの指標値

(15 分間隔の予測ダウンリンク物理リソースブロック利用率, 予測最大接続ユーザ数, 予測セクターダウンリンクスループット)は、捕捉時間(16:00-22:00 の 6 時間)全体で数百件のデータとなり得る。さらに単なるユーザ端末数だけでなく、アクティブユーザ数(同時接続数)に着目し、その変動パターンを詳細に分析することで、より微細な人流データと通信需要の相関を捉えることが可能になる。これにより、試合単位のデータ不足を、時間単位のデータ量で補完し、予測の精度を高める基盤を構築した。

アクティブユーザ数(同時接続数)は、RRC (Radio Resource Control) Connected、すなわち無線リソース制御接続状態にある端末の総数を指す。これはデータ送受信中のユーザに加え、すぐに通信可能な待機状態のユーザも含む。

表 5.1-4 ノエビアスタジアム神戸観客数(出典:ヴィッセル神戸公式サイト)

日付	観客数(人)
2025/08/16	23,166
2025/08/30	23,198
2025/09/07	6,171
2025/09/12	15,051
2025/09/23	17,132
2025/09/27	18,914

(ウ) 観客数レンジによるデータプール拡張:

6 試合の観客数データ(表 5.1-4 参照)を分析すると、

- ・ 6,171 人(低観客数)
- ・ 15,051 人~18,914 人(中観客数)
- ・ 23,166 人~23,198 人(高観客数)

の 3 つの明確なレンジが存在する。

本プロジェクトでは、この観客数レンジごとに過去の指標値を集約・分類した。これにより、各レンジの特性に合わせた指標値の「代表値」を算出するための統計的な安定性を確保し、予測アルゴリズムの精度向上を図った。観客数という主要な外部要因でデータを層別化することで、個々の観測データは少なくなるものの、より均質なデータグループから中央値を算出することが可能となり、結果として各観客数レンジにおける指標値の予測精度が向上した。

後述の通り、突発的なイベントによる外れ値の影響を最小限に抑えるため、算術平均ではなく中央値を採用することで、限られたデータ環境下でも信頼性の高いロバストな統計量である「中央値」を採用し、予測精度を追求した。これが予測アルゴリズムの基盤を生成する上で重要なアプローチとなる。

(エ) スタジアム環境下の指標値特性と中央値の優位性:

スタジアム環境下の指標値は、突発的なイベントにより「外れ値」が発生しやすい特性を持つ。このようなイベントには、

- ・ 試合開始直前の入場集中
- ・ 得点時や試合終了後の SNS 投稿やメッセージ交換の急増

- ・ ハーフタイム中の Web 閲覧や動画視聴
- ・ アリーナイベントにおける特定アーティストの登場時

など、観客の同時多発的な通信行動を誘発するあらゆる瞬間が考えられる。このようなデータ特性に対し、算術平均(例:単純移動平均や指数平滑移動平均)は外れ値の影響を受けやすい。これに対し、「中央値」は外れ値の影響を受けにくいロバストネスな統計量であり、データ全体の中心傾向を正確に反映可能である。

(オ) 観客数連動型中央値予測の優位性:

高度な時系列モデルの適用が困難な限定的なデータ環境下において、試合ごとの時間帯別指標値とアクティブユーザ数に着目し、観客数レンジによるデータプールの拡張戦略を用いることで、予測アルゴリズムの生成とシミュレーションが可能な状態を追求した。さらに、突発的な外れ値の影響を排除し、ロバストに中心傾向を捉えることができる観客数連動型中央値予測は、現段階で最も信頼性の高い予測精度の提供が可能で、かつ実用性に優れた選択肢であるといえる。

2) 観客数連動型中央値予測による精緻化と輻輳リスクの可視化

本プロジェクトでは、単一の中央値に留まらず、観客数という主要な外部要因を連動させることで、中央値予測の精度と実用性を向上させた。観客数と指標値との間に強い相関関係が存在することは、以下のグラフ(図 5.1-8)によって示される。

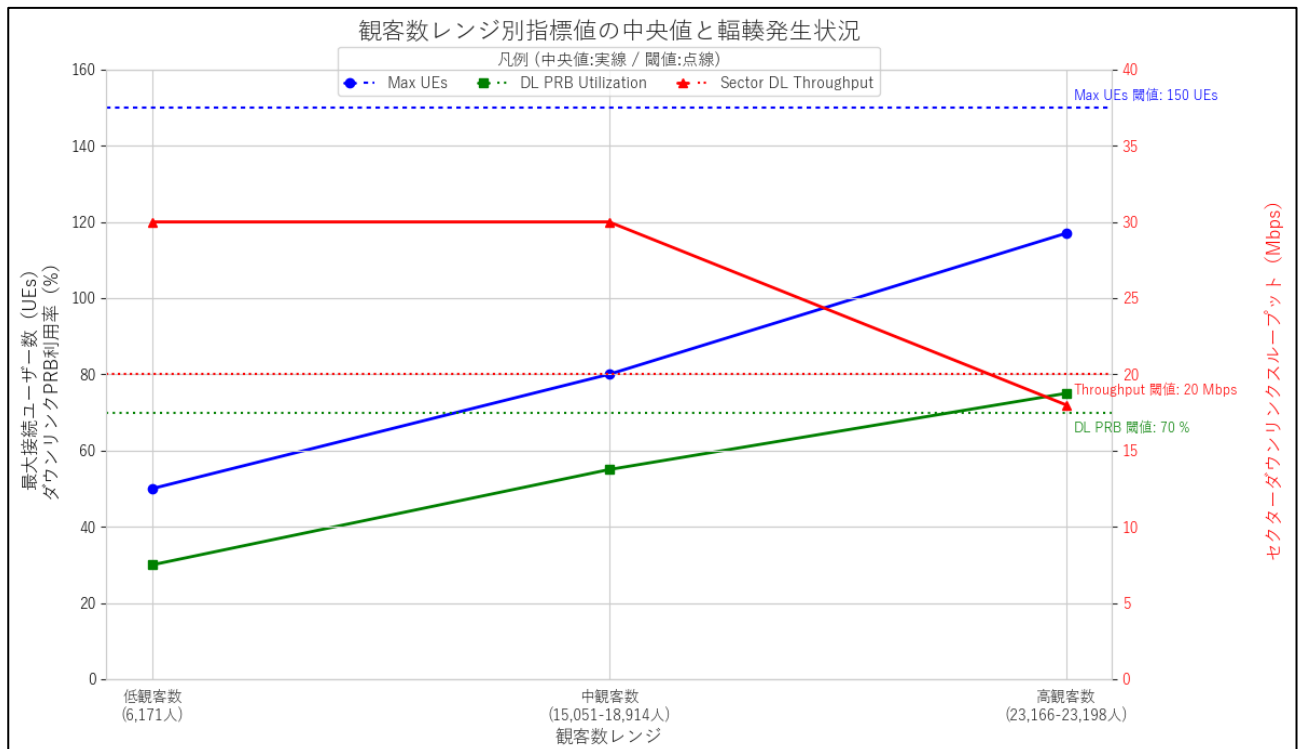


図 5.1-8 観客数レンジ別指標値の中央値と輻輳発生状況

各指標値の中央値は、当該観客数レンジに該当する試合および試合前後の時間帯(16:00-22:00)データから算出。

図 5.1-8 は、提供された 6 試合の観客数データに基づき、観客数が増加するにつれて最大接続ユーザ数およびダウンリンク物理リソースブロック利用率の中央値が顕著に上昇し、輻輳発生頻度が増すことを明確に示している。

- (ア) 低観客数レンジ(6,171 人)の試合では、全ての中央値が輻輳閾値を大きく下回り、輻輳は全く観測されなかった。
- (イ) 中観客数レンジ(15,051 人～18,914 人)では、大接続ユーザ数中央値が70UEsを超え、ダウンリンク物理リソースブロック利用率中央値も 55%に達したものの、輻輳発生の兆候は見られない。高観客数レンジ(23,166 人～23,198 人)の試合では、ダウンリンク物理リソースブロック利用率中央値が 75%と輻輳閾値を超過。セクターダウンリンクスループット中央値は 18Mbps と、輻輳閾値の 20Mbps を下回っている。実際に、2025/08/16 と 2025/08/30 の両試合において、全指標値で輻輳閾値超過が複数回観測されている

5) 結論

本 Congestion API 開発における予測アルゴリズムの選定は、ノエビアスタジアム神戸における限定的なデータ環境(6 試合分)と、スタジアム特有の突発的な通信需要変動という指標値特性を詳細に分析した結果、観客数連動型中央値予測が最も合理的かつ実用的な解であると結論付けられる。

この手法は、提供された 6 試合の観客数データと指標値の相関分析により、観客数増加に伴う指標値変化と輻輳リスクの明確な傾向が数値的に裏付けられたことに基づいている。データ量の制約下で予測精度と信頼性を両立させるため、観客数レンジによるデータ分類と外れ値の影響を受けにくい中央値の採用を通じ、統計的に頑健な予測手法を追求した。これにより、イベントの規模を考慮したより実態に即した予測を提供し、輻輳リスクをシミュレーションによって事前に評価できる状態を確立することで、ネットワーク運用における適切な意思決定を支援することが可能となる。

(6) エンドユーザアプリケーションの開発

1) 開発の目的

Web API から送信されたイベント要約レポート、イベント情報、画像、映像クリップは、警備担当者が携帯端末により確認できるようにする必要がある。

そのため、Web API から送信されたイベント要約レポートの FCM プッシュ通知を表示し、またエンドユーザが通知をタップした場合は、Web API からイベント詳細情報、画像、映像クリップを取得して表示する、エンドユーザデバイス(スマートフォン、スマートグラス)上で動作するアプリケーションを開発する。

当機能により、警備担当者はリアルタイムでの異常発生地点の状況(異常通知)、またはスタジアム全体の状況(定期通知の場合)の把握と、以上に対して適切なアクションを取ることが可能となる。

スマートフォンアプリ、スマートグラスアプリの概要は以下のとおりである。

- a スマートフォンアプリ

- (ア) 機種: SHARP AQUOS R5G
 - (イ) OS: Android 11
 - (ウ) 開発環境、言語: Unity, C#
 - (エ) コンテンツ表示方式: UI のみを 2D 表示する。
- b スマートグラスアプリ
- (ア) 機種: Apple Vision Pro (256GB, MQL83J/A)
 - (イ) OS: visionOS 2
 - (ウ) 開発環境、言語: Xcode, Swift
 - (エ) コンテンツ表示方式: 実空間にオーバーレイする形で UI を AR 表示する

機能の概要については「5.1.2 利用技術・データ」の(13)エンドユーザアプリケーション参照。

(7) ファーエッジ上 AI パイプラインの精度評価(中間)

1) 評価の目的

この中間測定・評価は、AI パイプラインの開発完了に伴う、要件定義への適合性およびパフォーマンス指標を確認することを目的として実行される。

目標は、非運用条件下における各 AI 検出モジュールの機能的な挙動を確認し、ベースラインとなる性能特性を確立することである。

これらの評価結果は、最終的な KPI 目標を満たすことを意図したものではなく、技術的な限界、ならびにデータ品質や環境要因に対する感度を特定するために用いられた。

2) 検証概要

各評価対象イベントについて、事前に定義されたテストイベントに基づいて、検出精度、未検出率、誤検出率などの指標を測定した。

- 試験対象のカメラ : 明るい照明条件下での単一カメラ構成を使用
- 評価対象: スタジアムの事前録画映像および公開テストデータセットを使用した制御環境下の試験
- 評価対象イベント種別:侵入、マスク、侵入(2人超)、火・煙、子ども・高齢者検出

3) 検証手順

検証は、推論中に AI モデルによって生成されたテレメトリデータと、対応するテストビデオデータのために用意された事前アノテーション済みのグラントゥールス(真値)テレメトリを比較することで実施された。

各テストケースにおいて、ファーエッジ AI パイプラインが出力したイベント種別、検出タイミング、および分類結果をリファレンスアノテーションと照合し、見逃し(未検出)、誤検出、分類エラーを特定した。この比較により、制御された条件下でのモデルの挙動の客観的な評価が可能となり、期待される結果と実際の AI 推論結果との一貫性が確認された。

4) 測定項目

測定項目と結果(正解率のみ)については以下の表に示す通りである。

表 5.1-5 ファーエッジ AI パイプライン 中間評価項目・結果

評価項目	中間評価結果
侵入検知(10秒未満/10秒以上)	正解率 約 95-97%
群衆検知	正解率 約 99%
マスク検知	正解率 約 23%
火災・煙検知	正解率 約 6% (模擬シーン)
子ども・高齢者検知	正解率 約 65-70%
リスクアセスメント (ロジック層)	約 90%の正しい分類
処理の遅延	約 50~500 ミリ秒

侵入検知から子ども・高齢者検知までの測定項目の詳細については、(8)ファーエッジ上 AI パイプラインの精度評価(実証)、リスクアセスメントについては 5.1.6 KPI/KGI の(5)AI パイプラインによる検出の精度 - 3)、KPI 項目詳細 - d リスクアセスメント、処理の遅延については 5.1.6 KPI/KGI の(7)ファーエッジ推論の遅延時間参照。

(8) ファーエッジ上 AI パイプラインの精度評価(実証)

1) 評価の目的

AI パイプラインが実環境において、実用的な精度(未検知率・誤検知率)で異常検知ができるかを判定するために、ノエビアスタジアム神戸に 3 章に示した構成で AI システムを構築の後、スタジアムにおいて検証を実施する。

2) 検証概要

本システムは、本来人がいない場所に人がいることを検知するものであり、限られた検証期間中に不審者がエリアに侵入しない可能性があるため、ロールプレイによりリスクイベントを疑似的に発生させる。また実際の侵入者は、一方向からではなく様々な方向からカメラ視界内に侵入と思われるため、ロールプレイでも複数の方向(8 方向)からカメラ視界内に侵入する。

炎・煙イベントの検知に関しては、スタジアム内で実際にその状況が発生させることは危険であるため、炎・煙の動画を使用して検証を実施する。

- 試験場所、タイミング：ノエビアスタジアム神戸、全システム開発完了後
- 試験対象のカメラ：多様な照明条件を網羅するため、10 台すべてを使用する。
- 評価対象：ロールプレイ以外の、たまたまスタジアムスタッフなどがカメラに映り込んだことにより発生したイベントは評価対象外とする。
- 評価対象イベント種別：全種別(1 人かつ 10 秒未満、2 人以上、1 人かつ 10 秒以上、1 人かつマスクあり、1 人かつ 10 歳未満、1 人かつ 70 歳以上、炎・煙)
 - 「2 人以上」イベントについては、2 人一組でロールプレイを行う。

3) 検証手順

人のイベントのロールプレイは、楽天モバイル従業員、AWL 従業員または試合当日(17 日(金))スタジアムで募ったボランティア参加者(10 歳未満、70 歳以上のテストケース)により行われる。ボランティア参加者本人(70 歳以上のテストケース)またはその親権者(10 歳未満のテストケース)には、肖像権使用同意書に記入、署名してもらう。

人のイベントのロールプレイでは、ロールプレイを行う人は、下図に示す 8 方向からカメラの視界内に侵入する。

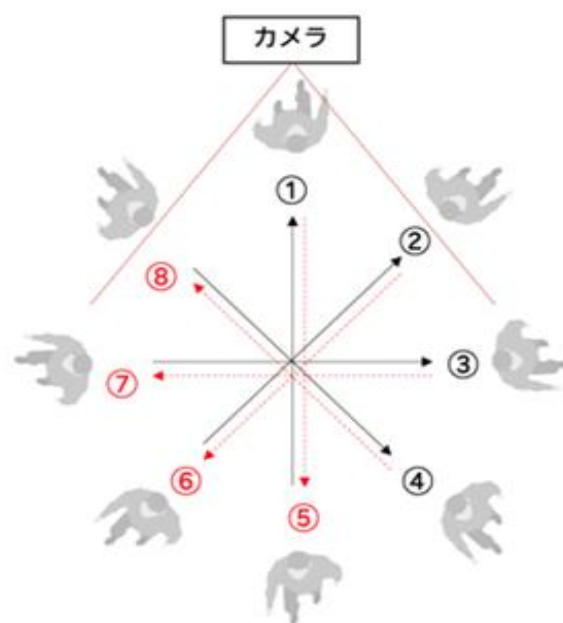


図 5.1-9 ロールプレイ時の侵入方向



図 5.1-10 エリア#6 における「立ち入り 10 秒未満」イベントロールプレイの様子

炎・煙のイベントについては、事前に用意した 5 つの炎・煙動画の内の 1 つをラップトップ PC 上で再

生し、それをカメラの視界内に入れる。




図 5.1-11 エリア#1 における「炎・煙」イベントロールプレイの様子



図 5.1-12 「炎・煙」イベントロールプレイに使用された動画

4) 測定項目

a. 侵入検知(10 秒未満 / 10 秒以上)

(ア) 目的

AI パイプラインが制限区域への侵入者を正しく検知し、侵入時間を低リスク(10 秒未満)または高リスク(10 秒以上)に正確に分類できることを検証する。この評価により、テレメトリが確実に生成され、誤分類、未検知、不要なアラート生成が許容範囲内に収まることを保証する。

(イ) 測定項目

① 検知精度

- ② 未検知(偽陰性)率:有効な侵入が検出されなかった、またはテレメトリで報告されなかった場合
- ③ 誤検知(偽陽性)率:侵入が発生していないのに侵入を報告するテレメトリ、または誤分類(10秒未満を10秒以上と報告、またはその逆)
- ④ 誤った検知タイプ(低リスクと高リスクの誤分類)
- ⑤ テレメトリ生成と送信の信頼性

(ウ) 測定方法

低リスク(10秒未満)と高リスク(10秒以上)の制限区域侵入のロールプレイを、照明条件、カメラからの距離、侵入角度を変化させて実施した。詳細は a.「検証概要」b.「検証手順」参照。

各テストケース中、AI パイプラインが生成したテレメトリを収集し、テストケース仕様で定義された期待される結果と比較した。検証では以下に焦点を当てた。

- 侵入イベントが生成されたかどうか
- 報告された継続時間とリスクレベルが想定カテゴリと一致しているか
- 誤った侵入イベントや不要な侵入イベントが生成されていないか
- テレメトリフィールド(タイムスタンプ、侵入タイプ、リスク)が要求される一貫性と完全性を満たしているか
- エッジサーバのテレメトリがファーエッジデバイスと一致しているか
- ファーエッジテレメトリのタイムスタンプとエッジサーバテレメトリのタイムスタンプを比較して、遅延を測定する。

各テストケースシナリオにおいて、テレメトリ出力が期待される結果と一致しているかを確認することで、誤検知(偽陽性)と未検知(偽陰性)を特定した。

b. 群衆検知

(ア) 目的

カメラの視野内に2人以上の個人が存在するシナリオをシステムが正確に検知し、高リスクの群衆イベントを正しく生成することを検証する。

マルチターゲット検出精度は、カメラの視野内で複数の個人を同時に正しく識別・追跡するシステムの能力を評価する。この測定は、AI パイプラインが常に存在する個人をすべて検出できるか、フレーム間で安定した識別を維持できるか、特に人々が一緒に入場したり、密接して歩いたり、部分的に互いを遮蔽したりする場合に、重なり合ったり近接したターゲットを分離できるか、個人の見落としがないかに焦点を当てる。

(イ) 測定項目

- ① マルチターゲット検出精度
- ② 重なり合ったまたは近接したターゲットの分離
- ③ カメラ視野内の個人の誤検出回数
- ④ 誤検知(偽陽性)率:2人未満の人がいるのに、テレメトリが群衆イベントを報告する
- ⑤ 未検知(偽陰性)率:2人以上がいるのに混雑イベントを報告しない

(ウ) 測定方法

「2人以上」のロールプレイを、2人の役者により、侵入間隔・移動パターン・相対位置を変化させて実施した。詳細は a.「検証概要」b.「検証手順」参照。テストには並行侵入、時差侵入、一時的重複、遮蔽が含まれていた。

各テストケース中、AI パイプラインが生成したテレメトリを収集し、テストケース仕様で定義された期待される結果と比較した。検証では以下に焦点を当てた。

- 2人以上の個人の正確な認識
- テレメトリにおける正確な検出数
- 重なり合ったまたは近接した対象の安定した追跡と分離
- 偽陽性と偽陰性の特定

イベントの継続性は、連続するフレームにわたるテレメトリを確認することで検証され、シナリオ全体を通じて両個人の検出が一貫していることを保証した。

c. マスク検知

(ア) 目的 : AI パイプラインが、検知した個人がマスクを着用しているかどうかを正確に判断できることを検証する。

(イ) 測定項目

- ① 未検知(偽陰性)率: マスクを着用しているにもかかわらず、マスク着用と分類できなかったケース
- ② 誤検知(偽陽性)率: マスクを着用していないにもかかわらず、誤ってマスク着用と判定されたケース
- ③ 誤った分類イベント: テストケースで定義された想定マスク状態と、テレメトリにおけるマスク分類出力との間に不一致が生じた場合。これには偽陽性・偽陰性に加え、マスク状態予測の不整合や断続的な予測(予測が不安定または一貫性を欠く)も含まれる。

(ウ) 測定方法

マスクあり、またはマスクなしのケースを含むロールプレイを、照明条件、移動方向などを変化させて実施した。詳細は a.「検証概要」b.「検証手順」参照。

各テストケース中、AI パイプラインが生成した、分類フラグ(マスク=真/偽)を含むテレメトリを収集し、テストケース仕様で定義された(マスクあり/なし)期待される結果と比較した。

d. 火災・煙検知

(ア) 目的 : 火災または煙の危険をリアルタイムで検知する能力を検証する。

(イ) 測定項目

- ① 5つのテストパターンにおける検知精度 : 事前定義された5つの火/煙動画ごとの精度評価。評価には誤検知(偽陽性)と未検知(偽陰性)を含む
- ② 未検知(偽陰性)率: 火・煙が動画内に表示されているにもかかわらず検知されない、または対応するテレメトリが生成されない場合。
- ③ 誤検知(偽陽性)率: 火・煙が動画内に表示されていないにもかかわらず検知された、または意図した評価時間枠外で検知が発生した場合。

(ウ) 測定方法

事前に定義された 5 種類の火・煙テスト動画を使用して、様々なスタジアム照明条件下でロールプレイを実施した。詳細は a.「検証概要」b.「検証手順」参照。これらの動画は、異なる火・煙の外観パターンと運動特性を表していた。

各テストケース中、AI パイプラインが生成したテレメトリを収集し、テストケース仕様で定義された期待される結果と比較した。検証では以下に焦点を当てた。検証では以下に焦点を当てた。

- 火・煙イベントの正しいトリガー
- バウンディングボックスとメタデータの適切な存在
- 定義された評価時間枠外での検出がないこと

e. 子ども・高齢者検知

(ア) 目的：AI パイプラインが、頭部と顔の特徴に基づいて、特に子ども(10 歳未満)と高齢者(70 歳以上)の年齢層に属する人物を正しく識別できることを検証する。

(イ) 測定項目：

- ① 年齢カテゴリ分類精度：人物を正しい年齢カテゴリ(子ども、成人、高齢者)に分類する頻度を測定する。これは子ども・高齢者以外のテストケースを含む全テストケースにおける正しい分類の割合を示す。
- ② 誤分類率：システムが誤った年齢層を割り当てる頻度を測定する(例：児童を成人と分類、高齢者を成人と分類)。これには以下が含まれる。
- ③ 未検知(偽陰性)率：子ども/高齢者を誤って成人と分類した場合
- ④ 誤検知(偽陽性)率：成人を誤って子ども/高齢者と分類した場合

(ウ) 測定方法

「10 歳未満」「70 歳以上」を含むロールプレイを、照明条件、動き、外見、姿勢、カメラからの距離、侵入角度を様々な変化させて実施した。詳細は a.「検証概要」b.「検証手順」参照。

各テストケース中、AI パイプラインが生成した、年齢カテゴリ(子ども/大人/高齢者)を含むテレメトリを収集し、テストケース仕様で定義された(子ども/大人/高齢者)期待される結果と比較し、以下のように予測結果を分類した。

- 正解：正しいカテゴリに分類した場合
- 偽陰性：子ども/高齢者を誤って成人と分類した場合
- 偽陽性：成人を誤って子ども/高齢者と分類した場合

年齢カテゴリ分類精度と誤分類率は、これらの結果に基づいて算出された。

(9) エッジサーバ上 AI 異常レポート要約エージェント(SLM)の精度評価

1) 評価の目的

警備担当者が要約レポートにより、正しく現場の状況を把握できるか判定するために、AI 異常レポート要約エージェント(SLM)による出力の精度の評価を実施する。

2) 検証概要

(8)の AI 精度検証とほぼ同じ手順で検証を実施する。

- 試験場所、タイミング：ノエビアスタジアム神戸、全システム開発完了後
- 評価対象：
 - 定期通知：試験期間中に生成された全定期通知
 - 異常通知：(8)、(10)ファアーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価の全ロールプレイ
- 評価対象イベント種別：全種別(1人かつ10秒未満、2人以上、1人かつ10秒以上、1人かつマスクあり、1人かつ10歳未満、1人かつ70歳以上、炎・煙)

3) 検証手順

ノエビアスタジアム神戸における実証実験後に、AI 異常レポート要約エージェントが要約生成時に出力するログを元に測定項目の集計を行う。

4) 測定項目

以下の項目について、ログを確認・結果を集計することにより算出する。

(ア) 異常通知正解率(フィードバックループなし)

フィードバックループなしの場合、警備担当者が異常を正しく把握できるか判定する。

(イ) 異常通知正解率(フィードバックループあり)

フィードバックループありの場合、警備担当者が異常を正しく把握できるか判定する。

(ウ) 定期通知正解率(フィードバックループなし)

フィードバックループなしの場合、警備担当者がどの地点に異常が発生していないかについて、正しく把握できるか判定する。

(エ) 定期通知正解率(フィードバックループあり)

フィードバックループありの場合、警備担当者がどの地点に異常が発生していないかについて、正しく把握できるか判定する。

(10) ファアーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価

1) 評価の目的

当ソリューションのデータ削減能力を定量的に評価することが目的である。

具体的には、以下の削減効果を測定する。

- IP カメラの映像フィードをファアーエッジ上 ソフトウェア(AWL Engine Agent)により、リスクレベルと通信輻輳度に応じた圧縮方式で変換することによるデータ削減効果
- エッジサーバ上 AI 異常レポート要約エージェント(SLM コンポーネント)のデータ要約と、エッジサーバ上統合・配信処理(Web API)のデータ集約によるデータ削減効果

2) 検証概要

(8)の AI 精度検証とほぼ同じ手順(ロールプレイ)で検証を実施する。

- 試験場所、タイミング：ノエビアスタジアム神戸、全システム開発完了後
- 試験対象のカメラ：
 - (2) ネットワーク混雑時に中圧縮方式の使用を避けることによるファーエッジ⇒エッジサーバデータ送信削減率：2 か所
 - 試験時間帯(試合前、試合後)に、試合準備や撤収作業のための関係者出入りが多い地点や、選手などが使用するため立ち入り禁止となる地点は避ける。
 - それ以外：10 台すべてを使用する。
- 結果確認方法：ロールプレイ後に、エッジサーバ上 MongoDB に記録された受信/送信ログデータからデータ削減率を算出する。
- 評価対象：ロールプレイ以外の、たまたまスタジアムスタッフなどがカメラに映り込んだことにより発生したイベントは集計対象外とする。
- 評価対象イベント種別：1 人かつ 10 秒未満、2 人以上、1 人かつ 10 秒以上、1 人かつマスクあり、炎・煙の 5 種類

3) 検証手順

人のイベントのロールプレイでは、7)の AI 精度検証とは異なり、ロールプレイを行う人は、8 方向ではなく、「図 5-10 ロールプレイ時の侵入方向」内の①、②に対応する 2 方向からカメラの視界内に侵入するように、手順を簡略化する。これは、本検証の目的はデータ削減率の算出であり、異常検知 AI の汎用性の検証ではないためである。

また炎・煙のイベントについては、7)の AI 精度検証とは異なり、「図 5.1-11 エリア#1 における「炎・煙」イベントロールプレイの様子」の内の①、②に対応する 2 つの炎・煙動画の 1 つをラップトップ PC 上で再生し、それをカメラの視界内に入れる。

ロールプレイにより、エッジサーバ上 MongoDB には、以下の 2 種類の受信/送信データ量ログが記録される。

- ① 受信データ量ログ：(5)エッジサーバ上集約処理(Edge Server Application)により、ファーエッジからのデータ受信時に記録される。記録項目はデータサイズ、データ種別(テキスト(JSON イベント情報)/ 画像 / 映像クリップ)、受信日時などである。
- ② 送信データ量ログ：(6)エッジサーバ上統合・配信処理(Web API)により、エンドユーザーアプリケーションへのデータ受信時に記録される。記録項目はデータサイズ、データ種別(テキスト(SLM 要約レポート) / 画像 / 映像クリップ)、送信日時、送信先端末 ID などである。

上記データ量ログを元に、4) 検証項目に記載する 3 種類の KPI を算出する。

4) 検証項目

a. ファーエッジ上映像圧縮プロセスによるデータ削減率

算出方法：1 - ①「ある期間中に全ファーエッジからエッジサーバに送信されたデータ量の合計」 / ②「圧縮なしの場合、その期間中に送信されるはずだった映像ストリームのデータ量」により算出される。

- ① a 受信データ量ログから算出
- ② 一般的な監視カメラが一般的な映像品質で映像ストリームを継続的に配信したと仮定した場合のビットレートと試験期間から算出

b. ネットワーク混雑時に中圧縮方式の使用を避けることによるファーエッジ⇒エッジサーバデータ送信削減率

算出方法：1 - ③「ある期間中(ネットワーク輻輳時)に全ファーエッジからエッジサーバに送信されたデータ量の合計」 / (③ + ④「その期間中に(ネットワーク輻輳中でなければ)送信されるはずだった映像クリップデータ量」)

- ③ ①と同様に算出
- ④ 「a 受信データ量ログから算出した、映像クリップデータの平均サイズ × 試験期間中のハイリスキイベントの件数」により算出

c. エッジサーバからエンドユーザへの情報集約によるデータ削減率

算出方法：1 - ⑤「ある期間中にエッジサーバからある 1 台のエンドユーザデバイスに送信されたデータ量の合計」 / ⑥「ある期間中に全ファーエッジからエッジサーバに送信されたデータ量の合計」

- ⑤ ①③と同様に算出
- ⑥ b 送信データ量ログから算出

(11) 警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定

1) 評価の目的

スマートグラスアプリは、スマートフォンアプリと異なり端末を手にとらずに即座にイベントを確認できるため、ユーザ反応時間がスマートフォンアプリよりも短いはずである、という仮説の検証のため、それぞれの端末について反応時間 KPI を測定する。

2) 検証概要

警備員に業務を委託する責任者である施設管理部部長を含むヴィッセル神戸従業員 2 名は、Apple Vision Pro の使用方法について簡単なレクチャーを受けた後、スマートフォン・スマートグラスアプリを使用して、楽天モバイル従業員のロールプレイによるイベントを確認する。その後、自動記録されたユーザ操作ログデータから反応時間を計測する。

- 試験場所、タイミング：ノエビアスタジアム神戸、全システム開発完了後
- 結果確認方法：エンドユーザによるアプリ操作後に、エッジサーバ上 MongoDB に記録されたユーザ操作ログデータから、イベントに対する反応時間を算出する。
- 評価対象：ロールプレイ以外の、たまたまスタジアムスタッフなどがカメラに映り込んだことにより発生したイベントは集計対象外とする。
- 評価対象イベント種別：1人かつ10秒未満、2人以上、1人かつ10秒以上、1人かつマスクありの4種類

3) 検証手順

警備員に業務を委託する責任者によるアプリ使用後に、スマートフォン・スマートグラスアプリの両方について、DBに保存されたユーザ操作ログデータから、以下の2種類のイベント反応時間 KPI を算出する。

- ① 通知への反応時間：ファーエッジでのイベント検出から、エンドユーザアプリでイベントが選択されるまで(イベント詳細画面の表示直前まで)
- ② 映像クリップ表示までの時間：ファーエッジでのイベント検出から、エンドユーザアプリ上で映像再生ボタンがクリックされるまで(前述の通り、スマートグラスアプリでは映像クリップをエッジサーバからダウンロードして表示することが困難なため、ローカルのダミー映像が再生されることに注意)




図 5.1-13 ユーザ反応時間の計測

反応時間は、エッジサーバ上 MongoDB に保存されている以下の 2 種類のタイムスタンプから算出できる。

- a. イベント発生日時：ファアエッジの AI パイプラインがイベントを検出した日時。
ファアエッジからエッジサーバに送信され、MongoDB に保存されるイベント情報 JSON に含まれる。
- b. ユーザアクション日時：ユーザがエンドユーザアプリケーションを操作した日時。
エンドユーザによる操作のタイミングで、エンドユーザアプリケーションから Web API(POST /kpi_log)経由でエッジサーバに送られ、MongoDB に保存される。

正確なタイムスタンプを求めるためには、すべてのファアエッジ、エッジサーバ、エンドユーザデバイス
は同一の NTP サーバを使用して時刻同期を行う必要がある。

- NTP サーバ：ntp.nict.jp
- ファアエッジ (Ubuntu) での時刻同期：systemd-timesyncd により OS レベルで時刻同期を行う

- エッジサーバ (Ubuntu) での時刻同期 : ファーエッジと同様
- エンドユーザアプリケーション (Android, Unity) での時刻同期 : Android OS 11 はユーザによる NTP サーバの指定に対応していないため、アプリ内でフリーの C# NTP クライアント [GuerrillaNtp](https://guerrillanntp.machinezoo.com/):<https://guerrillanntp.machinezoo.com/>を使用して時刻同期を行う
- エンドユーザアプリケーション (Apple Vision Pro, Swift) での時刻同期 : iOS・Swift に公開された NTP Client のライブラリを使用して時刻同期を行う。

またファーエッジは外部の NTP サーバにアクセス必要があるため、ファーエッジからインターネットへのアクセスが可能なネットワーク構成にする必要がある。

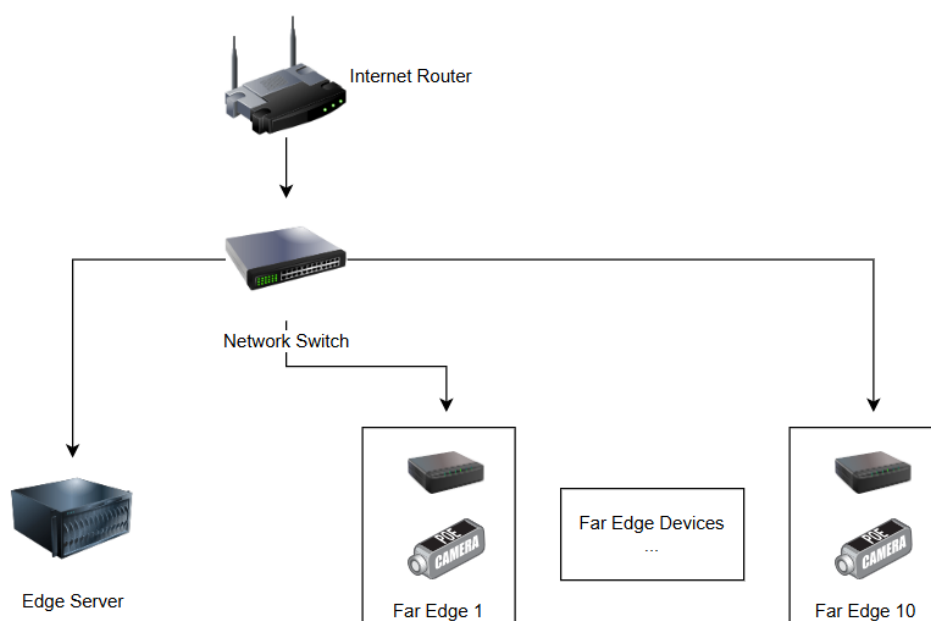


図 5.1-14 NTP 構成図

(12) エンドユーザアプリケーションを使用した警備担当者からのフィードバック収集

1) 評価の目的

エンドユーザアプリケーションの現在の課題の特定と、社会実装に向けた対応策の検討のため、警備員に業務を委託する責任者であるヴィッセル神戸担当者から、スマートフォン・スマートグラスアプリの全体的なユーザ体験に関するフィードバックを収集する。

2) 検証概要

- 試験場所、タイミング : (11)「警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定」の後
- 結果確認方法 : 警備員に業務を委託する責任者である施設管理部部長を含むヴィッセル神戸従業員 2 名は、スマートフォン・スマートグラスアプリを使用して、楽天モバイル従業員のロールプレイによるイベントを確認後、アンケートに回答する。

3) 測定(アンケート)項目

- 既存のソリューション(すべての映像が常に保存されている)と比較して、運用効率と精度が向上しているか。
- スタジアムでのセキュリティニーズを満たしているか(現行システムと比較して)。誰かがいるべきでない場所にいることを理解し、不審者を特定するのに十分であるか。
- エンドユーザ UI で受信される SLM からの結果を十分に理解できるか。
- スマートグラスのインターフェースとスマートフォンのインターフェースを比較し、検証とフィードバックを行う。
- 即時通知を受けながら、現在のタスクを継続できるかに関するユーザのフィードバック。
- 移動中の情報確認や、表示形式(AR vs 画面)に関するユーザのフィードバック。
 - スマートグラス利用者の満足度が高いことを期待。

5.1.6 KPI/KGI

本検証は、エッジ AI による通信量の低減に関して、ファーエッジ上のデータの圧縮率、データ送信削減率、エンドユーザアプリケーションの利用についての検証を目的とする。精度の判断基準および KPI 目標値を以下の表 5.1-6 エッジ AI による通信量の低減に関する評価項目のように設定する。

表 5.1-6 エッジ AI による通信量の低減に関する評価項目

定性評価 /定量評価	番号	目標値
定性評価	1	エンドユーザに対するアンケート結果が以下を満たすこと <ul style="list-style-type: none"> • スマートグラスアプリの方がスマートフォンアプリよりも満足度が高い
定量評価	2	ファーエッジ上の圧縮プロセスによる映像圧縮率が以下を満たすこと <ul style="list-style-type: none"> • 超高圧縮(テキストへの変換):99%以上 • 高圧縮(画像への変換):97%以上 • 中圧縮(映像クリップへの変換):94%以上
	3	ネットワーク混雑時に中圧縮方式の使用を避けることによるデータ送信削減率が以下を満たすこと <ul style="list-style-type: none"> • 73%以上
	4	エッジサーバでの情報集約によるデータ送信削減率が以下を満たすこと <ul style="list-style-type: none"> • 35%以上
	5	AI パイプラインによる検出の精度が以下を満たすこと <ul style="list-style-type: none"> • 人物の検知 <ul style="list-style-type: none"> ◦ 未検知率(人物が存在しているにもかかわらず検知されなかった): 1%以下 ◦ 誤検知率(人物以外の物体が人物として検知された): 10%以下 • 群衆検知 <ul style="list-style-type: none"> ◦ 正解率: 95%以上 • マスクの検知 <ul style="list-style-type: none"> ◦ 未検知率(マスクが着用されているにもかかわらず検知されなかった): 1%以下 ◦ 誤検知率(マスクが着用されていないにもかかわらず検知された): 10%以下 • 年齢推定 <ul style="list-style-type: none"> ◦ 正解率(10 歳未満および 70 歳以上グループの正しい識別): 90%以上 • 煙・炎の検知 <ul style="list-style-type: none"> ◦ 未検知率(煙・炎が存在しているにもかかわらず検知されなかった): 1%以下 ◦ 誤検知率(煙・炎が存在していないにもかかわらず検知された): 10%以下

		<ul style="list-style-type: none"> リスクアセスメント <ul style="list-style-type: none"> 未検知率(該当する条件が満たされているにもかかわらずイベントが検知されなかった)：1%以下 誤検知率(該当する条件が満たされていないにもかかわらずイベントが検知された)：10%以下
	6	<p>エンドユーザの反応時間が以下を満たすこと</p> <ul style="list-style-type: none"> 通知への反応時間：スマートグラスアプリの方がスマートフォンアプリよりも短い 映像クリップ表示までの時間(映像再生ボタンクリックまでの時間)：スマートグラスアプリの方がスマートフォンアプリよりも短い
	7	<p>ファーフエッジ推論の遅延時間が以下を満たすこと</p> <ul style="list-style-type: none"> 遅延時間：200～5000 ミリ秒(1000 ミリ秒をデフォルトのパラメータ設定とする予定。200 ミリ秒とする場合リアルタイム性は高いが、ノイズ誤検知が増えてしまうため)

(1) エンドユーザに対するアンケート結果

エンドユーザに対するアンケート結果が以下を満たすこと。

- スマートグラスアプリの方がスマートフォンアプリよりも満足度が高い

1) 目標値の妥当性、設定理由

スマートグラスアプリは、ユーザの視界に直接情報をオーバーレイ表示するため、スマートフォンを手にする手間がなく、常に必要な情報にアクセスできる。

またスマートフォンアプリでは、画面内に収まる情報しか表示できないが、スマートグラスアプリではユーザの周囲の空間全体を情報提示のキャンバスとして利用できる。これにより、より直感的で理解しやすい情報の提示が可能になる。

さらにスマートグラスアプリでは、イベント詳細情報が 3D スタジアムモデル上に 3D で表示されるため、警備担当者はスタジアムのどこでイベントが発生したか、直感的に把握することができる。

これらの理由により、スマートグラスアプリの方が、ユーザ満足度が高くなることが予想される。

2) KGI の取得方法

警備員に業務を委託する責任者である施設管理部部長を含むヴィッセル神戸従業員複数名は、スマートフォン・スマートグラスアプリを使用して、楽天モバイル従業員のロールプレイによるイベントを確認後、アンケートに回答する。詳細は「5.1.5 開発・評価項目」の(12)「エンドユーザアプリケーションを使用した警備担当者からのフィードバック収集」参照。

3) アンケート項目抜粋

- 既存のソリューション(すべての映像が常に保存されている)と比較して、運用効率と精度が向上しているか。
- スタジアムでのセキュリティニーズを満たしているか(現在の不十分なシステムと比較して)。誰かがいるべきでない場所にいることを理解し、不審者を特定するのに十分であるか。
- エンドユーザ UI で受信される SLM からの結果を十分に理解できるか。
- 通知を受けながら、普段のタスクを継続できるか。
- スマートグラスのインターフェースとスマートフォンの比較に関するフィードバック

- どちらの方が使い心地が良いか
- 今後、通知を受け取りながら通常業務をサポートするために、どちらを使用したいか
- 移動中の情報確認や、表示形式(AR vs 画面)はどちらが見やすいか
- スマートグラスの総合的満足度はどのくらいか。

(2) ファーエッジ上の圧縮プロセスによる映像圧縮率

ファーエッジ上の圧縮プロセスによる映像圧縮率が以下を満たすこと。

- 超高圧縮(テキストへの変換):99%以上
- 高圧縮(画像への変換):97%以上
- 中圧縮(映像クリップへの変換):94%以上

1) 目標値の妥当性、設定理由

各 KPI の算出方法は以下のとおりである。

- 超高圧縮(テキストへの変換):99%以上
 - 映像送信ビットレート：解像度 1080p (Full HD)、圧縮方法 H.264(Standard)、15FPS の場合 2.5mpb：①
 - 本来の 1 時間当たりデータ送信量 :1,125MB (① * 3600sec / 8)：②
 - 1 時間当たりのファーエッジからのレポート発生件数：28 件 (定期報告を 15 分ごと、イベント発生件数を 24 件と仮定)：③
 - 1 件当たりの平均データサイズ (仮定)：1 KB：④
 - 1 時間当たりのデータ送信量：0.027MB (③ * ④ / 1024)：⑤
 - 削減率：1 - (⑤ / ②) = 0.999
- 高圧縮(画像への変換):97%以上
 - 1 時間当たりのイベント発生件数：12 件 (低リスクイベントの発生頻度(仮定))：⑥
 - 1 件当たりのデータサイズ：450KB (Full HD, JPEG の平均画像ファイルサイズ※)：⑦
 - 1 時間当たりのデータ送信量：5.273MB (⑥ * ⑦ / 1024)：⑧
 - 削減率：1 - (⑧ / ②) = 0.995
- 中圧縮(10 秒間の映像クリップへの変換):94%以上
 - 1 時間当たりのイベント発生件数：12 件 (高リスクイベントの発生頻度(仮定))：⑨
 - 1 件当たりのデータサイズ：3500KB (Full HD, MP4, 10 秒の平均動映像ファイルサイズ※)：⑩
 - 1 時間当たりのデータ送信量：41.016MB (⑨ * ⑩ / 1024)：⑪
 - 削減率：1 - (⑪ / ②) = 0.964

※平均ファイルサイズは、AWL が VMS から収集した実際のファイルサイズを元に集計されている。

2) KPI の取得方法

楽天モバイル従業員によるロールプレイ後に、MongoDB に記録された受信ログデータからデータ送

信削減率を算出する。

算出方法：算出方法：1 - 「ある期間中に全ファアーエッジからエッジサーバに送信されたデータ量の合計」 / 「圧縮なしの場合、その期間中に送信されるはずだった映像ストリームのデータ量」。

詳細は「5.1.5 開発・評価項目」の(10)「ファアーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価」参照。

(3) ネットワーク混雑時に中圧縮方式の使用を避けることによるデータ送信削減率

ネットワーク混雑時にファアーエッジ上 AI パイプラインが中圧縮方式の使用を避けることによる、ファアーエッジ⇒エッジサーバデータ送信削減率が以下を満たすこと。

- 73%以上

1) 目標値の妥当性、設定理由

以下のように仮定した場合、データ送信削減率は下図 5.1-15 に示す計算式により求められる。

- 低リスクイベント発生頻度(回/時)：12
- 高リスクイベント発生頻度(回/時)：12
- 定期通知 JSON テキストサイズ(KB)：0.5
- 異常通知 JSON テキストサイズ(KB)：2

データ項目	値	番号	計算式
カメラ台数	10	①	
定期報告送信回数(回/時間)	4	②	
平均画像サイズ(KB)	450	③	
平均映像サイズ(KB)	3500	④	
定期報告テキストサイズ(KB)(仮)	0.5	⑤	
異常報告テキストサイズ(KB)(仮)	2	⑥	
低リスクイベント発生頻度(回/時)(仮)	12	⑦	
高リスクイベント発生頻度(回/時)(仮)	12	⑧	
1時間当たり受信画像サイズ	108000	⑨	③ x (⑦ + ⑧) x ①
1時間当たり受信映像サイズ	420000	⑩	④ x ⑧ x ①
1時間当たり受信テキストサイズ(定期報告)	20	⑪	⑤ x ② x ①
1時間当たり受信テキストサイズ(イベント)	480	⑫	⑥ x (⑦ + ⑧) x ①
1時間当たり受信データサイズ合計(通常時)	528500	⑬	⑨ + ⑩ + ⑪ + ⑫
1時間当たり受信データサイズ合計(輻輳時)	108500	⑭	⑨ + ⑪ + ⑫
データ削減率	0.794702		1 - ⑭ / ⑬

図 5.1-15 ネットワーク混雑時に中圧縮方式の使用を避けることによるデータ削減率

※平均画像サイズ、平均映像サイズは、AWL が VMS から収集した実際のファイルサイズを元に集計されている。

2) KPIの取得方法

楽天モバイル従業員によるロールプレイ後に、MongoDB に記録された受信ログデータからデータ送信削減率を算出する。

算出方法：1 - 「ある期間中(ネットワーク輻輳時)に全ファアエッジからエッジサーバに送信されたデータ量の合計」 / (「ある期間中(ネットワーク輻輳時)に全ファアエッジからエッジサーバに送信されたデータ量の合計」 + 「その期間中に(ネットワーク輻輳中でなければ)送信されるはずだった映像クリップデータ量」)。

詳細は「5.1.5 開発・評価項目」の(10)「ファアエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価」参照。

(4) エッジサーバでの情報集約によるデータ送信削減率

エッジサーバからエンドユーザへの情報集約によるデータ送信削減率が以下を満たすこと。

- 35%以上

エッジサーバにおける情報集約には以下の3つの方法がある。

- SLMによる、1つのファアエッジから受信した異常通知の要約レポート生成
- SLMによる、10台すべてのファアエッジから受信した定期通知の要約レポート生成
- 映像クリップをエンドユーザが映像再生ボタンを押下するまでエンドユーザに送信しないことによるデータ送信量削減

1) 目標値の妥当性、設定理由

以下のように仮定した場合、データ削減率は図 5.1-16 エッジサーバでのデータ削減率 KPI の算出方法のように求められる。

- エンドユーザ：1人
- ネットワーク輻輳度：低(高リスクイベントにおいて中圧縮方式が使用される)
- 定期通知テキストサイズ(KB)：0.5
- 異常通知テキストサイズ(KB)：1
- 低リスクイベント発生頻度(回/時)：12
- 高リスクイベント発生頻度(回/時)：12
- 異常通知テキスト送信時サイズ変化率：0.5
 - 異常通知テキスト(JSON)から必要なデータ項目のみ抽出(サイズの大幅な減少) ⇒ SLMによる要約レポート生成(サイズ増加)の結果、サイズは1/2になる、と仮定。
- 定期通知テキスト送信時サイズ変化率：0.05
 - 定期通知テキスト(JSON)から必要なデータ項目(カメラ設置場所)のみ抽出(サイズの大幅な減少) ⇒ SLMによる要約レポート生成(サイズ増加)の結果、サイズは1/20になる、と仮定。
- 映像クリップダウンロード率：0.5
 - スタジアムスタッフがカメラに映り込んだことにより発生した(不審者の侵入ではない)イ

イベントについては、警備員は対応する必要がない。このようなイベントの割合を 50%程度と仮定する。

- 警備員は、エンドユーザアプリの通知詳細画面に表示されるイベント情報(画像や要約レポートなど)により、発生したイベントについて、対応が必要か不要か判断できる。そして対応が不要な場合、警備員は映像クリップの再生を行わないと考えられる。

データ項目	値	番号	計算式
カメラ台数	10	①	
定期報告送信回数(回/時間) ※	4	②	
平均画像サイズ(KB)	450	③	
平均映像サイズ(KB)	3500	④	
定期報告テキストサイズ(KB)(仮)	0.5	⑤	
異常報告テキストサイズ(KB)(仮)	2	⑥	
低リスクイベント発生頻度(回/時)(仮)	12	⑦	
高リスクイベント発生頻度(回/時)(仮)	12	⑧	
異常通知テキスト送信時サイズ変化率(仮)	0.5	⑨	
定期通知テキスト送信時サイズ変化率(仮)	0.05	⑩	
映像ダウンロード率(仮)	0.5	⑪	
1時間当たり受信画像サイズ	108000	⑫	③ x (⑦ + ⑧) x ①
1時間当たり受信映像サイズ	420000	⑬	④ x ⑧ x ①
1時間当たり受信テキストサイズ(定期報告)	20	⑭	⑤ x ② x ①
1時間当たり受信テキストサイズ(イベント)	480	⑮	⑥ x (⑦ + ⑧) x ①
1時間当たり受信データサイズ合計	528500	⑯	⑫ + ⑬ + ⑭ + ⑮
1時間当たり送信画像サイズ	108000	⑰	⑫
1時間当たり送信映像サイズ	210000	⑱	⑬ x ⑪
1時間当たり送信テキストサイズ(定期通知)	1	⑲	⑤ x ① x ② x ⑩
1時間当たり送信テキストサイズ(異常通知)	240	⑳	⑮ x ⑨
1時間当たり送信データサイズ合計	318241	㉑	⑰ + ⑱ + ⑲ + ㉑
データ削減率	0.39784		1 - ㉑ / ⑯

※ファーエッジ-エッジサーバー、エッジサーバー-ユーザーアプリケーション共通

図 5.1-16 エッジサーバでのデータ削減率 KPI の算出方法

※平均画像サイズ、平均映像サイズは、AWL が VMS から収集した実際のファイルサイズを元に集計されている。

2) KPI の取得方法

楽天モバイル従業員によるロールプレイ後に、MongoDB に記録された受信・送信ログデータからデータ送信削減率を算出する。

算出方法：1 - 「ある期間中にエッジサーバからある 1 台のエンドユーザデバイスに送信されたデータ量の合計」/ 「ある期間中に全ファーエッジからエッジサーバに送信されたデータ量の合計」。

詳細は「5.1.5 開発・評価項目」の(10)「ファーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価」参照。

(5) AI パイプラインによる検出の精度

ファーエッジ上の AI パイプラインによる検出の精度が以下を満たすこと。

- 人物の検知
 - 未検知率(人物が存在しているにもかかわらず検知されなかった): 1%以下
 - 誤検知率(人物以外の物体が人物として検知された): 10%以下
- マスクの検知
 - 未検知率(マスクが着用されているにもかかわらず検知されなかった): 1%以下
 - 誤検知率(マスクが着用されていないにもかかわらず検知された): 10%以下
- 年齢推定(10歳未満・70歳以上・それ以外のグループの正しい識別)
 - 正解率: 90%以上
- 煙・炎の検知
 - 未検知率(煙・炎が存在しているにもかかわらず検知されなかった): 1%以下
 - 誤検知率(煙・炎が存在していないにもかかわらず検知された): 10%以下
- リスクアセスメント
 - 未検知率(該当する条件が満たされているにもかかわらずイベントが検知されなかった): 1%以下
 - 誤検知率(該当する条件が満たされていないにもかかわらずイベントが検知された): 10%以下

1) 目標値の妥当性、設定理由

- 目標値の設定基準
 - スタジアムなどの大規模な公共施設の運用上の必要性
 - ファーエッジハードウェアで利用可能な限られた計算リソース
 - リスク検知や火災検知などのタスクの安全上の必要性
- 精度閾値全般について
 - 精度閾値(未検知 1%以下、誤検知 10%以下)は、リアルタイム監視における業界標準の期待を反映しつつ、モデルがファーエッジにおいて計算上実現可能であることを保証する。
 - AI モデルにおいて、未検知と誤検知の両方の精度を極限まで高めることは非常に困難(一方を優先すると一方の精度が下がる)であるが、監視目的においては未検知を防止することが優先である(誤検知は、目視で排除可能であるため)ことから、このような目標設定としている。
- 人物の検知
 - AIによる人物検知において、未検知1%以下の数字を目標とすることは、あまり実用的・現実的ではない。

- リスクアセスメント(高リスク・低リスク・リスクなしの判定)
 - リスクアセスメントは if then ルールでの判定であり、判定が誤っていない場合は100%の精度で動作することが期待される。

2) KPI の取得方法

ノエビアスタジアム神戸において、設置されたカメラの前でロールプレイを行った後、検出結果を確認し、各イベントについて未検知率・誤検知率または正解率を求める。手順の詳細については「5.1.5 開発・評価項目」の(8)ファーエッジ上 AI パイプラインの精度評価(実証)参照。

3) KPI 項目詳細

a. 人物検知

人物検知の KPI は、リアルタイムの制約の下で人間の存在を正しく識別するシステムの能力を測定する。未検知率とは、人物がカメラの画角内にいるにもかかわらず、人物のバウンディングボックスが生成されないフレームの率を指す。誤検知(偽陽性)率は、人物以外の物体(例:看板、影、マネキンなど)が誤って人物として分類される率を指す。これらの閾値は、追跡、リスク分類、子ども・高齢者検知など、すべての下流モジュールの基本的な信頼性を確保する。

b. マスク検知

マスクを着用している個人をシステムが正しく識別できるかどうかを評価する。

顔や頭部の特徴が以下に示す最低品質(照明、サイズ、角度)を満たしているケースでは、未検知率 $\leq 1\%$ 、誤検知率 $\leq 10\%$ を達成しなければならない。

- 照明:照度レベル 1 - 明るい日光またはスタジアムの屋内照明下
- サイズ:識別対象者が入力動画フレームの 20%以上を占めること
- 角度:人物の顔がカメラレンズに対してヨー ± 40 度、ピッチ ± 35 度、ロール ± 30 度以内であること

c. 年齢推定

人物を年齢グループに分類する精度を評価する。主に、迷子の可能性が高い子どもと高齢者を識別する。顔または頭部の特徴が最低品質基準(照明、サイズ、角度)を満たす場合、正しい分類率は 90%以上を達成しなければならない。

- 照明:照度レベル 2 - 薄暗い照明または室内照明
- サイズ:識別対象者が入力動画フレームの 15%以上を占めること
- 角度:人物の顔がカメラレンズに対してヨー ± 40 度、ピッチ ± 35 度、ロール ± 30 度以内であること

d. リスクアセスメント

人物検知、追跡、年齢推定、マスク検知など、複数の AI 出力を組み合わせ、侵入(1 人)、混雑(2 人以上)、マスク着用などの状況的なリスク条件を識別するロジックの精度を評価する。

警備担当者が信頼性の高いリスク通知を受け取ると同時に、過剰な誤警報を避けるために、未検知率 1%以下、誤検知率 10%以下が要求される。

e. 火災・煙検知

炎または煙の特徴の識別精度を評価する。

このタスクは安全上極めて重要であるため、未検知率(≤1%)は厳しく設定されている。

f. 群衆検知

2 人以上の人物がその場にいる状況を識別する精度を評価する。

(6) エンドユーザの反応時間

警備員に業務を委託する責任者を含むヴィッセル神戸従業員複数名がエンドユーザアプリを使用した場合の反応時間が以下を満たすこと。

- 通知への反応時間: スマートグラスアプリの方がスマートフォンアプリよりも短い
- 映像クリップ表示までの時間(映像再生ボタンクリックまでの時間): スマートグラスアプリの方がスマートフォンアプリよりも短い

1) 目標値の妥当性、設定理由

スマートグラスアプリユーザは、常にスマートグラスを着用していれば、他の作業で忙しい場合も通知が届いたら即座に確認できる。スマートフォンアプリユーザは、作業の手を止めてスマートフォンを手に取り、何が起きているか確認する必要がある。

よって、スマートグラスアプリの方が、反応時間が短くなることが予想される。

2) KPI の取得方法

ヴィッセル神戸従業員複数名によるスマートフォン・スマートグラスアプリ使用後に、MongoDB に記録されたイベント発生時間とユーザ操作時間から、スマートフォン・スマートグラスアプリ両方についてイベント反応時間 KPI を算出する。

詳細は「5.1.5 開発・評価項目」の(11)「警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定」参照。

(7) ファーエッジ推論の遅延時間

ファーエッジ推論の遅延時間が以下を満たすこと。

- 遅延時間: 200~5000 ミリ秒

1) 目標値の妥当性、設定理由

異常をリアルタイムで検知するためには、人物検知、マスク検知、年齢推定、火災・煙検知、テレメトリ生成といった AI パイプライン全体が、フレームあたり 200 ミリ秒以下で実行される必要がある。

これにより、タイムリーなリスク警報が確保され、大規模な人出が発生するイベント中のライブモニタリングがサポートされる。

2) KPI の取得方法

テレメトリ生成時間と推論結果が確定した時間との差分を計算することによって求められる。

5.2 ユースケース②:山間部や海中等の携帯電話網不感地域における通信の確立

当該ユースケースは実施しなかった。

5.3 ユースケース③:多種多様なデバイスに対する通信リソースの最適化

当該ユースケースは実施しなかった。

5.4 ユースケース④:分散ネットワークにおける新たな AI ソリューションの創出

当該ユースケースは実施しなかった。

5.5 拡張性に関する検証

5.5.1 実証内容の詳細

本実証のソリューションは、図 5.5-1 に示す通り、スタジアムに限定されず、多様な産業・分野への横展開が可能であると考えられる。具体的には、イベント施設、オフィスビル、工場といった監視・警備を必要とする施設におけるセキュリティ用途に加え、来場者動線分析に基づくマーケティングなど、多岐にわたる用途への適用が期待される。

しかしながら、他業種・他用途への展開を検討する際には、環境変化が AI モデルの性能に与える影響、システム全体の可搬性、およびネットワークの拡張性について、導入前に十分な検証を実施する必要がある。

本フェーズでは、スタジアムでの実証で得られた知見を基に、異なる産業・分野、および異なる条件・環境への横展開が可能で汎用的な異常検知システムの実現性を検証する具体的には、以下の 2 点について検証を実施する。



図 5.5-1 社会実証に向けた拡張性の検証

(1) AIモデル拡張性の検証

本ソリューションの将来的なAIの網羅性を目指し、多様な施設において有効活用される可能性が高いAIモデルを選定し、オフライン環境下での精度検証を実施する。これにより、様々なAIモデルにおける適用範囲を明確化し、その実用性と有効性をオフラインAIパイプラインの検証で確認する。

- 人物の転倒検知: 高齢者施設や工場における安全監視への応用が期待される。
- 暴力検知: イベント会場や商業施設におけるセキュリティ強化に貢献する。
- 特定人物の顔認識: 入退室管理、VIP対応、迷子捜索など、多様な分野での応用が期待される。

(2) システム可搬性の検証

大規模多目的施設における警備監視システムの可搬性がもたらす導入効果およびその実現性について検証する。AIを用いた監視システムにおいて、その認識精度は照度やカメラの設置角度、混雑度、時間帯、天候といった多様な環境要因(異なる条件・環境)に大きく左右されることが想定される。可搬型カメラは、その柔軟性からあらゆる施設の様々なエリアに設置・運用されることが想定されるため、多様な環境下でのAI精度に差異が生じる可能性が指摘される。このため、広範囲な環境変化に対するAIモデルのロバスト性を評価することが不可欠である。

また、可搬型カメラの導入は、利用者が容易に任意の場所に設置できるという運用上の利点を提供する。しかしながら、実際の運用における効率性を確保するためには、設置の容易さだけでなく、広範囲な監視エリアを効果的にカバーするための最適な配置設計、およびその運用にかかる労力やコストを総合的に評価し、実現可能性を検証する必要がある。

5.5.2 前提条件

(1) AIモデル拡張性の検証(オフライン AIパイプラインの検証)

1) 人物転倒の検知

a. データ収集の前提条件

転倒検知のオフライン評価には、実環境下における多様な転倒挙動を網羅したデータセットを定義し動画記録の準備が必要であった。データセットは具体的に前方・後方・横方向への転倒に加え、体調不良等を想定した緩やかな崩れ落ち動作を記録対象に含めた。これらの動作は、異なる撮影距離および複数のカメラアングルから記録し、スケールの変動、遮蔽(オクルージョン)、視点変化を伴うバリエーションを確保した。これにより、姿勢推定および動作認識モデルの精度と、実利用環境における環境変化への耐性を十分に検証可能な条件を整えた。

b. 被験者とシナリオの要件

モデルの頑健性を多角的に評価するため、被験者が転倒する(

図 5.5-2 参照)際の「速度」、「倒れ方」、「身体の向き」に多様性を持たせたシナリオを策定した。また、単独の転倒動作だけでなく、背景に他の人物が通行・滞在するシーンを記録に含めることで、実際の施設における群衆密度やオクルージョン(重なり)を再現した。これにより、混雑した環境下における誤検知や未検知の要因を抽出し、実運用のノイズに対するシステムの耐性を検証可能なデータ構成とした。



図 5.5-2 転倒テストの様子

c. システムと処理の要件

転倒検知シナリオにおいて、高度な姿勢推定および骨格ベースの動作認識アルゴリズムを安定稼働させるため、高い計算リソースを有するエッジサーバを採用した。これらの高度な解析処理は、スマートカメラ等の末端デバイスの処理能力を大きく上回る計算負荷を伴うためである。また、転倒特有の動作パターンを正確に識別するには、時間的連続性を保持した一貫性のあるフレーム取り込み(高フレームレートの維持)が不可欠となる。そのため、パケットロスを抑え、リアルタイムに映像データを処理可能なシステム構成を要件として定義した。

2) 暴力検知

a. データ収集の前提条件

暴力検知の検証にあたり、パンチ、キック、押し倒し(

図 5.5-3 参照)といった明確な攻撃的行動を網羅したデータセットを定義した。特に、システムの識別精度(誤検知の回避能力)を評価するため、攻撃的動作と外見上の特徴が類似している非暴力的なアクション(-どのようなアクションかいくつか例を入れる-)を比較対象として収録した。これらのデータは、スタジアムにおける照明変化、床面や壁面の反射、影、および背景テクスチャを含むスタジアム内の複数のエリアで撮影を行い、推論に影響を与える光学的な変動要因を網羅的に確保した。



図 5.5-3 暴力テストの様子

b. 被験者とシナリオの要件

被験者に対し、動作の速度や強度(勢い)に意図的な変化を持たせたシナリオを指示した。これにより、暴力・非暴力の両動作において、実際の運用時に発生しうる「動作の揺らぎ」を再現し、オフライン動作認識パイプラインの頑健性をテスト可能な構成とした。また、多様な空間特性における検知性能を評価するため、「通路」、「コンコース」、「オープンフロア」の各エリアに検証シナリオを設定した。これにより、画角や背景、異なる環境下においても、安定した検知が可能であることを確認した。

c. システムと処理の要件

効果的なオフライン暴力検知には、エッジサーバが時系列推論をサポートする必要がある。これには姿勢抽出、骨格追跡、ルールベースフィルタリングが含まれる。これらの処理は安定したフレームシーケンスと、中断なく複数フレームの動作ウィンドウを処理する十分な計算スループットに依存する。

3) 特定人物の顔認識

a. データ収集の前提条件

顔認識の検証にあたり、登録対象となる個人の高品質な正面画像を用いた「参照用データベース(ギャラリー)」を構築する(図 5.5-4)。正面の画像は、被写体の顔の特徴を明確に示す必要がある。両目、鼻、できれば口を含むことが望ましい。顔は遮るものがなく完全に見える状態でなければならない。

また、画像は傾きや部分的な横向きではなく、真正面から撮影されている必要がある。これは、照合の基盤となる信頼性の高い特徴量(埋め込みベクトル)を生成するために不可欠なプロセスである。次に、テスト用の動画記録として、被験者がスタジアム内の複数のゾーンを自然に歩行する様子を収録する(

図 5.5-5)。この際、照合精度に影響を与える要因として、照明の変化、頭部の角度、遮蔽(「遮蔽」とは、顔の一部が一時的に他者や物体によって隠れる状態を指し、マスクやサングラス等の恒常的な装着物は含まないものと定義する)、および歩行時の動きのパターンを意図的に盛り込み、実環境における識別能力を厳密に検証可能なデータセットとする。

b. 被験者とシナリオの要件

被験者にはスタジアム内の複数の経路を移動するよう指示し、システムが「自然な頭部の動き」や「部分的な横顔」、さらに群衆や構造物による「瞬間的な遮蔽」が発生する条件下で、どの程度識別を維持できるかを検証した。これは、人物がカメラを意識しない動的な実環境において、顔認識パイプラインの性能を正しく評価するために不可欠なプロセスである。このシナリオにより、特定のゲートや通路における実用的な識別能力の限界を明らかにすることを目的とした。



図 5.5-4 顔位置登録画像



図 5.5-5 顔認識テストの様子

c. システムと処理の要件

エッジサーバには、顔検出、ランドマーク抽出、アライメント(傾き補正)、特徴量(埋め込み)生成、および本人照合までの一連の工程を完結させる「顔認識パイプライン」を実装した。また、拡張性の検証として、登録者数の増大に伴う認識精度の安定性や処理速度を評価できる構成とした。具体的には、小規模なデータセットから大規模な本人データセットまでを評価可能なシステム環境を構築した。

(2) システム可搬性の検証

1) 環境変化に伴う AI 検出精度

環境変化に伴う AI 検出精度における実施環境および設定に関する前提条件は以下の表 5.5-1 に示す。

表 5.5-1 環境変化に伴う AI 検出に検証の前提条件

前提項目	内容
検証場所	<ul style="list-style-type: none"> 人工照明が主体となる閉鎖的な空間。外部からの自然光の影響は限定的。室内の照明器具によって照度がコントロールされる環境を想定。
カメラ設置	<ul style="list-style-type: none"> 各エリアに同一機種の AI 監視カメラを 1 台ずつ設置する。カメラの設置高さ、画角、被写体までの距離は、各シナリオにおいて可能な限り均一になるよう調整する。
被写体 (ロールプレイを行う人物およびもの)	<ul style="list-style-type: none"> 人物: 検出シナリオにおける人物は、事前に指定された服装(一般的な日常着)を着用し、特定の動作(立入、マスク着用)を再現する。体型や服装の色は複数パターンを考慮しない。 炎: 炎の映像・画像は、標準的な PC モニターに表示し、カメラに対して一定の距離・角度で提示する。炎の大きさや動きのパターンは固定とする。
照度条件	<ul style="list-style-type: none"> 人工照明環境であるため、室内の照明調整によって照度条件を制御する。
システム・機器条件	<ul style="list-style-type: none"> AI 監視システム: 同一メーカー・同一モデルの AI 監視システムを使用し、AI モデルのバージョンも統一する。検証期間中に AI モデルのアップデートや再学習は行わない。 カメラ: 同一メーカー・同一モデルのカメラを使用し、設定(解像度、フレームレート、シャッタースピード、ISO 感度など)は可能な限り統一する。
再現性	<ul style="list-style-type: none"> 各検出シナリオは、可能な限り同一の条件と手順で再現されることを前提とする。

2) 設置・撤去時間

設置・撤去時間測定における実施環境および設定に関する前提条件は以下の表 5.5-2 に示す。

表 5.5-2 設置・撤去時間測定検証の前提条件

前提項目	内容
設置・撤去作業	<ul style="list-style-type: none"> 初期設置を想定し、利用者が事前に用意された設置マニュアルに従って設置作業を実施する。時間測定の検証に先立ち、設置を事前に 1 回以上行う。
設置場所	<ul style="list-style-type: none"> 電源: 設置場所には、各機器(エッジサーバ、ファアエッジ、カメラ、スイッチングハブ、設定用 PC、LTE/5G ルータなど)の動作に必要な電源コンセントが適切に配置されていることを前提とする。 ネットワーク接続: LTE/5G ルータが安定したモバイルネットワークに接続できる環境であることを前提とする。また、エッジサーバと LTE/5G ルータ間の LAN ケーブル接続、およびファアエッジとカメラ間の LAN ケーブル接続に必要なポートとケーブルが利用可能であることを前提とする。

	<ul style="list-style-type: none"> • 設置スペース: 各機器をマニュアルに従って配置するための十分なスペースが確保されていることを前提とする。本検証では、エッジサーバからカメラまでの距離を 5m 以内とする。
機器の状態	<ul style="list-style-type: none"> • 初期状態: 設置作業開始時点において、全ての機器は梱包状態から開封され、破損や初期不良がないことを確認済みとする。 • 設定用 PC: カメラビューの設定に使用する PC は、専用ソフトウェアが事前にインストールされ、動作可能な状態であることを前提とする。
マニュアル・ツール	<ul style="list-style-type: none"> • 設置マニュアル: 詳細な設置ステップが記載されたマニュアルが提供され、作業者はそれによって作業を行うことを前提とする。 • 必要工具: 設置・撤去に必要な工具(例:ドライバー、六角レンチなど、もし必要であれば)は、事前に準備されていることを前提とする。
サーバアプリケーションの起動	<ul style="list-style-type: none"> • 図 5.5-12 に示す Step④のサーバアプリケーションの遠隔起動は、利用者が行う設置・撤去作業とは独立して、サーバ運営担当者によって遠隔で実施されることを前提とする。この作業時間は、利用者の設置・撤去時間には含まれない。
留意事項	<ul style="list-style-type: none"> • 本検証の「設置時間」は初期設置を想定しているため、エッジサーバを特定の場所に継続運用する際に図 5.5-12 に示す Step①の設置手順が省略可能となる点については、今回の測定には反映されない。将来的な運用効率の評価において考慮されるべき点である。

3) 運用効率性評価

運用効率性評価における実施環境および設定に関する前提条件は以下の表 5.5-3 にする。

表 5.5-3 運用効果性評価の前提条件

前提項目	詳細
インタビュー対象者	<ul style="list-style-type: none"> • インタビュー対象者は、可搬型カメラシステムの設置・撤去作業を実際に実施した者、またはその運用に直接関与した者 1 名以上である。
質問内容と評価項目	<ul style="list-style-type: none"> • 網羅性: 質問項目は、「評価項目」で挙げられた全ての項目(設置、撤去、移動、運用全般に関する項目)を網羅的にカバーする。 • 誘導の排除: 質問は、特定の回答を誘導するものではなく、対象者の自由な意見を引き出すオープンな形式を基本とする。
データ収集・分析	<ul style="list-style-type: none"> • 記録方法: インタビュー内容は、対象者の同意を得た上で、音声録音、メモ、またはその両方で記録される。 • 分析方法: 収集された定性データは、テーマごとに分類・集計され、共通する課題や改善点、運用上のメリット・デメリットが抽出される。定量的データ(設置・撤去時間)と合わせて分析することで、より多角的な評価を行う。

5.5.3 評価項目

(1) AI モデル拡張性の検証

本検証では将来的な AI の網羅性を目指し、多様な施設において有効活用される可能性が高い AI モデルとして「人物転倒」「暴力検知」「特定人物の顔認識」を選定し、オフライン環境下での精度を測定することを目的とする。

表 5.5-4 AI モデル拡張性の検証 評価項目

番号	評価項目
1	人物転倒の AI 異常検知の精度および処理時間
2	暴力検知の AI 異常検知の精度および処理時間
3	特定人物の顔認証の AI 異常検知の精度および処理時間

1) 人物転倒

a. 目的

本検証の目的は、エッジサーバ上で動作するオフライン AI パイプラインが、実際のスタジアム環境において転倒行動を正確に識別できるかを確認することにある。

転倒検知には「人物検出」「姿勢推定」「時間的動作解析」「後処理」といった多段階の推論プロセスが必要となる。そのため、これらの複雑な処理工程を高精度かつ低遅延で実行するために、エッジサーバが十分な計算リソースを提供し、実運用に耐えうる性能を発揮できるかを検証する。

b. 評価項目

- AI 異常検知の精度
- AI 異常検知の処理時間

c. 評価手法

スタジアム全体で、参加者が制御されたシナリオ下で転倒に関連する動作を行う様子を録画したテスト動画を用いた。データセットには以下が含まれた：

- 突然の倒れ込み(前方、後方、横方向)
- 失神やバランス喪失を模した緩やかな姿勢変化
- 座る、しゃがむ、地面に休むなどの転倒以外の動作

実際の導入環境の多様性を再現するため、カメラアングルや被写体距離や配置は変化させた。

エッジサーバでのオフライン評価では、各フレームシーケンスが以下の全処理パイプラインを通過した：

- 人物検出 - シーン内の個人を特定する。
- 姿勢推定 - 骨格のキーポイントを抽出する。
- 時系列行動認識 - シーケンスベースモデルを用いて転倒、立位、歩行、着座などの行動を分類する。
- ルールベースフィルタリング - 生体力学的制約(脚伸展比率、関節運動速度など)を適用し、誤った転倒予測を除去する。

出力結果は、手動アノテーションで作成した事前定義のテストケースラベルと比較された。イベントレベルの検出精度、誤検知頻度、処理遅延を記録し、堅牢性と拡張性を評価した。

d. 検証手順

検証の具体的な検証手順は下記の表 5.5-5 に示す。

表 5.5-5 人物転倒の AI 精度測定の手順

手順	説明	評価項目
1	テスト参加者が事前定義された転倒／非転倒動作(突然の倒れ込	評価に用いる入力動画データの取得条件

	み、緩やかな姿勢崩れ、座る・しゃがむ等)を実施し、その様子をスタジアム内の複数環境で録画する。	の適切性
2	収録したテスト動画をオフライン AI パイプラインに入力し、人物検出・姿勢推定・時系列行動認識を順に実行する。	各 AI 処理ステージの推論実行可否および処理安定性
3	行動認識結果に対し、ルールベースフィルを適用し、誤検知を除去した最終転倒判定を生成する。	誤検知抑制効果(False Positive 低減)
4	生成されたイベント結果を、事前定義したテストケースの期待ラベル(正解ラベル)と照合し、転倒の有無・分類の一致を確認する。	検出精度(True Positive, False Negative, False Positive)
5	各動画の処理に要した推論時間(パイプライン全体の処理時間)を計測する。	AI 異常検知処理時間(遅延)
6	テストケースごとに結果を集計し、パイプライン全体の精度・誤検知率・未検知率・処理時間の統計を算出する。	異常検知総合精度および性能指標の評価

2) 暴力検知

a. 目的

暴力検出の評価として、パンチ、キック、押し合いなどの攻撃的な相互作用を検出する多段階オフライン AI パイプラインの性能検証を実施する。これらの動作解析には、時間的推論、骨格運動の理解、および曖昧な動作のフィルタリングが必要し、本検証では検出精度の測定に加え、エッジサーバがこれら高負荷なモデルを大規模に処理可能かどうかの確認を目的とする。

b. 評価項目

- AI 異常検知の精度
- AI 異常検知の処理時間

c. 評価手法

参加者は、スタジアム内の様々な場所で、暴力的な行動と非暴力的な行動の制御された一連の動作を行った。データセットには以下が含まれた:

- 模擬的な喧嘩(パンチ、キック、押し合い)
- 短時間の高速動作

映像はカメラ位置や環境条件の現実的な変動を反映するため、異なる距離、視点角度、照明レベルで撮影された。

オフライン暴力検知パイプラインはエッジサーバ上で以下の段階を経て実行された:

- 人物検出 - フレーム内の全個人を識別する。
- 姿勢推定 - 検出された全人物の関節キーポイントを抽出する。
- 時間的動作認識 - パンチ、キック、押し、歩行、着座、立位などの動作を分類する。
- ルールベースフィルタリング - 動作速度、関節間距離のしきい値、フレーム領域の制約を用いて誤分類を除去する(例:顔に手が近すぎる、四肢の速度が不十分)。

出力予測は、手動で注釈を付けた事前定義のテストケースと照合された。精度指標(未検出件数、誤検知、F1 スコア)と処理時間を測定し、運用準備状況と大規模展開におけるモデルの拡張性を評価した。

d. 検証手順

検証の具体的な検証手順は下記の表 5.5-6 に示す。

表 5.5-6 暴力検知の AI 精度測定の手順

手順	説明	評価項目
1	参加者が事前定義された暴力行動および非暴力行動(パンチ、キック、押し合い、短時間の高速動作など)をスタジアム内の複数環境で実施し、距離・視点角度・照明条件を変えて撮影した。	評価に用いる入力動画データの適切性・多様性
2	収録したテスト動画をオフライン暴力検知パイプラインに入力し、人物検出・姿勢推定・時系列動作認識を順に実行した。	各 AI 推論ステージの実行可否および安定性
3	ルールベースフィルタを適用し、曖昧または誤った暴力判定を除去した。	誤検知(False Positive)抑制の有効性
4	生成された暴力検知結果を、事前定義したテストケースラベルと照合し、暴力行動/非暴力行動の正しい分類を確認した。	検出精度(True Positive、False Negative、False Positive)
5	各動画に対する推論処理時間(パイプライン全体の処理時間)を計測した。	AI 異常検知処理時間(推論遅延)
6	全テストケースの結果を集計し、総合精度、誤分類傾向、誤検知率、未検知率、処理時間統計を算出した。	異常検知の総合精度および性能指標

3) 特定人物の顔認証

a. 目的

本検証では、エッジサーバ上で動作する完全オフライン顔処理パイプラインの拡張性、精度、および性能を検証するために設計された。高精度な顔認識には、顔検出、追跡、品質検証、位置合わせ、埋め込み生成、本人照合といった多段階の処理が必要となる。そのため、エッジサーバが安定した推論レイテンシを維持しつつ、小規模から大規模な登録データ(ギャラリー)を適切に処理できるかどうかの確認を主な目的とする。

b. 評価項目

- AI 異常検知の精度
- AI 異常検知の処理時間

c. 評価手法

被験者は事前に高品質な正面画像を用いて登録され、参照埋め込みを生成して身元ギャラリーを形成した。2つの評価モードを用いた:

- 小規模識別セット - ベースライン精度検証用
- 拡張身元セット - 登録者数増加時の拡張性を評価するため

参加者はスタジアム内の複数のエリア(開放区域、入口、保管通路など)を移動した。動画は明るい光、中程度の光、暗い光といった異なる照明条件下での移動、様々な頭部姿勢、遮蔽パターンを捉えた。

記録された動画は、エッジサーバ上でオフライン処理され、完全な顔認識パイプラインが適用された:

- 顔検出・追跡 - 顔の識別と継続的な追跡を維持する。
- 顔品質検証 - 十分な画像鮮明度、顔サイズ、姿勢の適切性を確保する。
- 埋め込み計算と本人照合 - 類似性閾値を用いて被写体の埋め込みデータを登録済みギャラリーと比較する。

システムの出力(顔追跡データ、予測 ID、信頼度スコア)は、事前定義のテストケースと比較された。評価項目は以下の通り:

- 正しい識別、誤検知、見逃し、ID 切り替えイベント
- 各動画シーケンスの処理遅延
- 照明や姿勢変化に対する感度

結果から、遠隔軽量モデルとエッジサーバの計算能力の相乗効果が実証され、大規模な身元認識タスクへの対応準備が整っていることが確認された。

d. 検証手順

検証の具体的な検証手順は下記の表 5.5-7 に示す。

表 5.5-7 特定人物の顔認証の AI 精度測定の手順

手順	説明	評価項目
1	被験者は高品質な正面画像で事前登録され、参照埋め込みを生成して身元ギャラリーを構築した。動画はスタジアム内の複数地点、異なる照明条件や頭部姿勢の下で取得した。	評価に用いる入力データの適切性・多様性
2	収録した動画をオフライン顔認証パイプラインで処理し、顔検出、追跡、品質検証、位置合わせ、埋め込み生成、本人照合を順次実行した。	各 AI 推論ステージの実行可否および安定性
3	低品質、ぼけ、向き不良などの顔サンプルは、品質検証モジュールにより照合前に除外された	誤検知(False Positive)抑制および品質管理の有効性
4	認識結果(予測 ID、類似度スコア、顔トラックの継続性)を事前定義テストケースの期待ラベルと照合し、正しい識別および安定的な認識が行われているかを確認した。	認識精度(正しい識別、誤検知、見逃し、ID 切り替えイベント)
5	小規模および大規模ギャラリー条件の双方で、各動画シーケンスの処理時間を計測し、システム性能を評価した。	AI 異常検知処理時間(推論遅延)
6	全テストケースの結果を集計し、照明や姿勢変化に対する認識精度、誤識別傾向、ID 切り替え率、性能指標を算出した。	異常検知の総合精度および性能指標

(2) システム可搬性の検証

本検証では、可搬性カメラの導入における実運用上の効率性を確認するため、以下の表 5.5-8 に示す項目を評価する。

表 5.5-8 システム可搬性検証の評価項目

番号	評価項目
1	環境変化に伴う AI 検出精度
2	設置・撤去時間
3	運用効率性評価

1) 環境変化に伴う AI 検出精度

a. 目的

本検証の目的は、異なる環境(設置場所および照度条件)に同一の AI 監視システムを設置した場合の検出精度を定量的に比較し、環境要因が AI 性能に与える影響を把握することである。これにより、将来的なシステム展開における課題を特定し、AI モデルおよびシステムのロバスト性向上に資する知見を獲得する。

b. 評価項目

本検証では、異なる設置環境であるエリア A とエリア B(図 5.5-6)、および表 5.5-9 ならびに図 5.5-7 に示すように異なる明るさ条件(3 パターン)下における各検出シナリオ(10 秒未満立入、マスク、炎)の AI 検出精度を主要な評価項目とする。これらの評価指標をクロス比較することで、環境変化が AI 性能に与える影響を詳細に分析する。

c. 評価手法

本評価では、図 5.5-6 に示す 2 箇所(エリア A とエリア B)にカメラを設置し、クロス検証を実施する。エリア A とエリア B は人工照明が主体となる閉鎖的な空間といった特徴を持つ。

検証場所の明るさについては、表 5.5-9 および図 5.5-7 に基づき、以下の 3 つのパターンを設定する。各エリアにおいて、これら 3 つの明るさ条件の下で検出精度を測定する。

- 検証場所: エリア A、B の 2 箇所にカメラを設置し、クロス検証を実施する。




図 5.5-6 エリア A と B の写真

- 場所要件: 図 5.5-7 に示す検証場所において、表 5.5-9 の照度条件スケールに基づいた 3 つの明るさパターンを比較環境として用意する。具体的な照度値は以下のように定義する。

表 5.5-9 明るさパターン別の照度測定範囲

パターン	明るさ	照度範囲(lx)	明るさの程度
照度 Lev.1	明るい	100 ~ 400	数十メートル先が確認できる程度の明るさ
照度 Lev.2	↑	5 ~ 7	足元が確認できる程度の明るさ

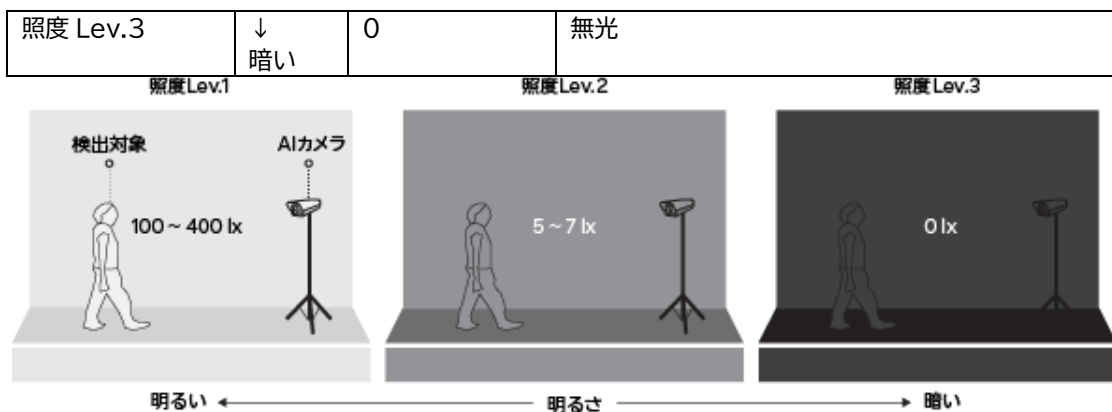


図 5.5-7 明るさスケール

- 検出シナリオ: 以下の図 5.5-8 に示すように 3 つの検出シナリオを実施する。
 - 10 秒未満立入検知: ロールプレイで人物の立ち入りを再現する。
 - マスク検知: ロールプレイでマスクをした人物による立ち入りを再現する。
 - 炎検知: ノートパソコンのモニターに炎の映像を表示し、カメラに映す。



図 5.5-8 検出シナリオ

- 実施回数: 各エリアにおいて、「10 秒未満立入」および「マスクの検出」シナリオは各図 5.5-9 に示すような 8 方向に立ち入りルートを変更しつつ検証を行う。また、「炎検出」シナリオは図 5.5-10 に示すように 5 個の異なる映像を用いて検証を実施する。

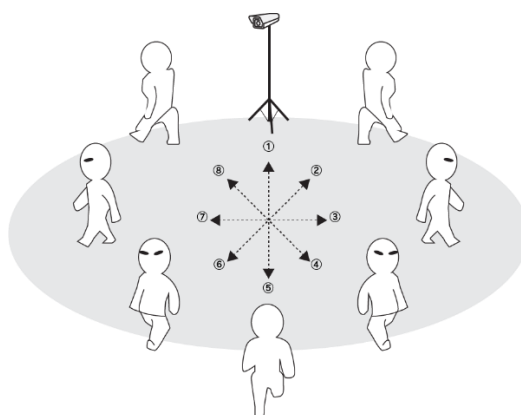


図 5.5-9 カメラビューに立ち入り方向



図 5.5-10 炎検証に使用した映像サンプル

- AI 検出の精度: AI 検出の精度は、3 つの明るさパターンによる検出シナリオを反復実施し、得られた結果に基づき定量的に検知の有効を計算する。

d. 検証手順

検証の具体的な検証手順は以下の表 5.5-10 に示す。

表 5.5-10 環境変化に伴う AI 検出精度の検証手順

手順	説明	評価項目
1	エリア A において、明るさ条件①の下、検出シナリオに基づき撮影を実施。	エリア A の AI 検出精度
2	エリア A において、明るさ条件②の下、検出シナリオに基づき撮影を実施。	エリア A の AI 検出精度
3	エリア A において、明るさ条件③の下、検出シナリオに基づき撮影を実施。	エリア A の AI 検出精度
4	エリア B において、明るさ条件①の下、検出シナリオに基づき撮影を実施。	エリア B の AI 検出精度
5	エリア B において、明るさ条件②の下、検出シナリオに基づき撮影を実施。	エリア B の AI 検出精度
6	エリア B において、明るさ条件③の下、検出シナリオに基づき撮影を実施。	エリア B の AI 検出精度

2) 設置・撤去時間

a. 目的

可搬型カメラシステムは、利用者が容易に任意の位置に設置できる利便性を有する。本検証の目的は、実際の運用を想定した際の設置および撤去の効率性を確認し、その実現可能性を検証することである。

b. 評価項目

本検証では、図 5.5-11 に示すように、利用者がエリア A においてカメラシステムの設置および撤収に要する時間を測定する。具体的な評価項目は以下の通りである。

- 設置時間
- 撤収時間

なお、本検証においては、ケーブル配線および配線撤去に要する時間は除外する。



図 5.5-11 利用者の設置および撤去・移動の写真

c. 評価手法

本検証では、現場へのシステム導入時(初期設置)を想定した作業性の評価を行う。具体的には、専門の技術者ではない利用者が、事前に用意された設置マニュアルのみを参照して設置作業を実施する。図 5.5-12 に示す詳細なステップに従って作業を行い、各工程に要する時間を測定する。また、撤収作業については設置の逆工程として定義し、同様に作業時間を記録することで、システムの可搬性と設置・撤収の容易性を検証する。

- Step①:エッジサーバの設置
 - エッジサーバと LTE/5G ルータをスイッチングハブに LAN ケーブルで接続する。
- Step②:ファアエッジおよびカメラの設置
 - ファアエッジケース内に事前に接続されているファアエッジとスイッチハブを準備する。
 - カメラをスイッチハブに LAN ケーブルで接続する。
- Step③:カメラのビュー設定
 - 設定用 PC をスイッチングハブに接続し、専用ソフトウェアを利用してカメラビューの調整を行う。
- Step④:サーバアプリケーションの遠隔起動
 - 利用者ではなく、サーバ運営担当者が遠隔でアプリケーションを起動する。
- Step⑤:通知確認
 - 利用者がモバイルフォンのアプリケーション側で通知が正常に届くことを確認する。

留意事項: 初期設置後、エッジサーバを特定の場所に継続して運用する際には、次回の設置から Step①の設置手順は省略可能となる。




図 5.5-12 カメラシステム設置のステップ

d. 検証手順

具体的な検証手順は以下の表 5.5-11 に示す。本測定の検証において、事前に利用者にマニュアルを共有し、設置方法を十分に習熟させるものとする。また、本測定の直前には事前検証を実施し、利用者が設置を経験するようにする。利用者が1回以上設置を経験した後に本測定を実施するものとする。これは、経験が皆無な状態での個別の利用者における設置および撤去に要する時間の誤差を最小限に抑えるためである。

表 5.5-11 設置・撤去の検証手順

手順	説明	評価項目
1	エリア A において、事前検証として Step①～Step⑤の、設置作業にかかる時間を測定する。	設置時間
2	エリア A において、Step①～Step⑤の、設置作業にかかる時間を測定する。	設置時間
3	エリア A において、Step①～Step⑤の、設置作業にかかる時間を測定する。	撤去時間

3) 運用効率性評価

a. 目的

本実証の運用統括者より、システム利用時の操作感や運用負荷に関するフィードバックを収集する。これにより、実証を通じて明らかになった課題を特定し、将来的な社会実装に向けた具体的な対応策を検討することを目的とする。

b. 評価項目

本評価では、設置および撤去に関する以下の項目を評価対象とする。これらの項目を通じて、システム運用の実態と課題を詳細に分析する。

- システム利用者(警備担当者)向けインタビュー項目
 - 設置に関する項目
 - 撤去に関する項目

- 移動に関する項目
- 運用全般に関する項目
- システムの実用性(スマートグラス使用の場合)
 - 施設利用者向けヒアリング項目
 - 動線への影響
 - 施設利用への影響全般
 - プライバシー・安全性の観点

c. 評価手法

本評価では、実際にシステムを設置・撤去する担当者に対し、作業時間計測とヒアリング調査を組み合わせることで、定量・定性の両面から運用効率性を評価する。

- 時間計測: 図 5.5-13 に示した手順に基づき、設置・撤去に要する時間を計測する。
- ヒアリング調査: 作業完了後、担当者に対して以下の項目に関する詳細なヒアリングを実施する。
 - 作業手順の理解度、マニュアルの分かりやすさ
 - 特定のステップで困難を感じた点、その原因
 - 改善提案や要望事項
 - 作業負担の程度

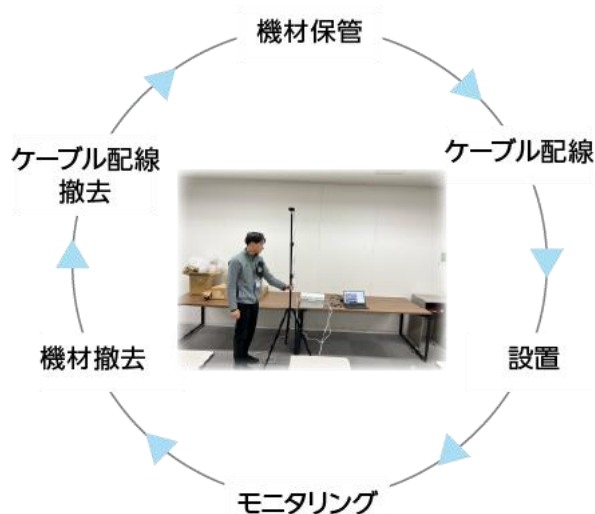


図 5.5-13 可搬形カメラ全般の運用イメージ

d. 検証手順

検証の具体的な検証手順は以下の表 5.5-12 に示す。

表 5.5-12 運用効率性評価の手順

手順	説明	評価項目
1	運用統括者にアンケートを実施	運用効率性評価
2	運用統括者にインタビューを実施	運用効率性評価

5.5.4 KPI/KGI

(1) AI モデル拡張性の検証

本検証は、オフライン環境下における「転倒検知」「暴力検知」「特定人物の顔認識」の各 AI モデルの精度検証を目的とする。精度の判断基準および KPI 目標値として「未検出率」「誤検出率」「処理遅延」を設定し、その詳細を以下の表 5.5-13 に示す。

表 5.5-13 AI モデル拡張性検証の KPI 目標値

定性評価 /定量評価	番号	目標値
定量評価	1	人物の転倒検知 ● 未検出率: ≤ 1% ● 誤検知率: ≤ 10% ● 処理遅延: 200~5000 ミリ秒
	2	暴力検知 ● 未検出率: 1%以下 ● 誤検知率: ≤ 10% ● 処理遅延: 200~5000 ミリ秒
	3	特定人物の顔認識 ● 未検出率: ≤ 1% ● 誤検知率: ≤ 10% ● 処理遅延: 200~5000 ミリ秒

1) 人物の転倒検知 – 目標値の設定根拠

転倒の目標値は、AI ベースの安全監視システムにおける業界の標準的な基準に基づいて設定された。検出漏れ率を 1%以下に抑えることで、運用環境において迅速な対応を要する転倒や暴力事件といった重大な安全事象を見逃すリスクを最小限に抑える。誤検知率を 10%以下に設定することで、検知感度と運用効率のバランスを保ち、監視スタッフの負担増やシステム信頼性の低下を招くことなく、偶発的な誤警報を許容する。処理遅延範囲 200~5000 ミリ秒(デフォルト 1000 ミリ秒)は、多段階モデルにおけるエッジサーバの典型的な推論性能を反映し、超低遅延処理を必要とせずに安全監視に十分な応答性を提供する。

2) 暴力検知– 目標値の設定根拠

暴力検知の目標値は、人物転倒の目標値と同様に業界安全性と効率的なバランスを保つ範囲で設定を目標とする。

3) 人物の顔認証– 目標値の設定根拠

顔認識の目標値は、信頼性と実用性を確保するため、AIベースの本人確認システム向け業界標準ベンチマークに基づき定義された。検出漏れ率≤1%は、必要な画質と検出条件を満たす個人に対する一貫した認識を支え、セキュリティ・安全関連ユースケースに不可欠である。誤検知率≤10%は、照明・姿勢・カメラ品質といった実環境の変動性と識別精度を両立させつつ、運用上の信頼性を損なう過剰な識別を防止する。処理遅延範囲 200~5000 ミリ秒(デフォルト 1000 ミリ秒)は、多段階顔認識パイプ

ラインにおけるエッジサーバの標準性能を反映し、タイムリーなシステム応答性を損なわずに拡張性の高い処理を可能にする。

(2) システム可搬性の検証

本検証は、システムの可搬性、および設置環境の変化に伴う AI 検知精度の安定性を評価することを目的とする。以下の表 5.5-14 に示す通り、異なる場所かつ同等の照度条件下で AI 精度を測定するとともに、運用総括者による設置・撤去作業の所要時間を計測し、システムの可搬性を検証する。

表 5.5-14 システム可搬性の検証における KPI の目標値

定性評価 /定量評価	番号	目標値
定量評価	1	環境変化に伴う AI 検出精度測定 <ul style="list-style-type: none"> 場所 A と場所 B の検出差(誤差率の差):10%未満
	2	設置・撤去時間測定 設置・撤去時間
定性評価	3	運用効率性評価

1) 場所 A と場所 B の検出差(誤差率の差):10%未満

場所 A と場所 B の検出差(誤差率の差):10%未満、ここでの誤差率は、(誤検知+未検知)/すべてのケース数 とする。実施内容計画において、設置場所 A・設置場所 B とともに「誤検知率 10%未満(目標)」「未検知率 1%未満(目標)」の AI を適用予定である。この前提に基づけば、各設置場所の誤差率は $\leq 11\%$ (誤検知率と未検知率の合計)となることが期待される。

2) 設置・撤去時間

設置および撤去にかかる時間を測定し換算した人件費を全体のコストと合算し、常設カメラを設置した場合のトータルコストと比較する。実運用を想定した条件下で、設置開始から利用可能状態までの時間と、撤去開始から撤去完了までの時間を計測し、その結果を用いて運用実現性を評価する計画である。

3) 運用効率性評価

システム利用者への可搬性カメラの設置、撤去および運用に関するインタビューを通じて、利便性や今後の課題解決策について考察。

5.6 効果検証

5.6.1 実証内容の詳細

本ソリューションは、圧縮アルゴリズムによる通信量削減技術と可搬型 AI カメラシステムがもたらす経済的効果、並びに既存通信インフラの有効活用と社会的価値について、以下の項目により検証する。

- コスト削減効果
- 投資対効果(ROI)

(1) コスト削減効果

本ソリューションの導入により期待されるコスト削減効果は、図 5.6-1 に示す通り、従来の既存ソリューションと比較して、初期導入費用および運用コストの両面から検証する。

総コスト: 初期導入コストと5年間の運用コストの合計を比較評価する。

- 総コスト: 初期導入コスト+運用コスト(5年間)

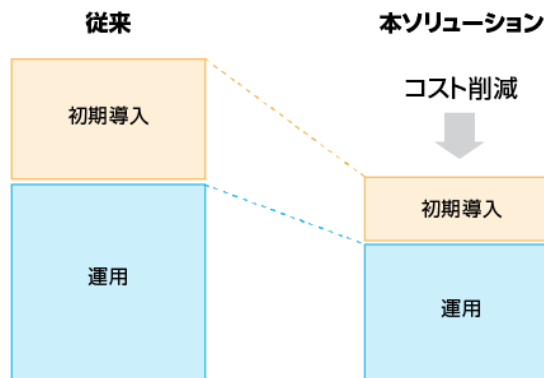


図 5.6-1 通信量削減における効果検証のイメージ

(2) 投資対効果(ROI)

本ソリューションがもたらす投資対効果(ROI)およびその他の経済的価値については、以下の項目を評価する。

- 業務員負荷軽減の検証
 - 業務時間短縮の評価: 常時監視や巡回警備などにおける現状の業務時間・工数を把握し、本ソリューション導入による業務効率化の効果を試算する。AI が異常を検知・通知することで、担当者が能動的に監視を行う必要が減り、業務負担が軽減されることを定量的に評価する。
 - 労働力不足への対応: 労働力不足が深刻な問題となっている現状において、AI 技術を活用することで、限られた人材をより効率的に活用できるようになる。また、AI が異常検知を担うことで、熟練者と非熟練者のスキル差を補完し、対応可能な人材の幅を広げることによる経済的・組織的価値を評価する。カメラ設置の柔軟性向上の検証
- カメラ設置の柔軟性向上の検証
 - 設置工数削減の評価: 可搬型カメラの設置にかかる工数を計測し、固定式のカメラ設

置にかかる工数との比較により、設置の柔軟性がもたらす経済効果を評価する。

- 機会損失の低減：大規模施設に監視システムを導入するためには、電源工事・配線工事・カメラ設備などの大規模な初期投資が必要となる。加えて、工事を伴う導入は施設が商用利用できない期間を発生させ、機会損失に繋がる可能性がある。ポータブルなソリューションは、初期投資コストを抑えるだけでなく、工事期間の短縮や施設の稼働率向上を通じて、運営者の経済効率を向上させる効果を評価する。
- 消費電力削減効果
 - 通信ネットワークのエネルギー消費原単位や帯域あたりの消費電力(W/Gbps)などの係数を用い、本ソリューションで削減されるデータ通信量に基づき、削減される消費電力量および電力コストを試算する。これは、環境負荷低減という側面と、運用コスト削減という経済的価値の両方を含む。

5.6.2 前提条件

上記のコスト削減および投資対効果の計算に対する効果検証は、表 5.6-1 に示すように地理的・空間的要件を伴う大規模施設の運用を想定し、以下の前提条件を設定する。




図 5.6-2 カメラ設置エリアの範囲

表 5.6-1 効果検証の前提条件

前提項目	詳細
カメラ設置場所	10 箇所
設置場所の面的	150m × 150m
導入期間	5 年
メンテナンス	5 年無償保証
運用時間	24 時間
リスク Event の検知数	カメラ 1 台当たり 12 件/日
データの保存期間	1 ヶ月
既存一般ソリューション	AI なし
回線	楽天モバイル

表 5.6-2 本ソリューションと一般ソリューションの前提

前提項目	①本ソリューション	②一般ソリューション		
		②-1 定式カメラ	②-2 Wi-Fi 型	②-3 ローカル 5G 新設
AI 型	O	X	X	X
監視業務員	1 人/日	3 人/日	3 人/日	3 人/日
データストレージ	HDD/SSD	HDD/SSD	クラウド	クラウド
通知	モバイルフォンアプリ	なし(常時監視)	モバイルフォンアプリ	モバイルフォンアプリ

5.6.3 評価項目

本検証は、本ソリューション導入時における既存施設の運用コストおよび一般的なソリューションの費用を比較し、その導入効果を明らかにすることを目的とする。以下の表 5.6-3 に効果検証の項目を示す。

表 5.6-3 効果検証の項目

番号	評価項目
1	コスト削減効果
2	投資対効果(ROI)

(1) コスト削減効果

- 総コスト
- 計算式
 - 総コスト=導入コスト+5年間の運用コスト
 - 初期導入費用: ハードウェア購入費、設置工事費など
 - 運用費用(5年間): 人件費、電気代、通信費、データ保存費、ライセンス費用、設備保守費など

(2) 投資対効果(ROI)

- 業務員負荷軽減の検証

検証は、従来の業務プロセスにおける年間業務員負荷時間と、エッジ AI 導入後の業務プロセスにおける年間業務員負荷時間を比較する。

- 計算式: 人件費削減額=(削減された業務時間)×(人時単価)×期間
 - 検証にあたっては、以下の要素に着目し、エッジ AI 導入前後の業務時間を比較することで、業務負荷軽減効果を算出する。
 - AI によるリスクイベント自動検知・通知: 従来の常時監視や広範囲の巡回警備の必要性を低減し、初期対応や確認作業にかかる時間を削減する。
- カメラ設置の柔軟性向上の検証
 - コスト削減額=(ケーブル固定式コスト)-(本ソリューション総コスト)
 - 消費電力削減効果

- 消費電力削減効果 (kWh/年) = (削減されるデータ通信量 (Gbps)) × (帯域あたりの消費電力 (W/Gbps)) × (年間稼働時間 (時間/年)) ÷ 1000

5.6.4 KPI/KGI

上記、表 5.6-3 の各項目に対応する詳細な算出内訳を以下の表 5.6-4 に示す。

表 5.6-4 効果項目の算出内訳

定性評価 /定量評価	番号	目標値
定量評価	1	コスト削減効果 - 総コスト(初期導入費用+運用費用)
	2	投資対効果(ROI)- 業務員負荷軽減の検証
	3	投資対効果(ROI)- カメラ設置の柔軟性向上の検証
	4	投資対効果(ROI)- 消費電力削減効果

(1) コスト削減効果 - 総コスト(初期導入費用+運用費用)

1) 目的

本プロジェクトは、本ソリューションの導入により、単なる通信量の削減に留まらず、警備業務における総コストの抜本的な削減を目指す。ここでいう総コストとは、ソリューションの導入から 5 年間の運用期間にかかる費用全体を指す。

検証は、本ソリューションを導入した場合の総コストと、比較対象となる既存または代替ソリューション(例:固定式有線 LAN ソリューション、ローカル 5G 新規構築ソリューションなど)の総コストを比較する形で行う。これにより、エッジ AI がもたらす具体的な経済的メリットを明確に示す。

2) 妥当性および設定理由

- ベンチマーク調査との整合性

本ソリューションは、他の一般的なソリューションと比較して、顕著なコスト削減効果を示すことが期待される。これは、同種の DX 推進プロジェクトにおける成果と照らし合わせても、有力な効率改善に該当するものである。この評価項目を設定することで、本ソリューションが単なる改善に留まらず、先進的なコスト構造改革をもたらす可能性を客観的に示すことができる。

- 短期的な投資回収と長期的な経済的合理性

導入コストに対する運用コストの削減効果を評価することで、投資回収期間の短縮と長期的な経済的合理性を検証する。これにより、本ソリューションへの投資が、持続的なコスト削減と高いリターンをもたらすことを論証する

(2) 投資対効果(ROI)- 業務員負荷軽減の検証

1) 目的

本プロジェクトで実証する本ソリューションは、リスクイベントの自動検知と生成 AI による状況要約レポートの自動生成機能を通じて、業務員の監視業務時間の削減、業務効率化することを目的としている。この項目では、業務員が監視業務や報告書作成に費やす時間の削減効果を定量的に検証する。

2) 妥当性および設定理由

- 労働力の最適化

労働力不足が深刻な問題となっている中、AI 技術を活用することで、限られた人材をより効率的に活用できるようになる。また、常時担当者が能動的に監視を行うのではなく、AI が異常を検知・通知することで熟練者とのスキルの差を解消し、対応できる人材の幅を広げることができる。これにより、警備業務の質を維持しつつ、他の業務とのリソースの最適配置が可能となる。

- 包括的な投資対効果(ROI)の最大化

業務員負荷の軽減は、警備業務への対応人数・時間に起因する人件費削減という直接的なコスト削減効果を生み出す。この効果は、組織全体の生産性向上とリスク低減に繋がっており、本ソリューションへの投資が高い費用対効果をもたらすことを示唆する。削減された時間を他の高付加価値業務に再配分することで、プロジェクト全体の事業貢献度をさらに高めることが可能となる。

(3) 投資対効果(ROI)- カメラ設置の柔軟性向上の検証

1) 目的

本プロジェクトのエッジ AI は、その本質的な特性として、カメラ設置の柔軟性を飛躍的に向上させることを目指している。この項目では、カメラ 1 台を設置する際にかかる工数を定量的に検証し、従来の設置方法と比較してどの程度の効率化が図れるかを示す。

2) 妥当性および設定理由

- 大規模展開におけるコストと時間の削減

従来の有線 LAN 敷設を伴うカメラ設置は、ケーブルルート設計、配線工事、壁面や天井への穴あけ作業など、多大な時間と専門的な技術、そして高額な工事費用が発生する。本ソリューションのポータブルなアーキテクチャと、将来的な無線通信技術の採用は、これらの大規模なケーブル敷設工事をほぼ不要とし、設置にかかる工数と費用を大幅に削減する可能性を秘めている。この評価項目は、プロジェクト全体の導入期間短縮とコスト削減に直接的に貢献する効果を検証するために不可欠である。

(4) 投資対効果(ROI)- 消費電力削減効果

1) 目的

I 本ソリューションは、その先進的な設計と技術により、総体的な消費電力の大幅な削減を目指してい

る。この項目では、ソリューション導入による電力コストの削減効果を定量的に検証する。

2) 妥当性および設定理由

- データ通信最適化と通信ネットワークの電力効率化

本ソリューションは、リスクイベントの検知内容とネットワーク状況に応じて最適な情報形式(テキスト、静止画、動画)を選択し、前処理・圧縮を行うことで、不要なデータの送信を抑制する。

6. 実証の結果・考察

6.1 全体スケジュール

本検証は大きく3つのテーマ「エッジ AI による通信量の低減」、「拡張性に関する検証」、「効果検証」において以下のスケジュールで実施した。

全体スケジュール(6.1)

ユースケース	フェーズ	2025年										2026年		
		5月	6月	7月	8月	9月	10月	11月	12月	1月	2月			
共通						▲ 9/19 政務官視察会			▲ 現地実証	▲ 中間報告	▲ 現地実証		▲ 1/16 視察会	▲ 最終報告
	実証準備 (事前計測、物品調達等)	機器調達			システム開発・環境構築									
					カメラ 2台 環境検証		カメラ 10台 環境検証							
ユースケース①：エッジ AI による通信量の低減	実証							現地実証 (データ取得)						
拡張性に関する検証								現地実証 (データ取得)						
効果検証											データ解析			
	実証評価						中間報告 書作成					報告書作成		

1

図 6.1-1 全体スケジュール

6.2 ユースケース①：エッジ AI による通信量の低減

6.2.1 実証スケジュール

「ユースケース①：エッジ AI による通信量の低減」の実証は以下のスケジュールで実施した。

ユースケース	項目	2025年										2026年			
		5月	6月	7月	8月	9月	10月	11月	12月	1月	2月				
共通						▲ 9/19 政務官視察会		中間報告				▲ 1/16 視察会	最終報告		
		機器調達				ファアーエッジ上AIシステム開発				エッジサーバ上AIシステム開発				エンドユーザアプリケーションの開発	
ユースケース① 通信量削減	実証						▲ 現地実証	データ取得	データ分析						
共通	実証評価						中間報告書作成					報告書作成			

図 6.2-1 実証スケジュール

6.2.2 開発・評価項目の結果

具体的な開発・評価項目は下記の表の通りである。

表 6.2-1 「エッジ AI による通信量の低減」開発・評価項目一覧

番号	開発・評価項目
1	ファアーエッジ上ソフトウェア(AWL Engine Agent)の開発
2	エッジサーバ上集約処理(Edge Server Application)の開発
3	エッジサーバ上統合・配信処理(Web API)の開発
4	AI 異常レポート要約エージェント(SLM コンポーネント)の開発
5	エッジサーバ上通信輻輳度取得コンポーネント(Congestion API)の開発
6	エンドユーザアプリケーションの開発
7	ファアーエッジ上 AI パイプラインの精度評価(中間) (1.の精度の測定)
8	ファアーエッジ上 AI パイプラインとの精度評価(実証) (1.の精度の測定)
9	エッジサーバ上 AI 異常レポート要約エージェント(SLM)の精度評価 (4.の精度の測定)
10	ファアーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価 (1., 3., 4.によるデータ削減効果の測定)
11	警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定 (1., 2., 3., 4.による処理速度の測定)
12	エンドユーザアプリケーションを使用した警備担当者からのフィードバック収集 (5.の操作しやすさについての評価)

(1) ファアーエッジ上ソフトウェア(AWL Engine Agent)の開発

1) AI パイプラインの開発

当初計画では、各モデルのパラメータ最適化を行い、必要な場合にのみファインチューニングや部分的再学習を行うこと予定だったが、初期のオンサイト評価において、一部モデル——特に人物検出において——については、事前学習済みモデルの使用が要求される性能レベルを達成するのに十分であることが示された。その結果、開発プロセスでは計算負荷の高い再学習よりも、パラメータ最適化とルールベースの改良を優先した。この変更により開発期間が短縮され、大規模なラベル付きデータセットの準備に伴う遅延を回避できた。主な要因は、実証現場における環境変動(照明、カメラ角度、被写体までの距離)が、閾値調整、ROI 調整、後処理ルールによって対処可能であり、基盤となる重みを変更する必要がないことが判明したことである。

AI パイプライン(人物・頭部)の開発においては、主に SNPE 実行向けに最適化された事前学習済みモデルに依存した。実証期間中に完全な再学習は行われなかったが、閾値パラメータ、フィルタリングルール、ROI 設定は現場検証結果に基づき反復的に調整された。これらの調整は GPU ベースの再学習を必要とせず、エッジデバイス上でのパラメータ調整で完了した。

詳細については 4.3「AI モデルの学習プロセス」、4.4「AI モデルの開発・学習にあたっての留意事項等」参照。

2) AWL Engine Agent の開発

AWL Engine Agent は、AI パイプラインと連携して動作するファーエッジ側の制御・通信レイヤとして機能する。

以下に AWL Engine Agent のシステム構成図を示す。

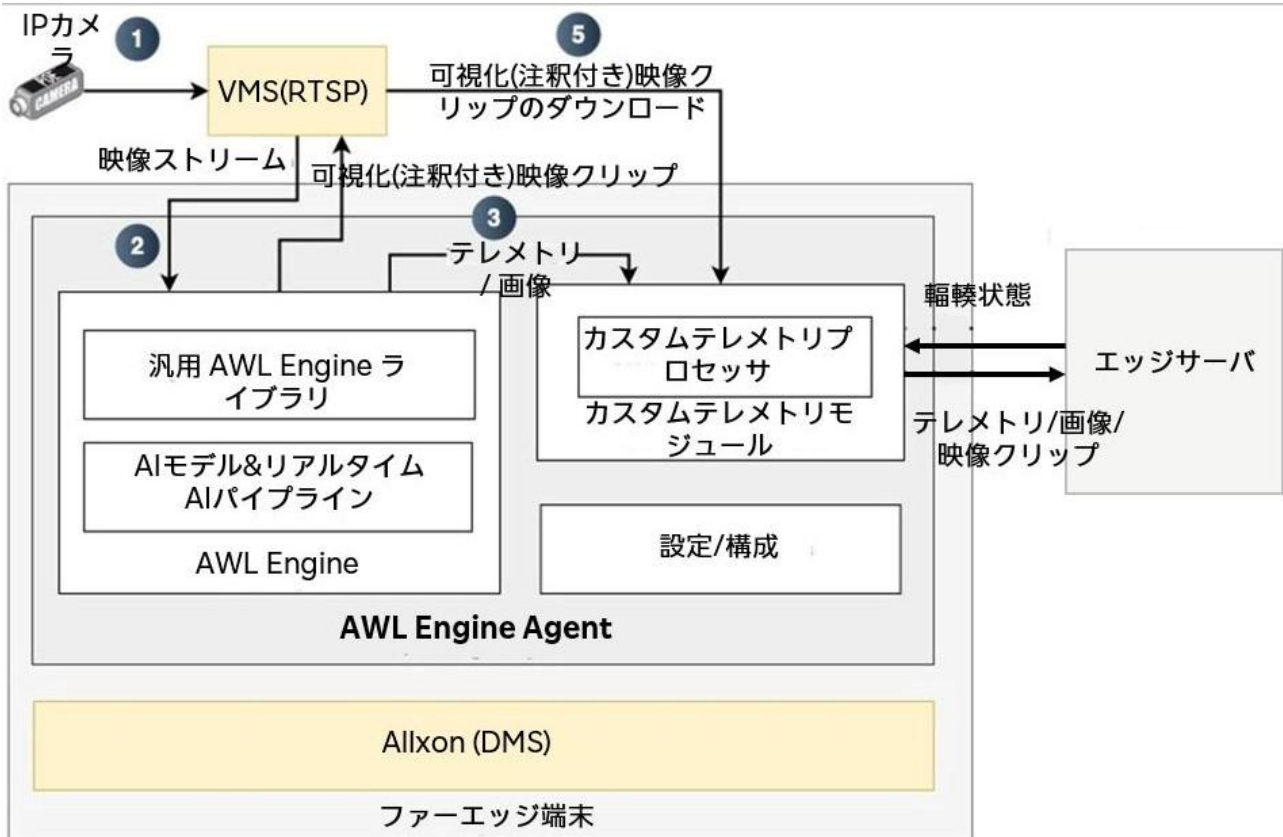


図 6.2-2 AWL Engine Agent システム構成図

各コンポーネントの概要は以下の通りである。

a. AWL Engine

AI 推論性能に制約があるファアーエッジデバイスにおいて、IP カメラより映像をリアルタイムで入力し、AI パイプラインによる推論処理を行い、推論結果を出力する、一連の制御を行う AWL 製のソフトウェアである。

AWL Engine は、複数の AI パイプラインを並列制御・結合する機能がある。このため、1 台のファアーエッジデバイスに複数の IP カメラを接続し、これをリアルタイム・並列で推論処理を行うことも、1 台の IP カメラの映像に対し、複数の AI パイプラインを並列に処理することもできる。

b. 汎用 AWL Engine ライブラリ

映像フレームに対する AI 推論を実行するためのコア SDK である。

c. リアルタイム AI パイプライン

リアルタイム AI パイプラインは、Qualcomm SNPE ランタイム上で動作する最適化された検知モデルによりカメラフィードを処理する。モデルは、シーン内の成人、子ども、頭部領域、および顔領域を識別し、スタジアム環境で典型的な変動する照明条件や混雑状態下で安定したパフォーマンスを維持するために、構成可能な確信度スコア閾値とサイズフィルタリングを適用する。追跡は ByteTrack アルゴリズムを使用して実行され、フレーム間で持続的な ID を保持し、イベントの期間(例:侵入時間、群衆形成)の正確な決定を可能にし、冗長な報告を防ぐ。

詳細は 4.1「AI モデルの全体像」参照。

d. カスタムテレメトリプロセッサ

AI 推論パイプラインの出力したリスクレベルと、2) エッジサーバ上集約処理 (Edge Server Application) から一斉配信されたネットワーク輻輳度に応じて、1 つないし複数の圧縮方法(テキスト変換、画像変換、および映像クリップ)を選択して映像を圧縮し、2) エッジサーバ上集約処理 (Edge Server Application) へ送信する。圧縮方法の選択・組み合わせについては下表参照。

表 6.2-2 カスタムテレメトリプロセッサによる、状況に応じた圧縮方式の組み合わせ

イベント重大度	定義	輻輳度:低	輻輳度:高
イベントなし(定期報告)	0 人		②
低リスクイベント	1 人(マスクなし、かつ 10-70 歳) < 5 秒	① ②	③ ②
高リスクイベント	2 人以上 1 人 > 5 秒 1 人かつマスクあり 1 人かつ 10 歳未満、または 70 歳を超える 煙・または炎あり	① ② ③	④ ②

⑤ : 超高圧縮(イベント情報テレメトリ JSON)、②:高圧縮(画像)、③:中圧縮(映像クリップ)

- 超高圧縮 - 映像をテキスト(イベント情報テレメトリ JSON)に変換する
- 高圧縮 - 映像を静止画像に変換する

- 中圧縮 - 継続的な映像ストリームの代わりに、リスクイベント前後 10 秒間のシーンだけを切り出した、短い映像クリップのみを送信する

(2) エッジサーバ上集約処理(Edge Server Application)の開発

エッジサーバ上集約処理(Edge Server Application)は C# で開発され、エッジサーバ上にデプロイされた。当機能は、複数のサービスで構成される、エッジサーバ上で動作するモジュール型システムである。複数のファアエッジデバイスと下位システムを接続する中核的な集約・制御ポイントとして機能し、AWL Engine Agent から TCP 接続を介して送信されるテレメトリおよびメディアデータを受信し、MessagePack 形式のペイロードを検証・デコードしたうえで、構造化されたテレメトリを MongoDB に保存し、関連する画像や映像クリップをストレージに格納する。また、KPI 計測や監査、性能分析を目的としたシステム活動ログの記録も担う。

さらに、エッジサーバアプリケーションはネットワーク輻輳状態の管理とフィードバックを行う。輻輳レポートを MongoDB から収集して最新のネットワーク状態を管理し、その情報を接続中のファアエッジデバイスへ配信する。

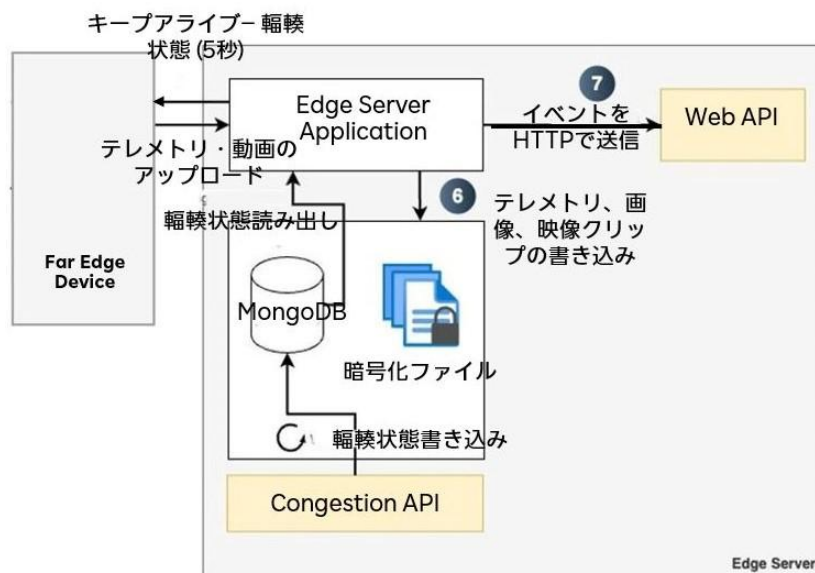


図 6.2-3 エッジサーバ上集約処理システム構成図・データフロー

(3) エッジサーバ上統合・配信処理(Web API)の開発

エッジサーバ上統合・配信処理(Web API)は、FastAPI フレームワークを使用した Python プログラムとして開発され、エッジサーバにデプロイされた。

当機能は、複数の RESTful Web API で構成されている。重要な API について、以下に処理概要を記載する。

1) POST /telemetry

AWL エッジサーバ上集約処理(Edge Server Application)から、ファアエッジからの圧縮データ受信時に呼び出される。

なお呼び出し元の Edge Server Application をブロックしないよう、新しくスレッドを立て非同期

処理として実行する。

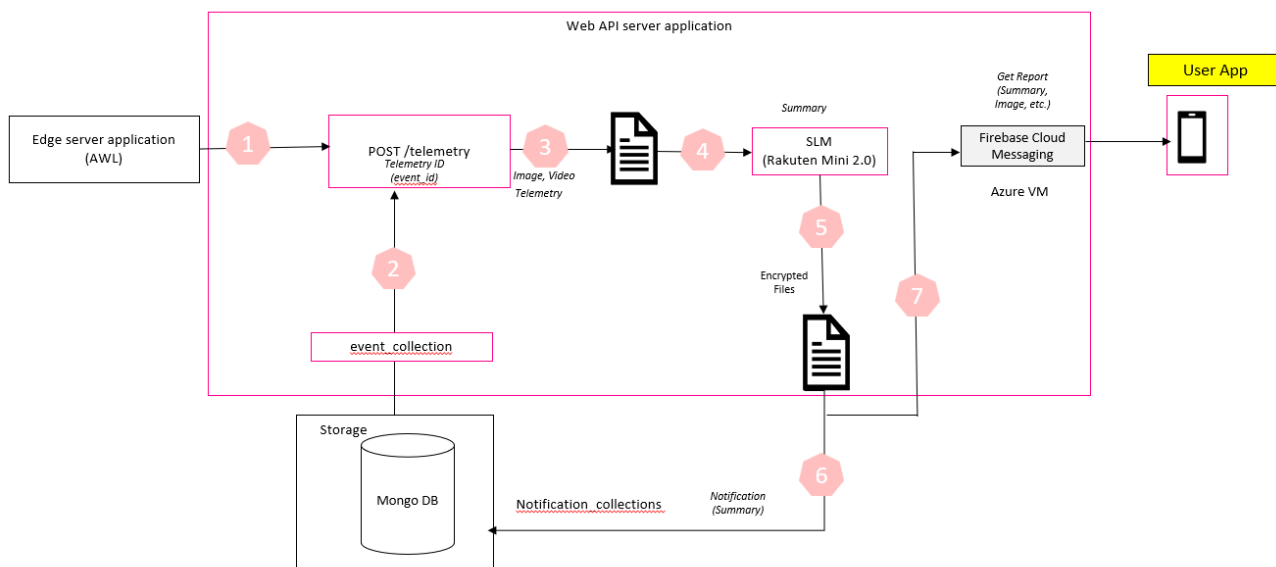


図 6.2-4 POST /telemetry 処理フロー

- ① Edge Server Application は、event_collection テーブルにイベント情報テレメトリ JSON、画像ファイルパス、映像クリップファイルパスを格納後、イベント ID をパラメータにこの API を呼び出す。
- ② MongoDB の event_collection テーブルから、対応するイベント情報テレメトリ JSON を取得。
- ③ MongoDB の event_collection テーブルから取得した画像パスに対応する画像を読み込み。
- ④ AI 異常レポート要約エージェントを用いて、イベント情報テレメトリ JSON の要約を作成。
- ⑤ 画像を base64 形式にエンコード。
- ⑥ 要約、base64 画像、イベント情報テレメトリ JSON をまとめて MongoDB (notification_collection テーブル) に保存。
- ⑦ Firebase Cloud Messaging (FCM) を介して、すべての登録済みデバイスへ要約テキストをプッシュ通知で送信。(画像、イベント情報テレメトリ JSON などはこの時点では送信されない)

2) GET /notifications

MongoDB の notification_collection テーブルに保存された通知の一覧を返す。

パラメータとしてタイムスタンプが指定された場合は、それよりも新しいレコードのみを返す。このパラメータは、エンドユーザアプリケーションが、既に取得済みの通知よりも新しい通知のみを取得するために使用できる。

また送信データ量(要約テキスト、画像)ログを MongoDB に保存する。この値は KPI5.1.6(4)「エッジサーバでの情報集約によるデータ送信削減率」を算出するために使用される。

3) GET /video

エンドユーザアプリケーションが映像クリップ再生ボタンを押下した際に、イベント ID をパラメータと

して呼び出され、MongoDB の event_collection テーブルから対応する映像クリップのパスを取得し、それに対応する映像クリップファイルを読み出し(④、⑤)、呼び出し元に返す(⑨)。

また、ユーザアクション(映像再生ボタン押下)ログ(②、③)、送信データ量(映像クリップ)ログ(⑥～⑧)を MongoDB に保存する。ユーザアクションログは、KPI 5.1.6(6)「エンドユーザの反応時間」を算出するために使用される。

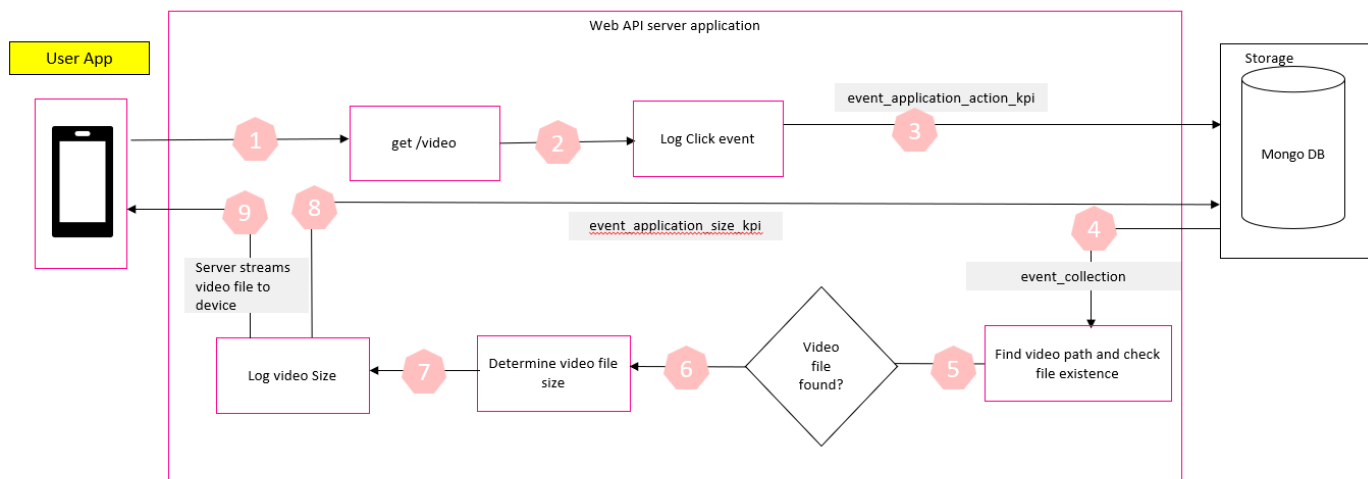


図 6.2-5 GET /video 処理フロー

4) 定期通知生成処理

15分ごと(00:05, 15:05, 30:05, 45:05)に定期的に行われる。直近15分間にすべてのファームウェアから受信した定期通知(異常なし)テレメトリJSONを event_collection テーブルから取得し(①～⑤)、AI異常レポート要約エージェントを使用して集約して要約を生成し(⑥)、notification_collection テーブルに保存し(⑦)、要約をすべての登録済みデバイスへプッシュ通知する(⑧)。

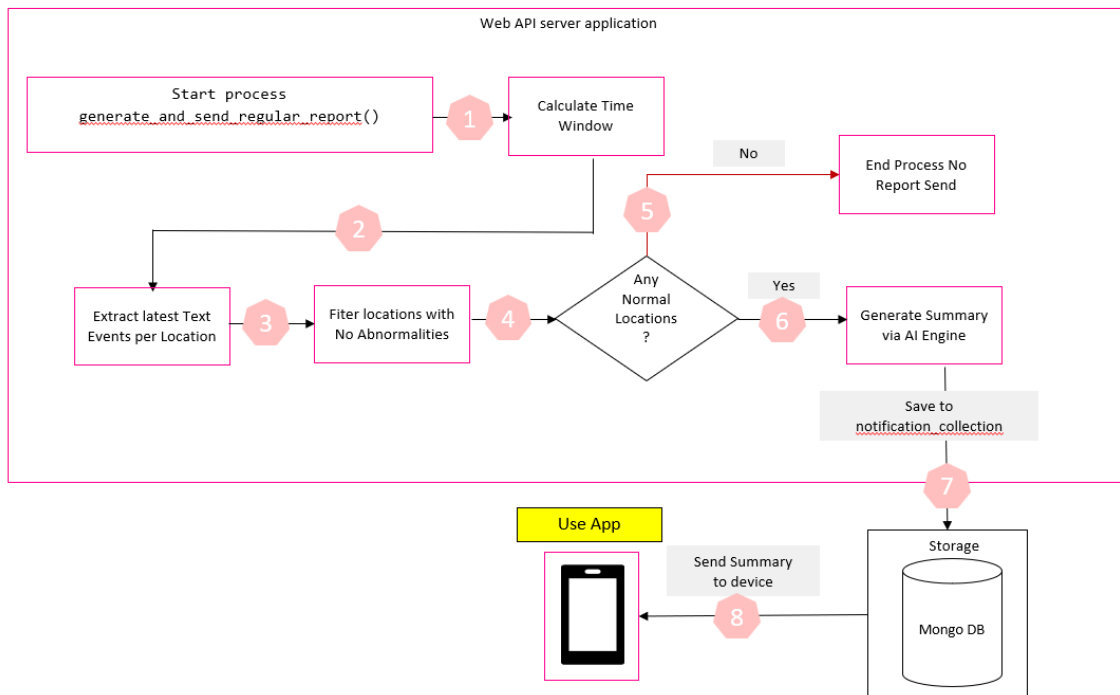


図 6.2-6 定期通知生成処理

5) POST /kpi_log

ユーザアクション(プッシュ通知クリック、通知一覧内の通知クリック等)ログを MongoDB に保存する。ユーザアクションログは、KPI 5.1.6(6)「エンドユーザの反応時間」を算出するために使用される。

6) 検証手順・測定手法・計測項目

各 API は、開発完了後に以下のようにして試験を実施した。

- POST 処理
 - 単体試験：API 呼び出し後の MongoDB 保存データ(と、POST /telemetry の場合 FCM メッセージ)の内容を、API 引数と比較
 - パフォーマンス試験：Postman、Curl コマンドを使用してレスポンス時間を測定
- GET 処理
 - 単体試験：API 呼び出し前の MongoDB データとレスポンス JSON の比較
 - パフォーマンス試験：Curl コマンドを使用してレスポンス時間を測定
 - GET /notifications に関しては、レスポンスまでに数十秒かかることがあったため、「タイムスタンプ」カラムにインデックスを追加して対応した

(4) AI 異常レポート要約エージェント(SLM コンポーネント)の開発

AI 異常レポート要約エージェント(SLM コンポーネント)は Python で実装され、エッジサーバ上にデプロイされた、同じく Python で実装された Web API の部品として組み込まれた。

AI 異常レポート要約エージェントは、ファーエッジから収集した映像メタデータを SLM に入力し、異常報告および定期報告の要約文を生成する。生成された要約は通知メッセージとして Web API 経由

でエンドユーザアプリケーションへ送信される。AI 異常レポート要約エージェントの開発に関するシステムアーキテクチャ、選定した SLM、精度向上のための手法などの詳細は、4 章に記載している。

ノエビアスタジアム神戸の実証実験では、主にプロンプトエンジニアリング手法を適用し、全体で 99.09% の高い正確率を示した。詳細な評価内容(評価指標や要約の正解定義など)は本節の(9)項目に記載している。また、システムの安定性については、4.4 節で詳述した。AI 異常レポート要約エージェントと Web API を統合した際、大量の異常イベント発生時の負荷により、まれにメモリエラーが発生した。ただし、発生は数回にとどまり、実証結果への影響は大きくなかった。予備手法であるファインチューニング版では当該メモリエラーが頻発したため、本番の実証での検証は使用しなかったが、開発環境でのオフラインテストの評価結果は(9)4)項目の AI 異常レポート要約エージェントの評価結果-2 (ファインチューニング手法)に記載している。

(5) エッジサーバ上通信輻輳度取得コンポーネント(Congestion API)の開発

本プロジェクトで開発した Congestion API は、OSS API からの指標値取得、輻輳状態の判定(0/1)およびデータベースへの格納、さらに観客数連動型中央値予測アルゴリズムによる Prediction KPI/Status の格納・提供機能が正常に動作することを確認した。この API により、ファアエッジデバイスへの輻輳情報提供のための基盤が確立された。

1) 実証

a. 評価環境

- a. 本実証は、2025 年 10 月 17 日(サッカー試合日)にノエビアスタジアム神戸において実施された。評価対象ネットワークは、楽天モバイル回線経由で提供されるサービスとした。実証当日の観客数は 25,806 人であり、これは事前に定義した「高観客数(20,000 人以上)」レンジに分類される。サーバ設置場所(楽天モバイル回線を使用)はスモールセルに接続されており、スタジアム入口のユーザはマクロセルに接続し、これが混雑の影響を受けていた。結果、ルータは輻輳の影響を受けず、ユーザ設置場所のみが輻輳の影響を受けていた。
- b. 実証当日、ネットワークのリアルタイム監視に用いる OSS API が正常動作せず、かつ対象エリアが高輻輳状態にあったため、手動での KPI 取得も困難であった。このため、リアルタイムでの実測 KPI 取得は不可能であった。この状況下で実証を継続するため、WebAPI 側で手動による模擬輻輳状態を設定し、この輻輳条件下でデータ削減がテストされた。
- c. Congestion API の基本機能を検証するために、試合後の実際のデータを取得した(表 6.2-3 実測値と予測値との比較(対象日:2025/10/17))。本報告では、この事後取得された実測指標値に対し、本実証のために開発した「観客数連動型中央値予測アルゴリズム」を適用した予測指標値と比較することで、実証当日の輻輳状況の再現性と予測性能の評価を可能な限り客観的に行うこととした。これにより、予測アルゴリズムに基づいた実証結果の妥当性を検証する。

表 6.2-3 実測値と予測値との比較(対象日:2025/10/17)

時刻/指標値	ダウンリンクリソース ブロック利用率		最大接続ユーザー数		セクターダウンリンク スループット		実測値 輻輳	予測値 輻輳	手動 輻輳
	70%超		150人超		20Mbps未満				
実測/予測	実測	予測	実測	予測	実測	予測			
16:00	17.5 %	14.3 %	24.0 %	18.0 %	84.5 %	173.0 %	○		-
16:15	21.3 %	21.5 %	29.3 %	22.7 %	79.5 %	168.0 %	○		-
16:30	36 %	48.8 %	34.0 %	72.0 %	78.0 %	120.0 %	○		-
16:45	64.4 %	83.3 %	49.3 %	76.0 %	67.5 %	73.0 %	○	○	-
17:00	55.2 %	40.4 %	44.7 %	80.7 %	76.5 %	125.0 %	○		-
17:15	42.3 %	31.0 %	46.0 %	29.3 %	97.5 %	168.5 %	○		-
17:30	68.5 %	28.4 %	47.3 %	56.7 %	72.0 %	111.5 %	○		○
17:45	63.5 %	46.1 %	56.7 %	61.3 %	71.5 %	75.0 %	○	○	○
18:00	76.4 %	47.4 %	58.0 %	64.0 %	58.0 %	74.0 %	○	○	○
18:15	62.6 %	26.0 %	60.0 %	50.0 %	92.0 %	103.5 %	○		○
18:30	52.9 %	20.1 %	57.3 %	22.0 %	103.5 %	159.5 %			○
18:45	33.9 %	23.8 %	36.7 %	18.7 %	85.0 %	189.0 %	○		○
19:00	14.8 %	27.1 %	20.7 %	11.3 %	110.5 %	268.5 %			-
19:15	9.2 %	8.9 %	13.3 %	9.3 %	138.5 %	203.5 %			-
19:30	6.6 %	9.3 %	12.0 %	8.0 %	158.0 %	183.0 %			-
19:45	12.9 %	14.1 %	22.0 %	14.7 %	87.5 %	199.5 %	○		-
20:00	16.7 %	12.5 %	28.0 %	16.0 %	73.0 %	155.5 %	○		-
20:15	14.5 %	11.2 %	12.7 %	10.0 %	119.0 %	194.0 %			-
20:30	22.3 %	14.8 %	12.0 %	9.3 %	142.5 %	181.5 %			-
20:45	22.5 %	13.5 %	15.3 %	11.3 %	123.0 %	141.5 %			-
21:00	64.5 %	32.7 %	68.0 %	38.7 %	62.0 %	116.0 %	○		-
21:15	51.7 %	44.5 %	55.3 %	44.7 %	101.5 %	132.0 %	○		○
21:30	28.6 %	23.2 %	43.3 %	33.3 %	142.0 %	158.0 %			○
21:45	8.8 %	16.0 %	20.0 %	26.0 %	158.0 %	151.0 %			○
22:00	4.7 %	12.0 %	16.0 %	10.7 %	133.5 %	182.0 %			○
黄色: 実測値輻輳									
ピンク: 予測値輻輳									
グレー: 実証未実施時間帯									

b. 評価結果

本実証では、予測アルゴリズムとして「観客数連動型中央値予測」を適用し、実証当日の観客数を「高観客数(20,000人以上)」レンジと仮定して評価を実施した。

輻輳の有無は16:00から22:00まで15分ごとに計測された。輻輳指標に基づいて、予測アルゴリズムは輻輳が発生する間隔を3回予測したが、結果的には、輻輳は15回発生した。

実測値との比較において、特に高輻輳時における予測精度に依然として課題が確認された。以下に、主要な指標値ごとの評価結果を示す。

a. DL_PRB_Utilization (ダウンリンク物理リソースブロック利用率)

DL_PRB_Utilization について、高観客数レンジに連動した中央値予測は、実測値と比較して以下の特徴を示した。

- 初期時間帯(16:00~17:00頃)における予測の過大評価:
16:45~17:00頃の予測値は最大83.3%に達し、実測値(最大64.4%)を大幅に上回って輻輳閾値(>70%)を超過した。これは、高観客数レンジの学習データにおいて、この時間帯に高いDL_PRB_Utilizationが観測される傾向が強いことを示唆する。観客数要因を考慮した結果、この時間帯における予測値は顕著に高い水準を示している。
- 主要な輻輳ピークに対する予測の限界:
実測値が輻輳閾値(>70%)を超過した18:00のピーク(実測値76.4%)および輻輳閾値に

迫った 21:00 のピーク(実測値 64.5%)に対して、予測値はそれぞれ 47.4%および 32.7%と推移し、ともに実測値を大幅に過小評価した。この結果は、高観客数時の平均的な傾向を中央値で捉えることには一定の効果があるものの、突発的なトラフィックの急増による瞬時的なピークを、中央値モデルのみで正確に予測することの限界を示している。




図 6.2-7 ダウンリンク物理リソースブロック利用率

図 6.2-7 ダウンリンク物理リソースブロック利用率:ダウンリンク物理リソースブロック利用率について、高観客数(≥20,000 人)の中央値予測は実測値よりも低く推移した。

特に 18 時以降は実測値が輻輳閾値を超えた時点もあるが、18:00 および 21:00 前後の実測値の急激な上昇を予測値は十分には予見できていない。

b. Max_UEs (最大接続ユーザ数)

Max_UEs:について、高観客数レンジに連動した中央値予測は、以下の点で実測値と乖離が見られた。

- 夕方の高負荷時間帯における予測の傾向: 16:30 から 18:15 にかけて、予測値は全体的に高い水準で推移したが、閾値を超える(>150)時間帯はなかった。この夕刻帯の予測は実測値を大きく上回り過大評価の傾向がみられた。ただ、17:30 以降は実測値の推移と比較して傾向は概ね捉えている様子が伺える。
- 夜間の急激なピークに対する予測の限界: 輻輳閾値には届かないものの、実測値が最も高いピークを示した 21:00(102 UEs)において、予測値は 58 UEs と大幅に過小評価した。同様に 21:15 のピーク(83 UEs)に対しても、予測値は 67 UEs に留まった。この時間帯は、試合終了後の退場に伴う一時的な高集中が考えられるが、高観客数レンジの学習データにおいても、この種の突発的かつ高負荷なイベントピークを中央値モデルが十分に学習しきれていない、あるいはその変動パターンをモデルが捉えきれない限界が示された。予測は全体的な増加傾向を捉えつ

つも、特定の急激なピークを予測する能力には課題がある。




図 6.2-8 最大接続ユーザ数

最大接続ユーザ数は、16:00 から 22:00 にかけて実測値が輻輳閾値(150UEs)を超過したことはない。

高観客数(≥20,000 人)の中央値予測は、このユーザ増加の傾向を概ね捉えているが、18:00 帯の実測値との乖離および 21:00 の急激な数値増加を十分には予見できていない。

c. Sector_DL_Throughput (セクターダウンリンクスループット)

Sector_DL_Throughput について、高観客数レンジに連動した中央値予測は、以下の特徴を示した。

- 輻輳発生傾向の概ねの捕捉:

実測値が輻輳閾値 (<20Mbps) を下回った 16:00 から 18:15 にかけて、予測値も同様に 20Mbps 前後で推移し、輻輳発生のトレンドラインを概ね捉えていた。予測値は閾値に近い水準で推移しており、観客数要因を考慮したことで輻輳の傾向を詳細に反映しようとしている。

- スループット低下に対する予測の限界:

しかし、実測値が示すスループット低下(例: 18:00 の約 11.6Mbps、21:00 の約 12.4Mbps)に対しては、予測値は実測値ほどの深い落ち込みを正確に予測できていなかった。この結果は、観客数レンジ別の中央値モデルが、ネットワークリソース枯渇に伴う極端なスループット低下の度合いを、実測レベルで精密に予測することには限界があることを示唆している。予測は全体的な輻輳傾向を捉えるものの、実測よりも「判定が緩い」傾向が継続している。




図 6.2-9 セクターダウンリンクスループット

図 6.2-9:セクターダウンリンクスループットは、16:45 から 18:15 にかけて実測値が輻輳閾値 (20.0Mbps)を下回った。(グラフ上は閾値:20Mbps=100%を上回っている箇所が該当)

高観客数(≥20,000 人)の中央値予測は、この時間帯の輻輳発生の特rendラインを概ね捉えているが、全体として実測値よりも判定が緩くなっている。

2) 実測値と予測値との乖離の要因分析

本実証で採用した「観客数連動型中央値予測」は、限られたデータ量という制約の下でロバストな予測を目指したが、実測値との乖離が発生した主要因として、以下の点が挙げられる。

a. 学習データ量の質的・量的制約:

a. データ量の不足:

直近 6 試合分のデータのみでは、スタジアムにおける多様なトラフィックパターン、特に突発的なイベントや時間帯ごとの微細な変動要因を十分に学習しきれていない。観客数レンジ別にデータを分類したとしても、各レンジにおけるデータポイントの数が依然として不足しており、統計的な安定性を完全に確保するには至っていない。

b. メタデータの不足:

試合の重要度(例:優勝決定戦、ダービーマッチ)、天候(雨天、猛暑)、曜日(平日、週末)、対戦相手のチームのファン層、具体的なイベントスケジュール(キックオフ時刻、ハーフタイム、イベント開催時間)といった詳細なメタデータが予測モデルに組み込まれていないため、観客数以外の影響因子を考慮できていない。特に、Max_UEs の 21:00 ピークのような試合終了後の突発的なユーザー集中は、単純な時間帯別中央値や観客数レンジだけでは捉えきれない複雑な要因(例:

試合結果、退場規制、二次交通機関の混雑状況)に起因する可能性が高い。

c. 高輻輳時のデータ稀少性:

過去のデータセットにおいて、実証当日と同等レベルの高輻輳状態のデータが不足していた可能性があり、モデルが極端な状況を学習できていないことが考えられる。これにより、実測値が閾値を大きく超過するような真の輻輳ピークに対する予測能力が限定されている。

b. 観客数連動型中央値モデルの特性と限界:

a. 突発的なピーク予測の困難性:

中央値モデルは外れ値に強いロバストな統計量である一方で、急激なトラフィック変動や、過去のデータにはない極端なピーク値(例:Max_UEs の 21:00 ピーク)を正確に予測する能力に限界がある。観客数レンジ別に中央値を算出しても、レンジ内のデータが示す「平均的な振る舞い」は捉えられるが、特定の試合や時間帯に発生する特異な事象(例:試合の劇的な展開、特定のイベント)による瞬間的な需要急増を捉えることは困難である。

b. 短期的な動的变化への対応不足:

観客数レンジ別の中央値は、時間帯ごとの一般的な傾向を捉えるには有効だが、短期的な動的变化やイベント進行に伴う突発的な変化をモデル化する能力には限界がある。特に、試合の開始・終了、ハーフタイムなどのイベントポイントにおける急激なトラフィックパターン変化は、より詳細な時系列モデルやイベントドリブンなアプローチが求められる。

c. 予測の過大評価/過小評価:

DL_PRB_Utilization の 16:45~17:00 における予測の過大評価や、Max_UEs の 21:00 における過小評価は、観客数レンジ内の過去データ分布の偏りや、中央値モデルが持つ「代表値」としての性質に起因すると考えられる。すなわち、レンジ内の少数の極端なデータポイントに引きずられることなくロバストである反面、その極端な挙動自体を予測することが困難である。

d. 実証環境の偶発的特殊性(リアルタイム KPI 取得の困難性:)

OSS API のトラブルにより、実証当日のリアルタイムな実測指標値取得が不可能であった。事後的な指標値取得と予測値の比較は行ったものの、リアルタイムでの評価ができなかったことは、予測モデルの即時性・適応性の検証を制約した。これにより、予測モデルの運用上の有効性を完全に検証できなかった。

3) 考察

今回の実証により、観客数連動型中央値予測はネットワーク挙動の傾向把握において一定の有効性を示し、予測の解釈可能性を向上させることが確認された。しかし、中央値モデルの特性上、突発的なトラフィックピークの捕捉や輻輳度の精密な予測には限界があることが明らかになった。特に、学習データ量の不足が、予測の過大評価などの課題を生じさせ、実運用における高精度な予測にはさらなる改善が必要であると考えられる。

4) 結論

今回の開発において得られた知見を活かしつつ、将来的には RIC 等の活用でリアルタイム性を追求

することも一つの手段になり得ると考える。

(6) エンドユーザアプリケーションの開発

エンドユーザアプリ(スマートフォンアプリ、スマートグラスアプリ)は、以下の構成で開発され、各試験端末にインストールされた。

- スマートフォンアプリ
 - 機種: SHARP AQUOS R5G
 - OS: Android 11
 - 開発環境、言語: Unity, C#
 - コンテンツ表示方式: UI のみを 2D 表示する。
- スマートグラスアプリ
 - 機種: Apple Vision Pro (256GB, MQL83J/A)
 - OS: visionOS 2
 - 開発環境、言語: Xcode, Swift
 - コンテンツ表示方式: 実空間にオーバーレイする形で UI を AR 表示する

以下に、エンドユーザアプリの詳細仕様を記載する。

1) スマートフォンアプリ詳細仕様

- プッシュ通知表示
 - 異常通知、定期通知ともに、SLM より生成された要約レポートは、FCM を使用したプッシュ通知により、Web API からユーザデバイスに配信され、端末のポップアップ通知として表示される。



図 6.2-10 プッシュ通知表示 (左 : アプリ上、右 : 端末の通知表示領域)

警備担当者は、プッシュ通知により、アプリを開いている時(アプリがフォアグラウンドにある)もそうでない時(アプリがバックグラウンドにある・または起動していない)も、バイブレーション・通知音など(端末の通知設定に依存する)により即座に通知を検知できる。なお、実施計画書に記載した音声による通知の読み上げは Voice Notify などのサードパーティ製アプリを使用すれば実現可能だが、バイブレーション・通知音などで必要十分であり、また警備業務の妨げになる可能性があるため今回は使用しなかった。

ユーザがプッシュ通知をクリックすると、アプリは新しい通知を通知一覧取得 Web API(GET /notifications)で取得した後、対応する通知詳細画面に遷移する。

- 通知一覧の取得
 - プッシュ通知を受信すると(アプリがフォアグラウンドにある場合)、またはユーザがポップアップ通知をクリックすると(アプリがバックグラウンドにある場合)、アプリは通知一覧取得 Web API(GET /notifications)を呼び出し、新しい通知一覧を取得し、通知一覧画面に降順で表示する。
 - 未読通知の場合、タイトル(定期通知/異常通知)の右に青い丸が表示され、タイトルが

太字で表示される。



※保安上の理由から地点名はマスクしてある

図 6.2-11 通知一覧画面(左：定期通知一覧、右：異常通知一覧)

通知一覧内の通知をクリックすると、通知詳細画面に遷移する。

- 通知詳細画面
 - 定期通知詳細画面には、受信日時と、SLM により生成された要約レポートのみが表示される。
 - 異常通知詳細画面には、リスクレベル、受信日時、SLM により生成された要約レポート、画像、検知対象ラベルが表示される。
 - 高リスクイベントかつ輻輳状態でない場合、画像には映像再生ボタンが表示される。低リスクイベントまたは輻輳状態の場合、ファアエッジ上ソフトウェア (AWL Engine Agent) において②: 高圧縮 (画像) のみが表示され、③: 中圧縮 (映像クリップ) 方式は使用されないため、映像再生ボタンは表示されない。
 - 映像再生ボタンを押下すると、映像クリップ取得 Web API (GET /video) により映像がエッジサーバからダウンロードされ、再生される。
 - なお再生中の映像クリップでは、検出されたオブジェクトの周りにバウンディングボックス

が表示される。

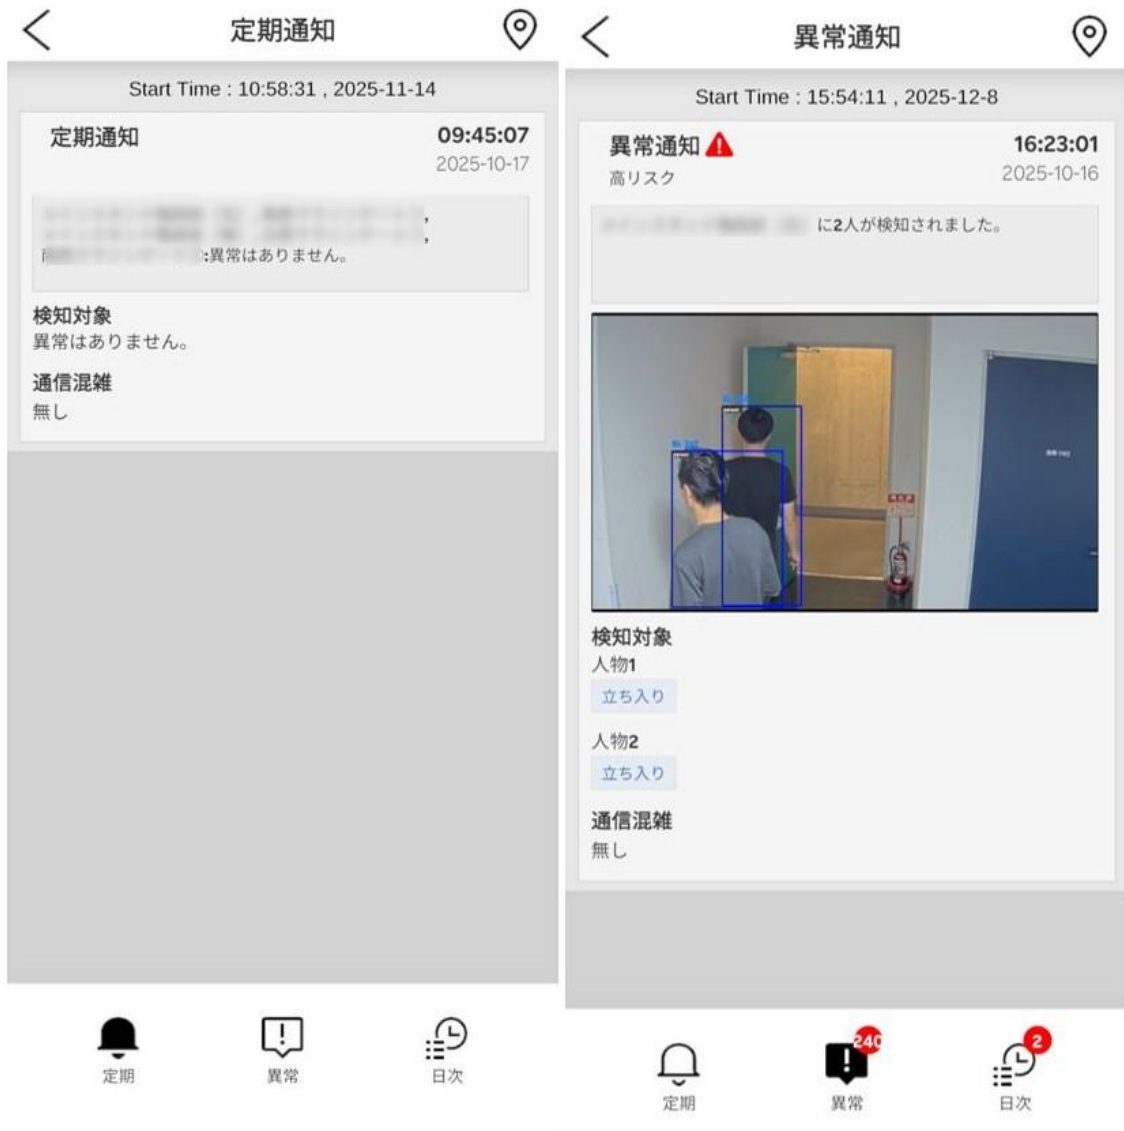


図 6.2-12 通知詳細画面(左：定期通知、右：異常通知(高リスク、輻輳なし))

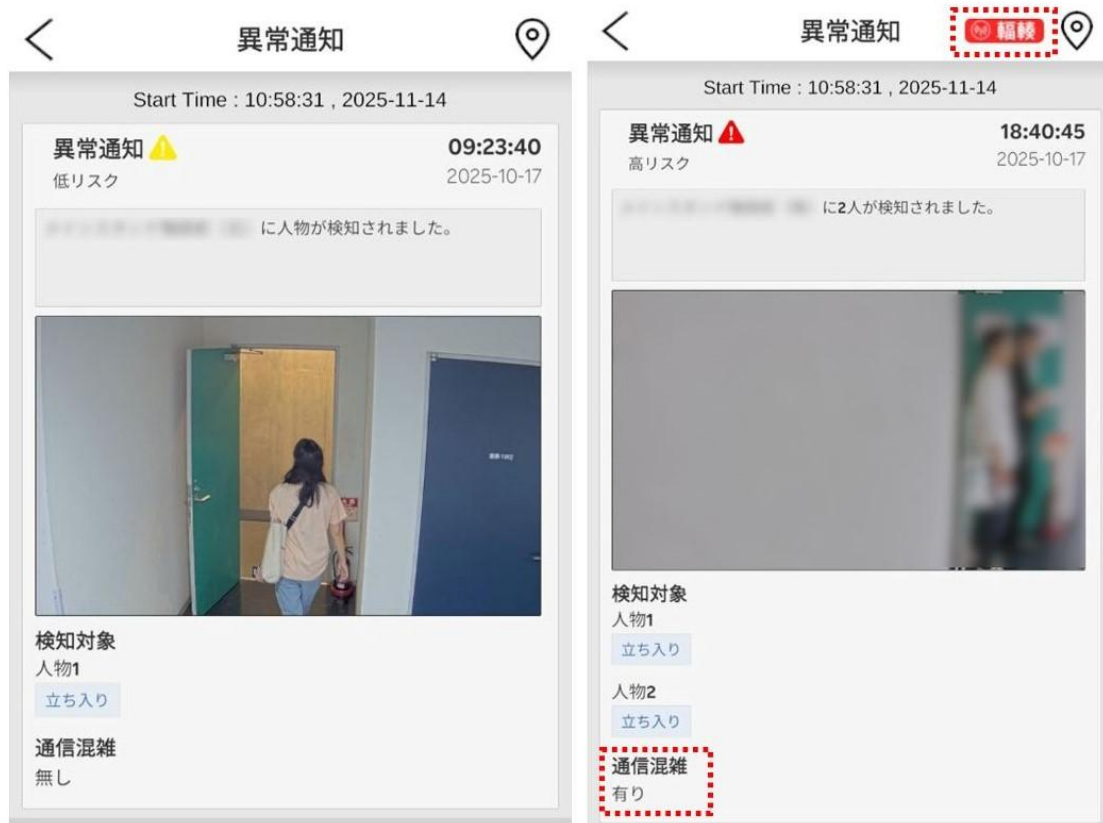


図 6.2-13 左：低リスク、右：高リスク、輻輳あり(映像再生ボタンは表示されない)



図 6.2-14 映像クリップ再生中(バウンディングボックスが検出対象の周りに表示される)

以下にすべてのイベント種別の詳細画面表示例(非輻輳状態)を示す。

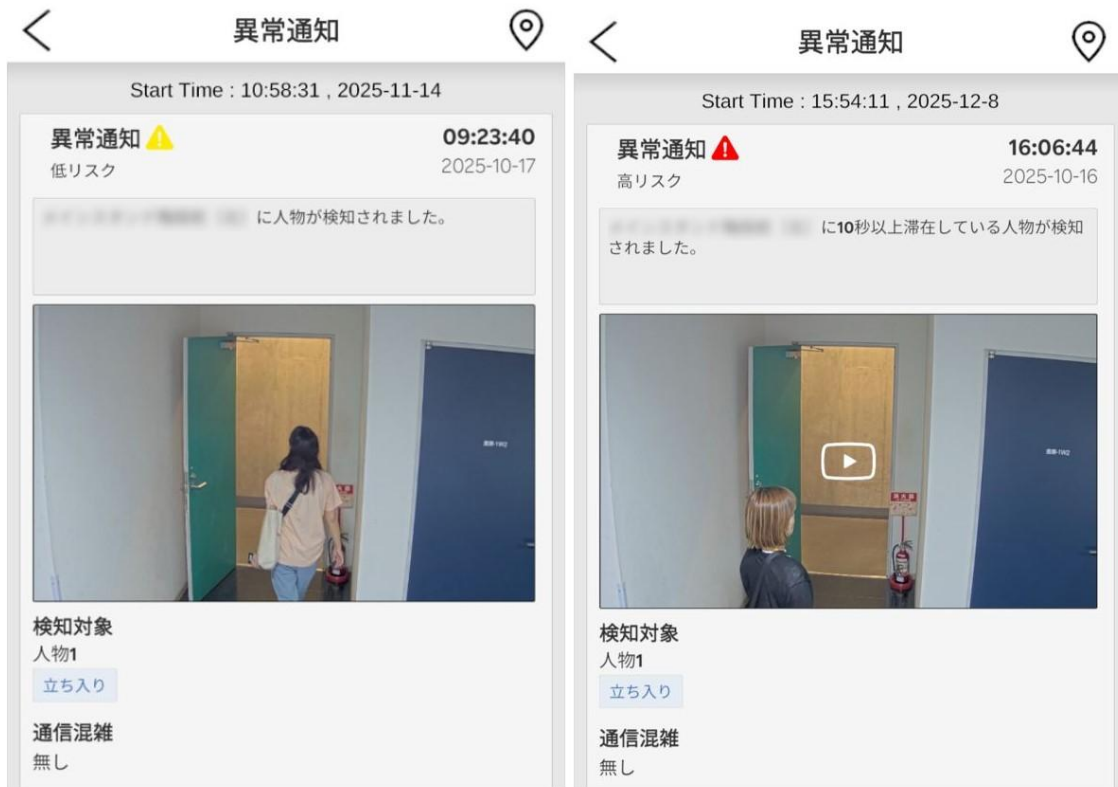


図 6.2-15 左：低リスク(1人、10秒未満)、右：高リスク(1人、10秒以上滞在)

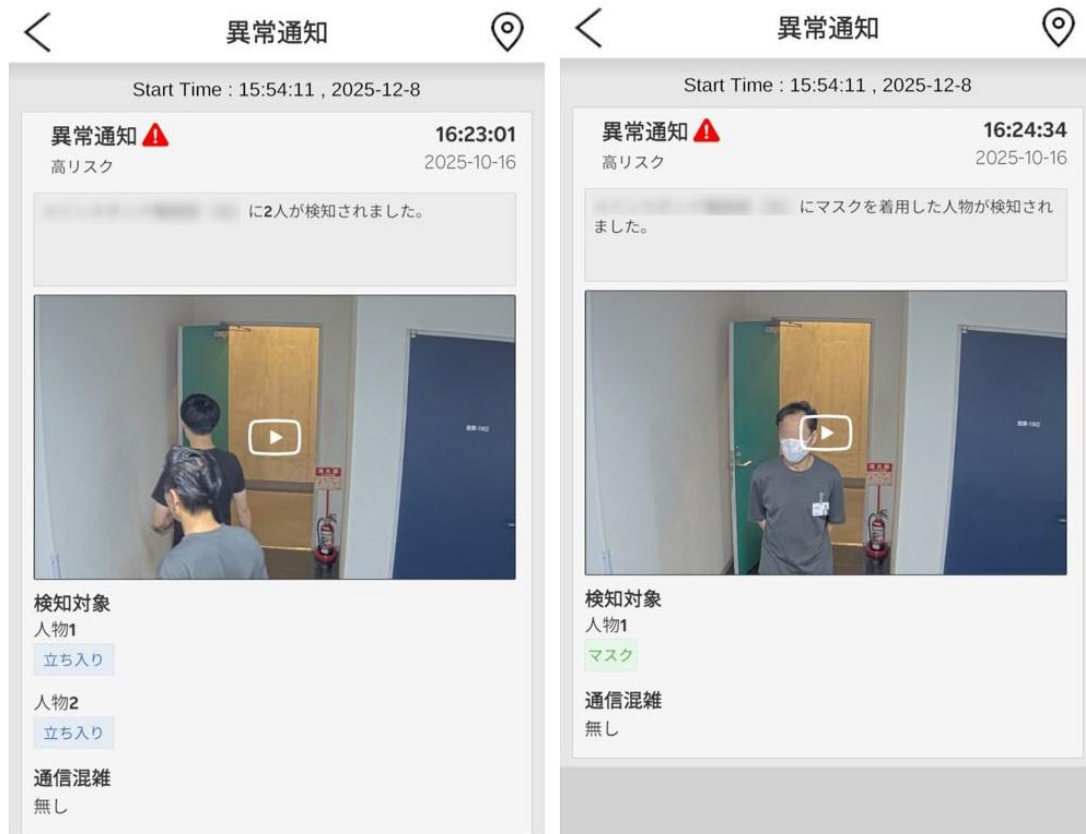


図 6.2-16 左：高リスク(2人以上)、右：高リスク(1人、マスクあり)




図 6.2-17 左：高リスク（1人、10歳未満）、右：高リスク（1人、70歳以上）



図 6.2-18 高リスク（炎・煙）

すべてのイベント種別は、要約レポートの内容によらず、リスクレベルと検知対象ラベルの表示により見分けることが可能である。

- KPI ログ

- プッシュ通知クリック、通知一覧画面の通知クリック、映像再生ボタンクリックのタイミングで、ユーザアクションイベントログを Web API(POST /kpi_log)に送信する。

2) スマートグラスアプリ詳細仕様

- 全体システム
 - スマートグラスのアプリケーションの全体構成図を以下に示す。

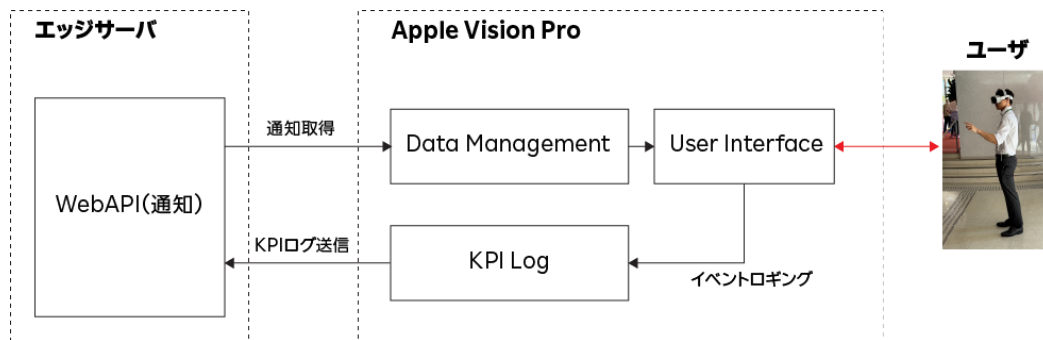


図 6.2-19 Apple Vision Pro 開発構成図

- 通知呼び出し
 - 0.5s~1s ごとに定期的に図 6.2-19 の Data Management が Web API(GET /notifications)を呼び出して通知の一覧を受信する。
- コンテンツ表示
 - 受信した通知一覧を実空間にオーバーレイして UI を Augmented Reality(拡張現実)に表示する。
- KPI ログ
 - ユーザが UI に表示された通知の UI コンポーネントまたは映像をクリックした際、ユーザアクションイベントのログを Web API(POST /kpi_log)に送信する。
- User Interface
 - スマートグラスのアプリケーションの UI は以下図 6.2-20 スマートグラスアプリケーションの UI に示す。
- 通知
 - 図 6.2-20 の左側の赤い点線の箇所に定期、異常、日次の通知の一覧と通知のサマリーを表示する。
- 詳細の通知
 - スマホアプリ UI 仕様と同じように通知をクリックすると検知されたりスクイイベントの詳細内容が表示される。
- スタジアムの 3D View
 - 通知がスタジアムのどのカメラ設置場所から発生するか参照するため、3D マップを AR に再現する。
- スタジアムの 2D マップ
 - 3D ではなく平面の 2D マップも表示する。

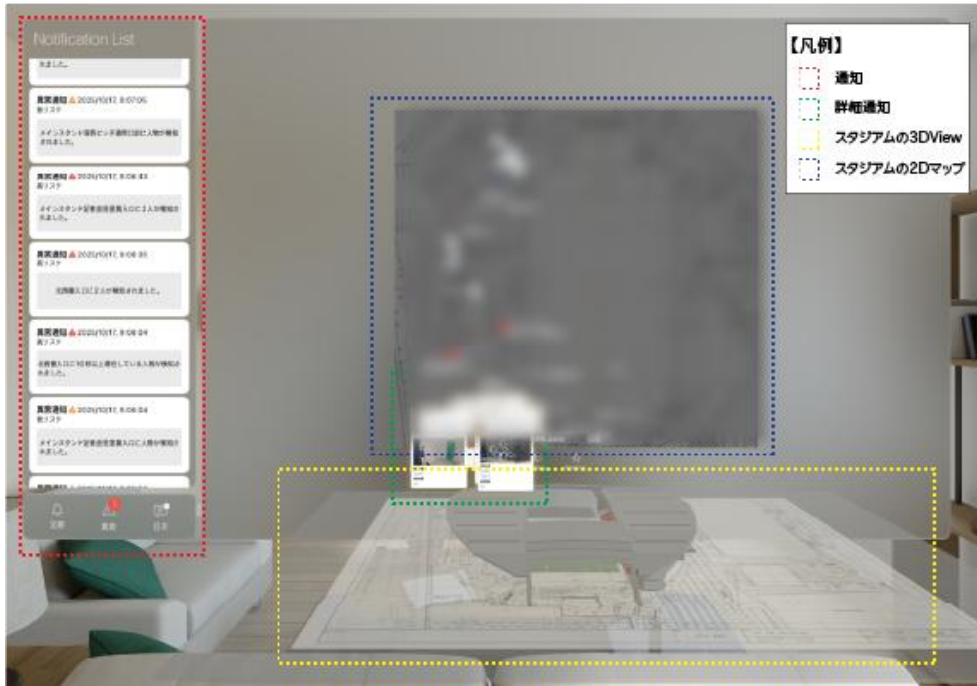


図 6.2-20 スマートグラスアプリケーションの UI

- 実施計画書と本検証の仕様差分
 - 映像再生不可
 - 課題:スマートグラスの開発において、SwiftUI VisionOS 環境はいまだに多くのビデオコーデックに対応していない状況にある。本検証ではファーエッジはMKV形式で映像クリップを生成し、エッジサーバにもMKV形式で保存しているが、SwiftUIはMKVに対応していない。
 - 変更点:ローカルのダミーの映像クリップを再生する。
 - FCM プッシュ通知の受信に対応していない
 - プッシュ通知は、警備担当者がスマートフォンアプリを常時表示していなくとも、ロック画面への通知表示でイベント発生に気付けるようにするために、企画段階に設計した。しかし、スマートグラスにはスマートフォンとは異なり、ロック画面がなくアプリは常時起動しているため、またスマートグラスは常時着用が前提であるため、AR空間に到着通知が表示されれば、それがプッシュ通知として機能し、ユーザはイベント発生に気づくことができる。

(7) ファーエッジ上 AI パイプラインの精度評価(中間)

1) 検証概要

- 試験日程 : 2025/8/12、8/15
- 試験対象のカメラ : 明るい照明条件下での単一カメラ構成を使用
- 評価対象: スタジアムの事前録画映像および公開テストデータセットを使用した制御環境下の試験

- 評価対象イベント種別:侵入、マスク、侵入(2人超)、火・煙、子ども・高齢者検出

2) 評価結果まとめ

以下に中間評価結果についてのまとめを記す。

表 6.2-4 中間評価結果まとめ

検知項目	サンプル数	正解率	誤検知率(False Positive)	未検知率(False Negative)
人物検知	214	99%	0%	1%
リスク判定(低)	107	100%	0%	0%
リスク判定(高)	346	40%	30%	30%
火災・煙検知	52	94%	6%	0%
マスク検知	123	23%	4%	73%
年齢推定	64	11%	0%	89%
行方不明者推定(子ども)	40	16%	0%	84%
行方不明者推定(高齢者)	24	4%	0%	96%
群衆検知(2人)	107	99%	0%	1%

(8) ファーエッジ上 AI パイプラインの精度評価(実証)

本項では、2)～7)において 5.1.5「開発目・評価項目」の(8)「ファーエッジ上 AI パイプラインの精度評価(実証)」の「d. 測定項目」に定義した、すべての測定項目について記載する。最後に 8)において、本評価のまとめと、中間評価との比較結果について記載する。

1) 検証概要

- 試験日程：2025/10/16(木)、10/17(金)
 - 10/16(木)：1人かつ10歳未満、1人かつ70歳以上以外の試験を実施する。
 - 10/17(金)：16:15-17:30(試合前)に、1人かつ10歳未満、1人かつ70歳以上の試験のみを実施する(試合前に募ったボランティアにロールプレイをしてもらう)。
- 試験対象のカメラ：多様な照明条件を網羅するため、10台すべてを使用する。
- 評価対象：ロールプレイ以外の、たまたまスタジアムスタッフなどがカメラに映り込んだことにより発生したイベントは評価対象外とする。
- 評価対象イベント種別：全種別(1人かつ10秒未満、2人以上、1人かつ10秒以上、1人かつマスクあり、1人かつ10歳未満、1人かつ70歳以上、炎・煙)
- 「2人以上」イベントについては、2人一組でロールプレイを行う。

2) 検知機能ごとの評価結果概要

以下に各検知機能の、最終評価結果の概要を記載する。

a. 侵入検知

短時間および長時間の侵入イベントの両方において安定した信頼性の高い性能を示した(正解率は短時間 100%、長時間 98%)。高い精度は、人物検知の基盤技術がスタジアム環境に適合しており、照明や動きの変化にわたって一貫した性能を維持できることを示している。

b. 群衆(二人)検知

二人検知も良好な結果を示し、80 件中、未検知は 1 件、誤検知は 2 件のみ、正解率は 96%であった。人物間の偶発的な重なりが誤分類の一因となったが、全体的な安定性は高い水準を維持した。

c. マスク検知

全ケースで 15%、最低限の画像品質を満たすケースで 40%と正解率が低かった。誤検知の多さは、照明変化・顔の部分遮蔽・被写体の頭部角度といった環境要因にモデルが敏感であることを示している。これらの要因により、同一ロールプレイ者でも複数回の試験で不一致が生じた。

d. 火災・煙検知

中間評価において正解率は 94%であったが、最終評価においては 58%にとどまり、中程度の信頼性を示した。ノートPCに表示した模擬火・煙には、画面反射や動きの現実性低下など、実際の火災では見られない視覚的アーティファクトが存在した。これらの特性が未検知や複数の誤検知を引き起こした。

e. 迷子推定(子どもと高齢者の分類)

正解率は子供で 13%、高齢者で 8%にとどまり、全モデル中で最も精度が低かった。広角カメラ映像では頭部の矩形領域に詳細情報が乏しく、年齢に関連する特徴を識別するのが困難であった。訓練データと実際ロールプレイ間の、動作パターンの差異、照明条件、実在人物の多様性が頻繁な誤分類の原因となった。広範なシナリオに対応するため、モデルの訓練は AWL の内部データセットと公開データセットを使用した。ノエビアスタジアム神戸に特有のロールプレイ者の動きや環境条件は訓練データに含まれていなかった。

なお、ファーエッジ端末からのテレメトリ生成および送信は安定していた。受信した映像品質の低下に起因して推論に失敗したケースを除き、有効な検出のすべてにおいてテレメトリ生成に成功した。

3) 侵入検知(10 秒未満/10 秒以上)

a. 正解率

- 侵入 <10 秒
 - 正解率:100%(80/80 サンプル)
 - 短時間の侵入はすべて正しく検知され、低リスクとして分類された。
- 侵入 ≥10 秒
 - 正解率:98%(約 78/80 サンプル)
 - 長時間の侵入は高い信頼性で検知され、一部に軽微な誤分類が見られた。

b. 未検知/偽陰性

- <10 秒:0%

- 未検知事例は確認されなかった。
- ≥ 10 秒:3%
 - 一部の有効な長時間侵入が検知されなかった、またはテレメトリへのエスカレーションが行われなかった。

c. 誤検知／偽陽性

- < 10 秒:0%
 - 誤った侵入アラートや、 ≥ 10 秒への誤エスカレーションは発生しなかった。
- ≥ 10 秒:0%(テレメトリ発報レベル)
 - 非侵入シーンにおいて侵入テレメトリが生成された事例は確認されなかった。
 - 観測された誤りの大半は誤検知ではなく、未検知に起因するものであった。
- 検知タイプの誤分類(低リスク／高リスク)
 - ≥ 10 秒の侵入が正しく高リスクへエスカレーションされなかったケースが限定的に発生し、これが正解率 2~3%の差分要因となった。

d. テレメトリ生成および伝送の信頼性

- 侵入検知イベントに関するテレメトリは、平均約 125 ミリ秒のエンドツーエンド遅延で生成・送信された。
- エッジデバイスからエッジサーバへの伝送において、テレメトリの欠損は確認されなかった。
- 報告条件を満たしたすべての侵入イベント(< 10 秒および ≥ 10 秒)は正常に配信・記録され、安定したネットワーク挙動と高いテレメトリ処理信頼性が確認された。

e. 総括

侵入検知は高い信頼性を示し、 < 10 秒のイベントでは 100%、 ≥ 10 秒のイベントでは 98%の正解率を達成した。誤りは主に滞在時間に基づくエスカレーションに関連する軽微な未検知に限定されていた。テレメトリは平均約 125 ミリ秒の遅延で安定して生成・伝送され、データ損失も確認されなかったことから、リアルタイム運用における安定性が実証された。

4) 群衆検知

a. 正解率

- 全 80 サンプルに対する全体の正解率は 96%であり、複数人シナリオを高い信頼性で識別できていることが確認された。

b. 未検知／偽陰性

- 群集イベントの 3%が報告されなかった。主な要因は、人物同士の重なりや近接配置により人数が過小カウントされたケースであった。

c. 誤検知／偽陽性

- 2%の誤検知が確認され、2人未満であったにもかかわらず群集イベントとしてテレメトリが報告された事例があった。

d. テレメトリ生成および伝送の信頼性

- テレメトリは平均約125ミリ秒の遅延で生成・送信された。
- エッジデバイスからエッジサーバ間において、テレメトリの欠損は確認されなかった。

e. 総括

群集検知は、高い正解率と低い誤検知率・未検知率を達成した。人物が重なった条件下で軽微な誤りが発生したものの、テレメトリ性能は安定しており、低遅延での動作が確認された。

5) マスク検知

マスク検知のロールプレイは80回実施されたが、その内以下の条件(5.1.6「KPI/KGI」 - (5)「AIパイプラインによる検出の精度」- 3)「KPI項目詳細」 - b.「マスク検知」参照)を満たしているケースは30件だった。

顔や頭部の特徴が以下に示す最低品質(照明、サイズ、角度)を満たす

- 照明:照度レベル1 - 明るい日光またはスタジアムの屋内照明下
- サイズ:識別対象者が入力動画フレームの20%以上を占めること
- 角度:人物の顔がカメラレンズに対して ± 40 度、ピッチ ± 35 度、ロール ± 30 度以内であること

a. 正解率

- マスク検出の正解率は低く、全80サンプルで15%、最低限の画像品質を満たす30サンプルについて40%の正解率にとどまった。
- パフォーマンスにはばらつきがあり、他の検出カテゴリを大幅に下回る結果となった。

b. 未検知／偽陰性(マスク未検出率)

- 高い偽陰性率が観察された。
 - 30サンプル:57%
 - 全80サンプル:76%
- 多くの場合、マスクを着用しているロールプレイヤーが「マスク着用」と正しく分類されなかった。

c. 誤検知／偽陽性(マスク誤検出率)

- 偽陽性率は比較的低い水準を維持した。
 - 30サンプル:3%
 - 全80サンプル:9%

- マスク非着用者を誤って「着用」と識別するケースは限定的だった。
- 誤分類事象 (Incorrect Classification Events)
 - 以下の要因により、頻繁な誤分類が発生した：
 - マスクの形状および着用位置の多様性
 - 顔の角度、部分的な遮蔽(オクルージョン)、およびカメラからの距離
 - 連続するフレーム間で、マスクの状態予測が断続的かつ不安定になる現象が観察された。

d. テレメトリ生成および送信の信頼性

- マスク検出のテレメトリは、平均約 125 ミリ秒のレイテンシで生成・送信された。
- エッジデバイスとエッジサーバ間でのテレメトリ損失は確認されなかった。

e. 総括

マスク検出のパフォーマンスは、高い偽陰性率と不安定な分類挙動が特徴であり、他の検出カテゴリよりも著しく低い結果となった。一方で、テレメトリ送信の信頼性は高く、低レイテンシが維持された。

6) 火災・煙検知

a. 正解率

- 火・煙の検知は、5 つの定義済み動画(計 50 サンプル)において、58%の総合正解率を達成した。
- 動画によってパフォーマンスにばらつきが見られ、シミュレーションされた火や煙の視覚的特徴、およびシーンのリアリティに対する感度が示された。

b. 未検知／偽陰性

- 6%のケースで偽陰性が発生した。これはテストパターン内に火災や煙が存在したものの、検知が行われずテレメトリも生成されなかったケースである。
- 未検知は、主に低コントラストまたは視覚的に微細な煙のシナリオで観察された。

c. 誤検知／偽陽性

- 36%という比較的高い偽陽性率が観察された。
- 誤検知は、火災や煙に似た視覚的パターン(例:照明のアーティファクトや反射)が検知を誘発した場合、あるいは意図した評価期間外で検知が発生した場合に起こった。

d. テレメトリ生成および送信の信頼性

- 火災および煙の検知テレメトリは、平均約 125 ミリ秒のレイテンシで生成・送信された。
- エッジデバイスとエッジサーバ間でのテレメトリ損失は確認されなかった。

e. 総括

火災および煙の検知は、未検知率は低いものの、精度は中程度であり、偽陽性率が高い結果となった。これは、火災以外の視覚的アーティファクトに対する感度が高いことを示している。テレメトリの配信は安定しており低レイテンシであったが、検知精度の向上および誤検知の削減には、追加のドメイン固有トレーニングと閾値のチューニングが必要である。

7) 子ども・高齢者検知

子ども・高齢者検知のロールプレイはそれぞれ 40 回、24 回実施されたが、すべてのケースについて以下の条件(5.1.6 「KPI/KGI」 - (5)「AI パイプラインによる検出の精度」- 3)「KPI 項目詳細」 - d.「年齢推定」参照)を満たしていた。

- 照明:照度レベル 2 - 薄暗い照明または室内照明
- サイズ:識別対象者が入力動画フレームの 15%以上を占めること
- 角度:人物の顔がカメラレンズに対してヨー±40 度、ピッチ±35 度、ロール±30 度以内であること

a. 正解率

- 子ども(10 歳未満): 40 サンプルにおいて 13%の精度。
- 高齢者(70 歳以上): 24 サンプルにおいて 8%の精度。
- 年齢に基づく迷子推定の総合的な正解率は低く、年齢層の分類の信頼性が低いことが示された。

b. 偽陰性

- 子ども(10 歳未満): 子どもの 70%が誤って成人と分類され、迷子事象として報告(エスカレーション)されなかった。
- 高齢者(70 歳以上): 高齢者の 92%が誤って成人と分類され、その結果、迷子の未検知が発生した。

c. 偽陽性

- 子ども(10 歳未満): 17%の偽陽性が発生。成人が誤って子どもとして分類されたケースである。
- 高齢者(70 歳以上): 偽陽性率は 0%。成人が誤って高齢者として分類されたケースはなかった。

d. テレメトリ生成および送信の信頼性

- 迷子推定のテレメトリは、平均約 125 ミリ秒の遅延(レイテンシ)で生成・送信された。
- エッジデバイスとエッジサーバ間でのテレメトリ損失は確認されなかった。

e. 総括

子ども・高齢者検知の正解率は非常に低く、その主な要因は子どもと高齢者の両方における高い偽

陰性率にある。偽陽性は限定的(特に高齢者において)であったものの、現在の年齢推定能力は信頼性の高い迷子検知を行うには不十分である。テレメトリのパフォーマンスは安定しており、低遅延かつ損失なしで運用されていることから、主な課題はシステム構成ではなくモデルの性能に起因することが確認された。

なお、5.1.5「開発目・評価項目」の「(8)ファーエッジ上 AIパイプラインの精度評価(実証)」に記載したとおり、ロールプレイヤーは8方向からカメラ視界内に侵入する。この時、侵入方向④-⑥では、ロールプレイヤーは常にカメラに背を向けている。本年度使用した年齢推定モデルは、頭部・顔の特徴を使用して判定するAIであるため、そのような侵入方向の場合、子ども、高齢者の検出は100%失敗した(偽陰性となった)。

8) 中間評価と最終評価の比較

下表に最終評価の結果(正解率・誤検知率・未検知率)について、イベント種別ごとに記す。中間評価の結果については表 6.2-4 中間評価結果まとめを参照。

表 6.2-5 最終評価まとめ

検知項目	サンプル数	正解率	誤検知率(False Positive)	未検知率(False Negative)
立ち入り 10 秒未満	80	100%	0%	0%
立ち入り 10 秒以上	80	98%	0%	3%
2 人	80	96%	2%	3%
炎・煙	50	58%	36%	6%
立ち入り 10 歳未満	40	13%	17%	70%
立ち入り 70 歳以上	24	8%	0%	92%
マスク着用	30	40%	3%	57%

本節では、中間レビューで得られた中間評価結果と、プロジェクト終了時に生成された最終結果との比較をまとめる。この比較により、AIの精度の差異を浮き彫りにし、性能変化に寄与した要因を特定し、最終結果が提案アーキテクチャの拡張性と運用上の実現可能性をどのように反映しているかを明らかにする。

表 6.2-6 中間評価と最終評価の比較

評価項目	中間評価結果	最終評価結果	比較結果の解釈
侵入検知(リアルタイム)	≈95-97%の正解率	約 99%の正解率	検出精度は、人物検出に関するモデルパラメータの調整および群集(2人以上)シナリオ評価のためのルール設計を含む、閾値調整とモデルの安定化によって向上した。
マスク検出(リアルタイム)	≈23%の正解率	約 15%の正解率(最低限の品質を満たすサンプルに限定すると 40%)	軽量モデルの表現力不足により、マスク形状差・着用位置・顔角度への対応が不十分であった。加えて、実環境を反映した学習データ不足により汎化性能が低下し、上流の人物/顔検出誤差がマスク判定に連鎖した。
行方不明の子ども・高齢者向け年齢推定(リアルタイム)	約 11%の正解率	約 10%の正解率	一貫して精度は低かった。
リスク評価(ロジック層)	約 90%の正しい分類	約 90%の正しい分類	安定。ただし上流の検出精度に強く依存。
火災・煙検知(リアルタイム)	94%の正解率(シミュレーション環境)	約 58%の正解率(シミュレーション)	中間評価では高い性能を示していたものの、スタジアム環境課下では精度が低下しており、環境条件の変動に対する

	境)	環境)	感度が高いことが示された。
群集検知	99%の正解率	96%の正解率	管理された中間評価テストと比較して、精度がわずかに低下した。
オフライン処理の遅延	約 50～500 ミリ秒	約 50～500 ミリ秒	安定かつ予測可能。許容範囲内。

(9) エッジサーバ上 AI 異常レポート要約エージェント(SLM)の精度評価

本節では、エッジサーバ上で稼働する SLM(Rakuten AI 2.0 Mini Instruct)を用いた AI 異常レポート要約エージェントの出力精度評価について述べる。まず、当該モデルの汎用性能評価を概説し、次に、プロンプトエンジニアリングを中心に設計したエージェントの実証運用で得られた結果を評価する。評価の詳細は、主な評価指標、正解要約の定義、エラー分析を含め、以下の各項目に記載する。最後に、本番では検証できなかった予備手法(ファインチューニング)のオフラインテスト結果を示す。

1) 検証概要

- 試験日程：2025/10/16(木)、10/17(金)
- 評価対象：
 - 異常通知：(8)ファーエッジ上 AI パイプラインの精度評価(実証)評価、(10)ファーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価の全ロールプレイ
 - 定期通知：試験期間中に生成された全定期通知
- 評価対象イベント種別：全種別(1人かつ10秒未満、2人以上、1人かつ10秒以上、1人かつマスクあり、1人かつ10歳未満、1人かつ70歳以上、炎・煙)

2) 評価指標について

a. Rakuten Mini 2.0 Instruction の評価指標

現在 LLM²³の評価指標について、LLM の評価プロセスはさまざまな方法があるが、別の LLM により LLM の応答を自動評価する手法、「LLM-as-a-Judge」が広く使われている。これはモデルの汎用性能を測定し、他モデルとの比較を可能にする。本実証で採用した Rakuten AI 2.0 Mini Instruction は既存ソリューションであり、日本語 LLM を対象とした MT-Bench(LLM-as-a-Judge)により評価済みで、複数のインストラクションチューニング済み日本語対応 LLM と比較されている。

²³ 本実証で用いる SLM(小規模言語モデル)は LLM(大規模言語モデル)とは名称が異なるが、多くのオープン LLM で同じく、Transformer アーキテクチャで学習された言語モデルであり、動作原理は他の LLM と共通している。モデルサイズ・パラメータ数が一般的な LLM より小さく軽量化されているため、SLM と呼称している。本報告の文章に SLM と LLM を共に使用し、比較する場合がある。(参考資料:LLM の選び方-パラメータ数と性能から考える:<https://zenn.dev/hellorusk/books/e56548029b391f/viewer/intro5>)

表 6.2-7 MT-Bench で Rakuten 2.0 mini instruction の性能を他の日本語のオープン LLM と比較
(評価結果は公式サイトから引用したもの)

インストラクションモデル	サイズ	日本語 MT-Bench スコア
llm-jp/llm-jp-3-3.7b-instruct	3.7B	4.98
Rakuten/RakutenAI-2.0-mini-instruct	1.5B	4.91
llm-jp/llm-jp-3-1.8b-instruct	1.8B	4.70
SakanaAI/EvoLLM-JP-v1-7B	7B	4.58
SakanaAI/EvoLLM-JP-A-v1-7B	7B	3.80

b. AI 異常レポート要約エージェントの評価指標

上記は SLM の汎用性能に関する評価結果であるが、本ユースケースの運用に合わせてデータ整形プロセスやフィードバックループなどの手法を導入し、実証用に異常レポートに特化した要約 AI エージェントとして実装した。このため、本ユースケースでは汎用的な評価指標ではなく、要約タスクにおける「出力の正確性」を主指標として用いる。

出力の正確性の定義は次のとおりである。異常レポートを正確かつ簡潔にユーザに伝達するため、システムプロンプトに厳密なルールを定め、期待される正解レポートを事前に明確化している。すなわち、システムプロンプトが求める要約を正解 (Ground Truth) とし、これと一致しない出力は不正解と判定する。なお、システムプロンプトの基本要約ルールでは、入力映像メタデータ (JSON 形式) の属性に基づき、対応する定型文を生成するよう規定している。本実証におけるシステムプロンプトの要約タスクは、主に 2 種類に分類される。一つは異常レポートの要約、もうひとつは 15 分ごとの定期レポートの要約、以下に、これら 2 種類のレポートについて説明する。

- 異常レポートの要約ルールと出力例:

ファーエッジで異常イベントを検知すると、AI 異常レポート要約エージェントが直ちに映像メタデータを取得して処理する。要約は主に「場所」と「異常の検知内容」で構成される。検知内容は、異常タイプ (type) とその詳細 (mask、detection_count など) を組み合わせ、対応する異常要約文へ変換する。以下に入力と出力の例を示す。

表 6.2-8 異常レポート正解の要約例

入力映像メタデータ(JSON形式)	正解の要約
<pre>{ "location_id": "area_8", "type": "single_person", "details": {"mask": true} }</pre>	<p><u>エリア 8</u> に <u>マスクを着用した人物</u> が検知されました。</p> <p>↕ ↕</p> <p>area_8 single_person & mask=true</p>
<pre>{ "location_id": "area_5", "type": "multi_person", "detection_count": 3 }</pre>	<p><u>エリア 5</u> に <u>3人</u> が検知されました。</p> <p>↕ ↘</p> <p>area_5 multi_person & detection_count=3</p>
<pre>{ "location_id": "area_3", "type": "single_person", "details": {} }</pre>	<p><u>エリア 3</u> に <u>1人</u> が検知されました。</p> <p>↗ ↕</p> <p>area_3 single_person & details=None</p>

- 定期レポートの要約ルールと出力例:

15分ごとに、Web API は異常イベントが発生していない場所の情報を収集し、AI 異常レポート要約エージェントにする。エージェントは、すべての異常なしエリアを報告する。要約ルールは異常レポートと同様に、JSON データの属性に基づいて要約文を生成する。本タスクは「場所」情報のみを扱うため、変換ルールはシンプルである。以下にと出力の例を示す。

表 6.2-9 定期レポート正解の要約例

入力映像メタデータ(JSON形式)	正解の要約
<pre>{ "location_id": "area_1, area_2, area_6, area_8" }</pre>	<p><u>エリア 1, 2, 6, 8</u>: 異常はありません。</p> <p>↕</p> <p>area_1, area_2, area_6, area_8</p>

以上では、システムプロンプトにおける出力ルールと正解例を用いて、データが所定の要約文へと変換されることを示した。したがって、本実証ではシステムプロンプトで定めたルールに従って生成された要約文を評価用の正解データ(Ground Truth)として用いる。

- 失敗例の分類と出力例:

次の表はいくつかの失敗例を示す。そしてなぜ失敗したかをさらに分類する。本ユースケースにおいて、SLM で発生しうる不正確な要約の種類は主に下の通り:

- 幻覚(ハルシネーション): JSON データにない情報または間違えた情報を生成した。
- 数値の誤り: detection_count(人数) のような数値が間違っている。
- 要素の欠落: 必要な情報が要約から抜け落ちている。
- フォーマットの逸脱: 要約が一文ではない、余計な記号が含まれるなど。
- 表現の不一致: 情報は合っているが、表現が正解と異なる(例: 「長時間滞在」と「10 秒

以上滞在)」

表 6.2-10 失敗例とその分類の表

入力映像メタデータ(JSON 形式)	不正確なレポート	エラータイプ	備考
{ "location_id": "area_8", "type": "single_person", "details": {"mask": true} }	エリア 8 に 10 歳未満と見られる人物が検知されました。	幻覚	入力データの mask を child と誤解し、不正確な情報を生成した
{ "location_id": "area_1, area_2, area_6, area_8" }	エリア 1, 2, 6, 7:異常はありません。	数値の誤り	エリア ID の数値が違う (正解はエリア 1, 2, 6, 8)
{ "location_id": "area_2", "type": "fire" }	エリア 2 に炎が検知されました。	要素の欠落	fire に対し、プロンプト内は「煙・炎」の出力を要求したが、「炎」のみ生成した
{ "location_id": "area_4, area_5, area_9, area_10" }	{"location_id": "area_4, area_5, area_9, area_10", "異常はありません。"}	フォーマットの逸脱	想定外のフォーマットで出力された
{ "location_id": "area_1", "type": "single_person", "details": {} }	エリア 8 に 1 人が検知されました。	表現の不一致	プロンプトのルールだと、「人物が検知されました」を出力すべきが、「1 人」の表現になった

3) AI 異常レポート要約エージェントの評価結果 (プロンプトエンジニアリング手法)

a. 厳密な文字列マッチングによる評価²⁴

本実証では、次の 3 種類の評価結果を提示する。ひとつは異常レポートの要約、もうひとつは 15 分ごとの定期レポートの要約、そして両者を統合した総合結果である。要約結果は 2 段階でデータログに保存しており、第 1 段階は入力データの整形のみを行った初回出力、第 2 段階はフィードバック手法を適用した最終出力である。前述のとおり、本ユースケースは定型文を前提とするため、定量評価は厳密な文字列一致 (Exact Match Accuracy) で実施し、評価用正解データと完全に一致した出力を正解とする。各評価セットの正解率を以下のテーブルに示す。

表 6.2-11 本実証における異常レポート要約の結果

	SLM 最初の要約 (入力データ整形のみ)	SLM 最終の要約 (フィードバックループあり)
不正確な要約数	232	2
全部の要約数	419 ²⁵	419
要約の正確率 (完全に一致した回答数 / 全回答数) * 100%	44.60%	99.50%

²⁴ LLM 評価方法の参考資料: ①LLM evaluation metrics: A comprehensive guide for large language models, ②LLM Evaluation Metrics: The Ultimate LLM Evaluation Guide

²⁵ 本実証実験における異常通知は計 434 件であったが、このうち 15 件の要約結果は不具合対応中に発生したシステムエラーに起因するため評価対象から除外し、評価対象の異常レポートは 419 件となった。

表 6.2-12 本実証における定期レポート要約の結果

	SLM 最初の要約 (入力データ整形のみ)	SLM 最終の要約 (フィードバックループあり)
不正確な要約数	2	2
全部の要約数	22	22
要約の正確率 (完全に一致した回答数 / 全回答数) * 100%	90.90%	90.90%

	SLM 最初の要約 (入力データ整形のみ)	SLM 最終の要約 (フィードバックループあり)
不正確な要約数	234	4
全部の要約数	441	441
要約の正確率 (完全に一致した回答数 / 全回答数) * 100%	46.94%	99.09%

表 6.2-13 本実証における異常レポートおよび定期レポートの総合要約結果

以下では、定期レポートおよび異常レポートの不正確な要約をすべて統合し、分類結果を示す。

表 6.2-14 不正確な要約をエラータイプ別での分類(初回出力と最終出力を区別して提示する)

SLM 出力段階	エラータイプ	幻覚	数値の誤り	要素の欠落	フォーマットの逸脱	表現の不一致	合計
SLM 最初に不正解な要約 (入力データ整形のみ)		125	0	12	2	95	234
SLM 最終に不正解な要約 (フィードバックループあり)		2	0	0	2	0	4

次に、各エラー種別の割合を円グラフで示す。初回出力(入力データ整形+基本システムプロンプト)で不正解が多かったため、この段階のエラー分類のみを提示する。




図 6.2-21 初回出力における要約エージェントのエラー種別分布

以上は、厳格な基準に基づく要約の正誤判定結果である。誤りと判定された出力は、システムプロンプトで定義したルールに違反していることを意味する。フィードバックループを導入した結果、厳格なチェックでも正確率は 99%を達成した。一方、基本システムプロンプトのみでは正確率は 47%にとどまった。次項目の評価については、判定基準をやや緩和し、実運用上支障がなく、かつ異常イベントの事実関係が正確である出力も正解に含める。

b. 事実の正確性による評価

前述のエラー種別のうち「表現の不一致」と「要素の欠落」については、正解例と表現が異なっているも、ユーザの判断・対応に必要な重要情報が適切に伝わっている場合は正解とみなす。例を以下に示す。

表 6.2-15 厳密な文字列マッチングでは誤判定となるが、事実は正しい要約例

実際に出力した要約	正解の要約	説明
エリア 2 に人物が検知されました。	エリア 2 に 1 人 が検知されました。	語彙は異なるが、同一の意味内容が伝達されている。
エリア 3 に煙・炎が検知されました。	エリア 3 に 炎 が検知されました。	期待要素の一部が欠落しているが、重要なキーワード(炎)が伝わっており、ユーザの判断に支障がない範囲として許容する。

表 6.2-16 事実の正確性に基づく総合要約の評価結果

	SLM 最初の要約 (入力データ整形のみ)	SLM 最終の要約 (フィードバックループあり)
不正確な要約数	127	4
全部の要約数	441	441
要約の正確率 (完全に一致した回答数 / 全回答数) * 100%	71.2%	99.09%

許容範囲を満たす要約は相当数に上り、これらを正解として扱うと、SLM の初期精度は 46.9% から 71.2% へと向上する。一方、残る約 29% の不正解要約には、ほとんど幻覚(ハルシネーション)による誤情報が含まれている。

以上は、本ユースケースにおいてプロンプトエンジニアリングのみを用いて得られた AI 異常レポート要約エージェントの精度評価結果である。基本のシステムプロンプトのみでは精度の一貫性を確保できなかったが、フィードバックループの導入により正答率は 99% を達成した。

4) AI 異常レポート要約エージェントの評価結果-2 (ファインチューニング手法)

4 章で言及したファインチューニング手法については、実証実験内での検証は行わなかったものの、実証環境と同一のエッジサーバを用いたオフラインテストを実施した。本項ではその結果について概説する。

本評価には、実証実験で扱った全種類の異常検知イベント(10 秒以上の立ち入り、10 秒以上のマスク着用、複数人検知、火災・煙検知など)および全エリアのバリエーションを網羅したテストデータを使用した。定期レポートに関して、エリア 1 から 10 まで可能な組み合わせが膨大となるため、100 件を抽出してテストを実施した。評価手法としては、出力結果に対する厳密な文字列マッチングを採用している。

表 6.2-17 ファインチューニング手法による要約を厳密な文字列マッチングで評価した結果

	異常レポート要約 (入力データ整形のみ)	定期レポート要約 (入力データ整形のみ)	全部の要約 (異常レポート+定期レポート)
不正解の要約数	2	7	9
全部の要約数	100	100	200 ²⁶
要約の正解率 (完全に一致した回答数 / 全回答数) * 100%	98%	93.0%	95.5%

※不正解となった異常レポート要約:2 件はハルシネーション(幻覚)に起因する誤情報の要約である。

※不正解となった定期レポート要約:7 件はいずれも数値誤りに分類され、集約すべきエリア ID が不一致である。

²⁶ 本テストのデータ数(200 件)は、実証実験のデータ数(441 件)を下回る。実証実験では同一エリアを異なる方向で歩行するテストが多く、同一の異常検知イベントが複数回記録された。その結果、要約内容に差異がなく重複が多発した。今回のオフラインテストでは、重複データを除外し、重複のないデータのみを収録している。

さらに、ファインチューニング手法との精度比較を行うため、実証実験で採用したプロンプトエンジニアリング手法に対しても同一のテストデータを用いた検証を実施した。その結果を以下に示す。

表 6.2-18 プロンプトエンジニアリング手法による要約を厳密な文字列マッチングで評価した結果
(ファインチューニング手法の評価時と同一のテストデータを使用)

	異常レポート要約 (フィードバックループあり)	定期レポート要約 (フィードバックループあり)	全部の要約 (異常レポート+定期レポート)
不正解の要約数	0	8	8
全部の要約数	200	100	200
要約の正解率 (完全に一致した回答数 / 全回答数) * 100%	100%	92.0%	96.0%

※不正解の定期レポート要約: 7 件はフォーマットの逸脱の要約だが、中の数値は全部正解だった。(出力例: {"location_id": "area_1, area_2, area_3, area_6"})

ファインチューニング手法により、フィードバックループを用いず、入力データの整形のみで AI 異常レポート要約エージェントの出力を厳密文字列一致(完全一致)で評価したところ、正解率は 95.5%であった。正解率は 100%には達していないものの、フィードバックループなしのプロンプトエンジニアリング手法の評価結果(96%)と同程度である。従来、フィードバックループ下での定期レポート要約処理で頻発していたフォーマット逸脱は、ファインチューニング済み SLM では発生しなかった。今後、フィードバックループ機能とファインチューニング済み SLM を併用することで、さらなる正解率向上が見込まれる。

5) AI 異常レポート要約エージェントの評価結果に関する考察

「Rakuten Mini 2.0 Instruct」モデルは、日本語ベンチマークの MT-Bench において高い評価を得ており、かつ小規模なパラメータ数によりエッジデバイスでもスムーズに推論処理を実行可能であると考えられたため、本実証で使用する SLM として Rakuten Mini 2.0 Instruction を選定した。

本ユースケースの監視データによる要約タスク運用について、基本のシステムプロンプトと入力データの前処理を行わずに実施したところ、所定の正解要約から逸脱した出力しか得られないことを確認した。一方、入力 JSON データの内容を簡素化した結果、求められる要約フォーマット(場所+検知内容+「検知されました」)に沿った出力が可能になった。この差異から、SLM のデータ解釈や条件分岐・計算の推論において、一般的な LLM(GPT-5, Gemini 等)と同等の推論能力を有していない可能性が示唆される。一方、AI 異常レポート要約エージェントに入力するデータの整形プロセスを導入し、JSON データを可読性の高い形式に変換するとともに、システムプロンプトのルールを簡素化した結果、推論結果は改善された。しかし、この改善手法は実証のテストデータにおいて正解率が 47%にとどまった。

これに対し、フィードバックループを導入し、誤った要約に対して正解情報を含むヒントプロンプトを提示する手法を採用した結果、正解率は 99%まで大幅に向上した。この手法は効果的である反面、すべての想定ケースについて正解情報を事前に定義する必要があり、実装コストが増大するという課題がある。特に今後、要約対象のケースが複雑化した場合、網羅しきれない事象が生じる懸念がある。

上記のようなプロンプトエンジニアリングの限界を踏まえ、当初計画にはなかった追加学習(ファイン

チューニング)についても検証を行った。本番実証では採用しなかったものの、オフラインテストではフィードバックループなしで約 96%の高い要約正確率を達成した。しかし、監視システムにおいて誤った緊急メッセージを送信することは安全性に影響を及ぼすため、限りなく 100%に近い正解率を確保する必要がある。

今後の改善策として、エージェント型 AI の設計パターンに基づくマルチエージェント構成の導入が挙げられる。評価プロセスを別の LLM/SLM サブエージェントに委譲することで、フィードバックループの実装コストを大幅に削減できると見込まれる。加えて、異なるエージェント AI システムの設計パターンの検証や、より高い推論能力を持つ LLM/SLM の採用により、さらなる性能向上が期待できるため、これらを次期の検証項目とする。さらに、今後はより複雑な異常イベントへの対応や要約内容の拡充が想定される。情報の正確性確保に加え、警備員にとってより有益な情報を提供できるよう、要約エージェントの出力設計についても継続的な課題として取り組む必要がある。

(10) ファーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価

10/17 午前(8:18-9:28)にネットワーク混雑なしの場合、午後 18:35-18:43(試合開始前)と 21:06-21:13(試合終了後)にネットワーク混雑ありの場合のデータ削減率の測定を実施した。

以下に結果詳細を記す。

1) 検証概要

(9)エッジサーバ上 AI 異常レポート要約エージェント(SLM)の精度評価の AI 精度検証とほぼ同じ手順で検証を実施する。

- 試験日程：2025/10/17(金)
 - 検証項目(2)「ネットワーク混雑時に中圧縮方式の使用を避けることによるファーエッジ⇒エッジサーバデータ送信削減率」はネットワーク輻輳時に実施する必要があるため、ヴィッセル神戸のホームゲーム開催日である 10/17(金)に実施する。
- 時間帯
 - 検証項目(2)「ネットワーク混雑時に中圧縮方式の使用を避けることによるファーエッジ⇒エッジサーバデータ送信削減率」：試合開始前(17:00-19:00)と試合終了後(21:00-21:30)
 - ネットワーク輻輳が見込まれる試合前・試合後の時間帯に実施する(試合中は、観客は観戦に集中していてスマートフォンを使用しないため、輻輳は発生しにくい傾向がある)。ネットワークが輻輳していない場合は、疑似的に DB 上で輻輳状態を作り出す。
 - それ以外：午前中
- 試験対象のカメラ：
 - (2) ネットワーク混雑時に中圧縮方式の使用を避けることによるファーエッジ⇒エッジサーバデータ送信削減率：2 か所
 - 試験時間帯(試合前、試合後)に、試合準備や撤収作業のための関係者出入り

が多い地点や、選手などが使用するため立ち入り禁止となる地点は避ける。

- それ以外：10 台すべてを使用する。
- 結果確認方法：ロールプレイ後に、エッジサーバ上 MongoDB に記録された受信/送信ログデータからデータ削減率を算出する。
- 評価対象：ロールプレイ以外の、たまたまスタジアムスタッフなどがカメラに映り込んだことにより発生したイベントは集計対象外とする。
- 評価対象イベント種別：1 人かつ 10 秒未満、2 人以上、1 人かつ 10 秒以上、1 人かつマスクあり、炎・煙の 5 種類

2) ファーエッジ上映像圧縮プロセスによるデータ削減率

a. 10/17 午前(8:18-9:28)のデータ削減率(ネットワーク非輻輳状態)

試験時間中(70 分間)に、10 台のカメラから、67 件の高リスクイベントと 100 件の低リスクイベント、16 件の定期報告イベントが発生した。高リスクイベントと低リスクイベントの発生頻度(カメラ 1 台、1 時間当たり 低リスク：8.57 件、高リスク：5.74 件)については、KPI 算出時の仮定(12 件)を下回った。

削減率は、以下に示すように、超高圧縮のみ、高圧縮のみ、中圧縮のみ、合計のすべてにおいて、98.88%以上を達成した。

送信されるはずだったデータ

①	映像送信ビットレート	2.5Mbps	
②	時間(分)	70	
③	時間(秒)	4200	②x60
④	カメラ台数	10	
⑤	本来送信されるはずだったデータ	13,762,560,000Bytes	①x1024x1024/8x③x④

実際に送信されたデータ

		件数	送信サイズ	圧縮率	
	超高圧縮 (JSON)、異常報告	100	107,308Bytes	-	
	超高圧縮 (JSON)、定期報告	16	9,522Bytes	-	
⑥	超高圧縮 (JSON) 合計	116	116,830Bytes	0.999991511	1-(⑥/⑤)
⑦	高圧縮 (画像)	100	12,444,265Bytes	0.999095789	1-(⑦/⑤)
⑧	中圧縮 (映像クリップ)	67	140,906,024Bytes	0.989761641	1-(⑧/⑤)
⑨	合計	283	153,467,119Bytes	0.988848941	1-(⑨/⑤)

※①映像送信ビットレートは、一般的な監視カメラが一般的な映像品質(解像度 1080p (Full HD)、圧縮方法 H.264(Standard)、15FPS)で映像ストリームを送信した場合のビットレートである。

図 6.2-22 10/17 午前のデータ削減率(ネットワーク非輻輳状態)

3) ネットワーク混雑時に中圧縮方式の使用を避けることによるファーエッジ⇒エッジサーバデータ送信削減率(とファーエッジ上映像圧縮プロセスによるデータ削減率)

a. 10/17 午後(18:35-18:43)のデータ削減率(試合開始前、ネットワーク輻輳中)

試験時間中(8 分間)に、2 台のカメラから、12 件の高リスクイベントと 4 件の低リスクイベント、0 件の定期報告イベントが発生した。高リスクイベントと低リスクイベントの発生頻度(カメラ1 台、1 時間当たり 低リスク :15 件、高リスク : 45 件)については、KPI 算出時の仮定(12 件)を上回った。特に高リスクの頻度は仮定の 3.75 倍だった。

ファーエッジ上映像圧縮プロセスによるデータ削減率は、以下に示すように、超高圧縮のみ、高圧縮のみ、(中圧縮のみ、)合計のすべてにおいて、99.6%以上を達成した。

なおネットワーク輻輳時は中圧縮の使用が避けられるので、中圧縮の圧縮率は当然 100%になった。

ネットワーク輻輳時に中圧縮方式の使用を避けることによるデータ削減率は、約 95.43%を達成した。

送信されるはずだったデータ

①	映像送信ビットレート	2.5Mbps	
②	時間(分)	8	
③	時間(秒)	480	②x60
④	カメラ台数	2	
⑤	本来送信されるはずだったデータ	314,572,800Bytes	①x1024x1024/8x③x④

実際に送信されたデータ

		件数	送信サイズ	圧縮率	
	超高圧縮 (JSON)、異常報告	16	17,635Bytes	-	
	超高圧縮 (JSON)、定期報告	0	0Bytes	-	
⑥	超高圧縮 (JSON) 合計	16	17,635Bytes	0.99994394	1-(⑥/⑤)
⑦	高圧縮 (画像)	16	1,225,433Bytes	0.996104453	1-(⑦/⑤)
⑧	中圧縮 (映像クリップ)	0	0Bytes	1	1-(⑧/⑤)
⑨	合計	32	1,243,068Bytes	0.996048393	1-(⑨/⑤)

輻輳時に中圧縮データを使用しないことによる削減率

⑩	動画件数 (高リスクイベント件数)	12	
⑪	平均動画サイズ	2,163,287Bytes	
⑫	非輻輳時に送信されるはずだった動画サイズ合計	25,959,445Bytes	⑪x⑫
⑬	輻輳時に動画を送信しないことによる削減率	0.954303193	1-⑨/(⑨+⑫)

※⑩平均動画サイズは、試験期間中(10/16,10/17)に送信されたすべての映像クリップの平均サイズである

図 6.2-23 10/17 午後 試合開始前のデータ削減率(ネットワーク輻輳状態)

b. 10/17 午後(21:06-21:13)のデータ削減率(試合終了後、ネットワーク輻輳中)

試験時間中(7 分間)に、2 台のカメラから、6 件の高リスクイベントと 2 件の低リスクイベント、0 件の定期報告イベントが発生した。高リスクイベントの発生頻度(カメラ1 台、1 時間当たり 25.71 件)については、KPI 算出時の仮定(12 件)を大幅に上回り(約 2.14 倍)、低リスクイベント(8.57 件)については下回った。

ファーエッジ上映像圧縮プロセスによるデータ削減率は、以下に示すように、超高圧縮のみ、高圧縮のみ、(中圧縮のみ、)合計のすべてにおいて、99.6%以上を達成した。

なおネットワーク輻輳時は中圧縮の使用が避けられるので、中圧縮の圧縮率は当然 100%になった。

ネットワーク輻輳時に中圧縮方式の使用を避けることによるデータ削減率は、約 95.43%を達成した。

送信されるはずだったデータ

①	映像送信ビットレート	2.5Mbps	
②	時間(分)	7	
③	時間(秒)	420	②x60
④	カメラ台数	2	
⑤	本来送信されるはずだったデータ	275,251,200Bytes	①x1024x1024/8x③x④

実際に送信されたデータ

		件数	送信サイズ	圧縮率	
	超高压縮 (JSON)、異常報告	8	8,830Bytes	-	
	超高压縮 (JSON)、定期報告	0	0Bytes	-	
⑥	超高压縮 (JSON) 合計	8	8,830Bytes	0.99996792	1-(⑥/⑤)
⑦	高压縮 (画像)	8	612,047Bytes	0.997776406	1-(⑦/⑤)
⑧	中圧縮 (映像クリップ)	0	0Bytes	1	1-(⑧/⑤)
⑨	合計	16	620,877Bytes	0.997744326	1-(⑨/⑤)

輻輳時に中圧縮データを使用しないことによる削減率

⑩	動画件数 (高リスクイベント件数)	6	
⑪	平均動画サイズ	2,163,287Bytes	
⑫	非輻輳時に送信されるはずだった動画サイズ合計	12,979,723Bytes	⑩x⑫
⑬	輻輳時に動画を送信しないことによる削減率	0.954349292	1-⑨/(⑨+⑫)

図 6.2-24 10/17 午後 試合終了後のデータ削減率(ネットワーク輻輳状態)

4) エッジサーバからエンドユーザへの情報集約によるデータ削減率

a. 集計対象データ

当 KPI は、10/17 午前に、(11)警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定 を実施した際のデータを集計対象とする。理由は、それ以外の期間、またはそれ以外のエンドユーザによる操作の場合、映像ダウンロード率が非常に低くなるためである。以下にその理由を示す。

以下は 5.1.6 「KPI/KGI」の(4)「エッジサーバでの情報集約によるデータ送信削減率」から転載した、KPI 目標値の算出方法を示す図である。

データ項目	値	番号	計算式
カメラ台数	10	①	
定期報告送信回数(回/時間) ※	4	②	
平均画像サイズ(KB)	450	③	
平均映像サイズ(KB)	3500	④	
定期報告テキストサイズ(KB)(仮)	0.5	⑤	
異常報告テキストサイズ(KB)(仮)	2	⑥	
低リスクイベント発生頻度(回/時)(仮)	12	⑦	
高リスクイベント発生頻度(回/時)(仮)	12	⑧	
異常通知テキスト送信時サイズ変化率(仮)	0.5	⑨	
定期通知テキスト送信時サイズ変化率(仮)	0.05	⑩	
映像ダウンロード率(仮)	0.5	⑪	
1時間当たり受信画像サイズ	108000	⑫	③ × (⑦ + ⑧) × ①
1時間当たり受信映像サイズ	420000	⑬	④ × ⑧ × ①
1時間当たり受信テキストサイズ(定期報告)	20	⑭	⑤ × ② × ①
1時間当たり受信テキストサイズ(イベント)	480	⑮	⑥ × (⑦ + ⑧) × ①
1時間当たり受信データサイズ合計	528500	⑯	⑫ + ⑬ + ⑭ + ⑮
1時間当たり送信画像サイズ	108000	⑰	⑫
1時間当たり送信映像サイズ	210000	⑱	⑬ × ⑪
1時間当たり送信テキストサイズ(定期通知)	1	⑲	⑤ × ① × ② × ⑩
1時間当たり送信テキストサイズ(異常通知)	240	⑳	⑮ × ⑨
1時間当たり送信データサイズ合計	318241	㉑	⑰ + ⑱ + ⑲ + ⑳
データ削減率	0.3978		1 - ㉑ / ⑯

※ファーエッジ-エッジサーバー、エッジサーバー-ユーザーアプリケーション共通

図 6.2-25 エッジサーバでのデータ削減率 KPI 目標値の算出方法

上図に記載の⑩映像ダウンロード率(50%、仮定値)を 30%にするとデータ削減率目標値は 55.6%、20%にすると 63.6%と、実施計画書に記載の 39.8%と比較し大きく増加(改善)してしまう。そして今回の検証期間中(10/16-10/17)においては、評価(11)における警備担当者によるアプリ操作中を除けば、映像ダウンロード率は 50%よりも大幅に低くなった。

実運用における警備担当者による映像ダウンロード率については実績データが存在しないが、警備担当者はすべての映像は確認せず、スタジアムスタッフが検知された場合など、不審人物の侵入でないことが(画像の確認で)明らかな場合は映像の再生は行われられないと思われる。その率が半々である(50%)とするのは自然な仮定であると思われる。

よって、評価(11)における警備担当者によるアプリ操作で使用された端末のデータ送受信ログを集計に使用する。また試験中(9:52-10:08)、警備担当者はすべての映像をダウンロードした(ダウンロード率 100%)したため、ダウンロード率が 50%になるように、期間を 9:21-10:08 に広げて集計した。

b. 集計結果

集計期間 47 分間に、10 台のカメラから、22 件の高リスクイベントと 56 件の低リスクイベント、10

件の定期報告イベントが発生した。高リスクイベントと低リスクイベントについては、KPI 算出時の仮定（ともにカメラ1台、1時間当たり12件）よりも発生頻度（低リスク：2.81件、高リスク：7.15件）は低かった。

エッジサーバからエンドユーザへは、イベントサマリ、画像に加え、5件の定期通知が送信された。エンドユーザによる映像ダウンロード率は、前述の通り50%（11件/20件）となるよう期間を調整した。

その結果、エッジサーバからエンドユーザへの情報集約によるデータ削減率は、以下に示すように、39.99%を達成した。

また78件の異常通知JSONと10件の定期通知JSONは、78件の異常通知サマリと5件の定期通知サマリに要約され、これによるデータ削減率は92.85%を達成した。

カメラ台数	10
集計期間(分)	47
高リスクイベント発生件数	11
低リスクイベント発生件数	56
定期通知イベント受信件数	10
受信データサイズ合計	56,165,205Bytes
受信データサイズ合計(テレメトリテキスト)	85,632Bytes
受信データサイズ合計(異常通知テレメトリ)	79,681Bytes
受信データサイズ合計(定期通知テレメトリ)	5,951Bytes
受信データサイズ合計(画像)	10,404,314Bytes
受信データサイズ合計(映像)	45,675,259Bytes
定期通知送信件数	5
送信データサイズ合計	33,705,338Bytes
送信データサイズ合計(サマリテキスト)	6,119Bytes
送信データサイズ合計(異常通知サマリ)	5,375Bytes
送信データサイズ合計(定期通知サマリ)	744Bytes
送信データサイズ合計(画像)	10,790,173Bytes
送信データサイズ合計(映像)	22,909,046Bytes
動画ダウンロード率	0.5
データ削減率	0.399889344
データ削減率(テキスト)	0.928543068

図 6.2-26 エッジサーバからエンドユーザへの情報集約によるデータ削減率

(11) 警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定

1) 検証概要

- 試験日程：2025/10/17(金)
- 結果確認方法：エンドユーザによるアプリ操作後に、エッジサーバ上MongoDBに記録されたユーザ操作ログデータから、イベントに対する反応時間を算出する。
- 評価対象：ロールプレイ以外の、たまたまスタジアムスタッフなどがカメラに映り込んだことにより発生したイベントは集計対象外とする。

- 評価対象イベント種別：1人かつ10秒未満、2人以上、1人かつ10秒以上、1人かつマスクありの4種類

2) 試験結果概要

試験時間中に6回のロールプレイが実施された。2名の警備担当者は、ロールプレイによるイベントを、片方はスマートフォンアプリを、もう片方はスマートグラスアプリを使用して確認した。それぞれのイベントに対する警備担当者のイベントへの反応時間は、自動的にMongoDBに記録された。

なお、試験時間中に、たまたまスタッフ等が映り込んだことによる意図しないイベントも5件発生したが、それについては反応時間測定対象外としている。

イベント種別	イベント発生時間	端末種別	エンドユーザ	通知タップ時間	通知タップまでの時間	映像再生ボタンタップ時間	映像再生までの時間
2人以上	2025/10/17 9:52:40	smartphone	被験者A	2025/10/17 9:52:53	00:13.514	2025/10/17 9:52:56	00:16.812
		smartglasses	被験者B	2025/10/17 9:52:50	00:10.195	2025/10/17 9:52:57	00:17.017
10秒以上	2025/10/17 9:53:11	smartphone	被験者A	2025/10/17 9:53:20	00:08.530	2025/10/17 9:53:22	00:10.614
		smartglasses	被験者B	2025/10/17 9:53:20	00:08.597	2025/10/17 9:53:33	00:21.867
2人以上	2025/10/17 9:56:38	smartphone	被験者B	2025/10/17 9:56:47	00:09.587	2025/10/17 9:56:50	00:12.910
		smartglasses	被験者A	2025/10/17 9:56:43	00:05.494	2025/10/17 9:56:52	00:14.772
マスク	2025/10/17 9:57:17	smartphone	被験者B	2025/10/17 9:57:28	00:11.517	2025/10/17 9:57:31	00:14.638
		smartglasses	被験者A	2025/10/17 9:57:23	00:05.976		
10秒未満	2025/10/17 9:57:53	smartphone	被験者B	2025/10/17 9:58:02	00:08.536		
		smartglasses	被験者A	2025/10/17 9:58:00	00:06.981		
10秒未満	2025/10/17 9:58:45	smartphone	被験者A	2025/10/17 9:59:03	00:17.876		
		smartglasses	被験者B	2025/10/17 9:59:59	01:13.956		

図 6.2-27 反応時間ログ



図 6.2-28 スマートグラスアプリを操作する被験者 A と、スマートフォンアプリを操作する被験者 B

3) 試験結果まとめ

以下に反応時間のまとめを示す。なお、最後のイベントに対する、スマートグラスアプリの通知タップ（被験者 B による）までの時間は、他と比較して大きすぎるため、外れ値として除いてある。

		通知タップまでの時間	映像再生ボタンタップまでの時間	通知タップから映像再生ボタンタップまでの時間
SmartGlasses	平均	00:07.449	00:17.885	00:09.790
	平均-被験者A	00:06.150	00:14.772	00:09.278
	平均-被験者B	00:09.396	00:19.442	00:10.046
Smartphone	平均	00:11.593	00:13.744	00:02.956
	平均-被験者A	00:13.307	00:13.713	00:02.691
	平均-被験者B	00:09.880	00:13.774	00:03.222

図 6.2-29 反応時間ログまとめ

- 通知タップまでの反応時間は、全体平均、被験者ごと平均ともに、スマートグラスの方が短くなった。
- 一方、通知タップ(イベント詳細画面の表示)から映像再生ボタンタップまでの時間は、全体平均、被験者ごと平均ともに、逆にスマートグラスの方が大幅に長くなった。スマートフォンの場合、平均 3 秒程度だったが、スマートグラスの場合平均 10 秒程度かかった。

4) 試験結果考察

a. 通知タップまでの反応時間

スマートグラスアプリの方が短くなった要因については、以下のようなことが考えられる。

1. スマートグラスの常時着用のメリット
スマートグラスは常時着用しているため、スマートフォンとは異なり端末を手を取る必要がないため、通知に早く反応できた可能性がある。
2. スマートフォンアプリに Firebase Cloud Messaging (FCM)メッセージが到達するまでの時間
スマートフォンアプリには、Web API から FCM によりイベント発生が通知され、通知を受信すると、スマートフォンアプリは対応するイベント情報を表示する。FCM がサーバ側で送信されてから端末に届くまでに、ネットワーク状況や FCM サーバの負荷などの要因により変動するが、一般的には数秒から数十秒程度かかる。
一方、スマートグラスアプリは FCM プッシュを使用せずに、0.5~1 秒程度の間隔で定期的に最新のイベント情報を Web API から取得し、表示している。
そのため、イベント情報がアプリに表示されるまでの時間が、スマートグラスの方が短かった可能性がある。
3. スマートフォンアプリのポップアップ通知表示までの時間
スマートフォン(Android)アプリは、フォアグラウンド状態で FCM 通知を受け取った場合、ポップアップ通知をアプリ側で表示する必要がある(バックグラウンド状態の場合、OS の機能により自動的に表示される)。この際、表示時間として 1 秒後など近すぎる時間を指定すると、ユーザに

よるポップアップ通知タップのイベントを正常に処理できない場合がある²⁷ため、表示時間として2秒後を指定している。

そのために、スマートフォンの方がイベント情報表示までの時間が長くなった可能性がある。

b. 通知タップから映像再生ボタンタップまでの時間

スマートグラスアプリの方が大幅に長くなった要因については、以下のようなことが考えられる。

1. スマートグラスのクリック操作の難しさ

本検証の被験者2名は、ともにApple Vision Proの使用経験はなかったため、検証前にApple Vision Proの使用方法についてレクチャーを受け、操作に慣れるための時間(約5分,1回/1人)を設けた。しかしApple Vision ProでUIをクリックするには、まずUIに視線を合わせ、UIがハイライト表示されたら(選択状態になったら)、親指と人差し指を使用して「ピンチ」操作を行う必要がある。これは警備担当者が使い慣れたスマートフォンアプリのタップ操作とは大きく異なるため、これらの操作に慣れるまでには時間を要する。そのため、被験者2名はスムーズにクリック操作が行えなかった可能性がある。

通知タップまでの反応時間がスマートグラスの方が短かったのは、「a 通知タップまでの反応時間」に述べた要因によってスマートフォンアプリにおいて余計にかかった時間が、スマートグラスアプリにおいて通知タップが難しいことにより余計にかかった時間を上回ったと解釈できる。

2. 動画再生ボタンの使い勝手が悪かった

動画再生ボタンに視線を合わせるとハイライト表示される(選択状態になる)が、ボタンが小さく、Apple Vision Proに慣れていない被験者にとってはそれが困難だった可能性がある。

(12) エンドユーザアプリケーションを使用した警備担当者からのフィードバック収集

各評価項目に対するユーザフィードバックと、そこから導かれる主要な考察を以下に示す。

1) 検証概要

- 試験日程：2025/10/17(金)
- タイミング：11)「警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定」の後
- 結果確認方法：警備員に業務を委託する責任者である施設管理部部長を含むヴィッセル神戸従業員2名は、スマートフォン・スマートグラスアプリを使用して、楽天モバイル従業員のロールプレイによるイベントを確認後、アンケートに回答する。

2) アンケート結果一覧

アンケート結果は以下に示すとおりである。

²⁷ ポップアップ通知タップのイベントを正常に処理できない場合：以下の記事の「通知を開いてもGetLastNotificationIntent()がnull」を参照。[https://okamochi-storage.com/2022/05/30/\[unity\]mobilenotificationについてメモ android/](https://okamochi-storage.com/2022/05/30/[unity]mobilenotificationについてメモ android/)

質問・選択肢	被験者A	被験者B	合計
1. Edge AIを使ってみて、業務の効率や正確さはどうでしたか？			
非常に効率・正確さが向上した	1		1
やや効率・正確さが向上した		1	1
効率・正確さに変化はなかった			
やや効率・正確さが低下した			
非常に効率・正確さが低下した			
2. スタジアムのセキュリティ強化に役立つと感じましたか？			
非常に役立つと感じた	1	1	2
ある程度役立つと感じた			
どちらとも言えない			
あまり役立つと感じなかった			
まったく役立つと感じなかった			
3. SLMからの情報（Edge AIが教えてくれる内容）は分かりやすかったですか？			
非常に分かりやすかった	1	1	2
だいたい理解できた			
どちらとも言えない（分かりにくい部分もあった）			
少し分かりにくい部分があった			
理解するのが難しかった			
4. スマートグラスとスマートフォンの使い心地はどうでしたか？			
スマートグラスの方が格段に使いやすかった			
スマートグラスの方がやや使いやすかった			
どちらも同じくらいだった			
スマートフォンの方がやや使いやすかった			
スマートフォンの方が格段に使いやすかった	1	1	2
5. 通知を受けながら、普通の業務を続けられましたか？			
問題なく業務を継続できた			
少し中断が必要だったが、許容範囲だった	1	1	2
どちらとも言えない			
業務を一時的に中断することが多かった			
通知があるたびに業務が滞ってしまった			
6. 今後、通知を受け取りながら通常業務をサポートするために、スマートフォンとスマートグラスのどちらを使用することを好みますか			
スマートグラス			
スマートフォン	1	1	2
どちらでもない			
7. 移動中の情報確認や表示方法についてのご意見			
スマートグラスのAR表示が格段に見やすかった			
スマートグラスのAR表示がやや見やすかった			
どちらも同じくらいだった			
スマートフォンの画面表示の方がやや見やすかった			
スマートフォンの画面表示の方が格段に見やすかった	1	1	2
8. スマートグラスを使ってみて、総合的な満足度はいかがでしたか？			
非常に満足している	1		1
やや満足している			
どちらとも言えない		1	1
やや不満がある			
非常に不満がある			

図 6.2-30 アンケート(選択式)結果

端末	内容	分類
スマートグラス	発生場所がわかりやすく良かった	ポジティブな意見
スマートグラス	実際の運用を考慮したシステムができれば、手を止めずに異常を検知できて有用	ポジティブな意見
スマートグラス	移動しても画面固定でユーザーの移動についてきてほしい	改善点・要望
スマートグラス	異常画像・動画はなるべく大きいサイズで見たい	改善点・要望
スマートグラス	画像・映像の拡大機能が欲しい	改善点・要望
スマートグラス	通知を音でも知りたい	改善点・要望
スマートグラス	スマートグラスの位置把握・操作（MAP）が難しい	改善点・要望
スマートグラス	ユーザーが移動しながら使えるように、スマートグラスに追従する設定があるとよい	改善点・要望
両端末共通	新規の異常検知をもっと目立たせてほしい (今の青の小さい丸アイコンだと少し気づきにくい)	改善点・要望
両端末共通	画像の前後2～3秒を見れるようにしたい (顔が映っていない画像があるため)	改善点・要望
両端末共通	画像とマップをセットで見たい（マップ全体の中において、異常が発生している場所の画像とマップとの関係性がわかるようなイメージ）	改善点・要望

図 6.2-31 アンケート(自由回答式)結果

3) アンケート結果まとめ・考察

表 6.2-19 アンケート:エッジ AI システムの有効性

エッジ AI システムの有効性	非常によい	ややよい	要約
運用効率・精度向上	1	1	回答者全員が業務効率・正確性の向上を実感。
セキュリティニーズへの適合性	2		回答者全員がセキュリティ強化に「非常に役立つ」と感じた。
SLM からの情報理解度	2		回答者全員が SLM からの情報が「非常に分かりやすかった」と評価。
考察	エッジ AI システムは、警備業務の効率化、セキュリティ強化、および情報提供の分かりやすさにおいて、高い有効性を持つことが確認された。これは、想定された計画に対するポジティブな結果である。特に、従来の監視体制では見落とされがちだった事象の検知や、迅速な状況把握に貢献する可能性が示唆された。		

表 6.2-20 アンケート:デバイスインターフェースに関する課題

デバイス IF に関する課題	スマートグラス	スマートフォン	要約
インターフェース比較 (スマートグラス vs スマートフォン)		2	「スマートフォンの方が格段に使いやすかった」「スマートフォンを使用したい」との回答。スマートグラスについては「位置把握・MAP 操作が難しい」との具体的な意見。
移動中の情報確認・表示形式		2	スマートフォンの視認性が高く評価され、スマートグラスでは「スマートグラスに追従設定があると良い」との要望。
スマートグラス利用満足度			満足度は二分。「非常に満足」1名(発生場所が分かりやすい)、一方で「どちらとも言えない」1名からは「移動しても画面固定」「異常画像・動画は大きいサイズで見たい」などの具体的な不満点。
考察	スマートグラスのインターフェースには顕著な課題が存在する。特に、移動時の操作性、画面の追従性、画像表示の視認性において、ユーザ体験上の不満が示された。これは計画段階で想定された利便性との相違であり、今後の機能改善が不可欠である。しかし、ハンズフリーで情報確認が可能となるスマートグラスの潜在的な利便性は高く、これらの課題を解決することで、警備員の業務負担軽減や迅速な状況判断に大きく寄与する可能性も秘めている。		

4) 課題と解決策

a. 通知の視認性向上

新規異常検知のアイコンをより目立たせる、スマートグラスアプリにおける音による通知の追加など、見落としを防ぐための改善が必要である。

b. 画像・映像表示機能の強化

画像の前後数秒の表示、マップとの連動表示、スマートグラスアプリにおける画像・映像の拡大機能など、情報不足や理解の困難さを解消するための機能強化が求められる。

c. スマートグラスアプリの抜本的改善

移動時の画面追従機能、位置把握・MAP 操作性の向上は、スマートグラスが本来持つべきハンズフリーという利点を活かすための最重要課題である。

d. 運用への適合性

実際の警備業務フローにシームレスに組み込まれるよう、ハンズフリーでの異常検知を可能にする。

5) 結論

フィードバック結果は、本システムが警備業務の効率性向上に貢献する可能性を強く示した。しかし、特にスマートグラスの利便性については、ユーザ体験上の明確な課題が認められた。設計内容の改善等、今後のシステム開発において継続して解決すべき課題である。

また社会実装に向け、ユーザからのフィードバックに基づいたインターフェースの改善、特にスマートグラスの機能強化と、運用の実態に即したシステム設計への見直しが不可欠である。これにより、本システムの真価を発揮させ、より効果的な警備ソリューションとして確立することが可能になると考えられる。

6.2.3 KPI/KGI との比較結果

当ユースケースの KPI/KGI は下記の表の通りである。

表 6.2-21 「エッジ AI による通信量の低減」KPI/KGI 一覧

定性評価 /定量評価	番号	目標値
定性評価	1	エンドユーザに対するアンケート結果が以下を満たすこと ● スマートグラスアプリの方がスマートフォンアプリよりも満足度が高い
定量評価	2	ファアエッジ上の圧縮プロセスによる映像圧縮率が以下を満たすこと ● 超高圧縮(テキストへの変換):99%以上 ● 高圧縮(画像への変換):97%以上 ● 中圧縮(映像クリップへの変換):94%以上
	3	ネットワーク混雑時に中圧縮方式の使用を避けることによるデータ送信削減率が以下を満たすこと

		<ul style="list-style-type: none"> 73%以上
4	エッジサーバでの情報集約によるデータ送信削減率が以下を満たすこと	<ul style="list-style-type: none"> 35%以上
5	AI パイプラインによる検出の精度が以下を満たすこと	人物の検出 <ul style="list-style-type: none"> 未検知率: 1%以下 誤検知率: 10%以下 群衆検知 正解率: 95%以上 マスクの検出 <ul style="list-style-type: none"> 未検知率: 1%以下 誤検知率: 10%以下 年齢推定(10 歳未満・70 歳以上・それ以外の判定) 正解率: 90%以上 煙・炎の検出 <ul style="list-style-type: none"> 未検知率 : 1%以下 誤検知率 : 10%以下 リスクアセスメント(高リスク・低リスク・リスクなしの判定) <ul style="list-style-type: none"> 未検知率 : 1%以下 誤検知率 : 10%以下
6	エンドユーザの反応時間が以下を満たすこと	<ul style="list-style-type: none"> 通知への反応時間: スマートグラスアプリの方がスマートフォンアプリよりも短い 映像クリップ表示までの時間(映像再生ボタンクリックまでの時間): スマートグラスアプリの方がスマートフォンアプリよりも短い
7	ファーフエッジ推論の遅延時間が以下を満たすこと	<ul style="list-style-type: none"> 遅延時間: 200~5000 ミリ秒(1000 ミリ秒をデフォルトのパラメータ設定とする予定。200 ミリ秒とする場合リアルタイム性は高いが、ノイズ誤検知が増えてしまうため)

(1) エンドユーザに対するアンケート結果

1) KGI 目標

スマートグラスアプリの方がスマートフォンアプリよりもユーザ満足度が高い。

2) 集計結果

以下の図は、6.2.2(12)「エンドユーザアプリケーションを使用した警備担当者からのフィードバック収集」に記載の、図 6.2-30 アンケート(選択式)結果からの、スマートグラスアプリとスマートフォンアプリの比較に関する項目の抜粋である。

以下の図に示す通り、警備員に業務を委託する責任者である被験者 2 名は、ともにスマートフォンアプリに対する満足度の方が高かった。

6. 今後、通知を受け取りながら通常業務をサポートするために、スマートフォンとスマートグラスのどちらを使用することを好みますか？			
スマートグラス			
スマートフォン	1	1	2
どちらでもない			
7. 移動中の情報確認や表示方法についてのご意見			
スマートグラスのAR表示が格段に見やすかった			
スマートグラスのAR表示がやや見やすかった			
どちらも同じくらいだった			
スマートフォンの画面表示の方がやや見やすかった			
スマートフォンの画面表示の方が格段に見やすかった	1	1	2

図 6.2-32 アンケート結果抜粋(選択式、スマートグラスとスマートフォンの比較項目)

3) KGI 結果考察

以下に示す図は、6.2.2(12)「エンドユーザアプリケーションを使用した警備担当者からのフィードバック収集」に記載の、図 6.2-31 アンケート(自由回答式)結果からの、スマートグラスアプリに関する回答の抜粋である。

No	端末	意見	分類
1	スマートグラス	発生場所がわかりやすく良かった	ポジティブな意見
2	スマートグラス	実際の運用を考慮したシステムができれば、手を止めずに異常を検知できて有用	ポジティブな意見
3	スマートグラス	移動しても画面固定でユーザーの移動についてきてほしい	改善点・要望
4	スマートグラス	異常画像・動画はなるべく大きいサイズで見たい	改善点・要望
5	スマートグラス	画像・映像の拡大機能が欲しい	改善点・要望
6	スマートグラス	通知を音でも知りたい	改善点・要望
7	スマートグラス	スマートグラスの位置把握・操作(MAP)が難しい	改善点・要望
8	スマートグラス	ユーザーが移動しながら使えるように、スマートグラスに追従する設定があるとよい	改善点・要望

図 6.2-33 アンケート結果抜粋(自由回答式、スマートグラスに関する回答)

上図に示す通り、スマートグラスアプリでは、イベント詳細情報が 3D スタジアムモデル上に 3D 表示されることにより異常発生場所を直感的に把握できること、つまりスマートグラスアプリがユーザの周囲の空間全体を情報提示のキャンバスとして利用できる利点を評価する声(No.1)があった。また、端末を手にとらずに異常を確認できる利点を評価する声(No.2)もあった。これらにより、スマートグラスアプリには警備業務に使用する利点が存在することを示せた。

また、スマートグラスアプリに対する改善点・要望については、すべて実装による対応が可能な項目である。本実証では、開発期間の都合上、スマートグラスアプリには最低限の機能を実装するのみで、ユーザビリティを改善するための細部の作り込みができなかったが、今回得られた改善点・要望を踏まえて細部の作り込み、改善、機能追加をすることにより、ユーザ満足度を向上させられる余地が十分にあると言える。これにより、前述のスマートグラスアプリの利点が欠点を上回り、スマートフォンアプリよりも満足度が高くなる可能性があると言える。

しかし、6.2.2(11)「警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定」で考察したとおり、Apple Vision Pro のクリック操作はスマートフォンと比較して慣れるのに時間がかかり、操作経験の少ないユーザは不満を感じる可能性が高い。来年度以降の実証では、被験者が

Apple Vision Pro に慣れるための時間を十分に確保するなどの対応が考えられる。

(2) ファーエッジ上の圧縮プロセスによる映像圧縮率

以下に KPI 実績値と達成状況を記載する。

この表は 6.2.2(10)「ファーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価」に記載の、図 6.2-22 10/17 午前のデータ削減率(ネットワーク非輻輳状態)、図 6.2-23 10/17 午後 試合開始前のデータ削減率(ネットワーク輻輳状態)、図 6.2-24 10/17 午後 試合終了後のデータ削減率(ネットワーク輻輳状態)」を要約したものである。

表 6.2-22 ファーエッジ上の圧縮プロセスによる映像圧縮率 KPI 達成状況
※ネットワーク輻輳中、中圧縮は使用されないため、中圧縮のデータ削減率は必然的に 1 になる。

	超高圧縮	達成状況	高圧縮	達成状況	中圧縮	達成状況	合計
目標値	0.99	-	0.97	-	0.94	-	-
10/17 午前 (輻輳なし)	0.99999	達成	0.99910	達成	0.98976	達成	0.98885
10/17 午後 (試合開始前、輻輳あり)	0.99994	達成	0.99610	達成	1	(達成)	0.99605
10/17 午後 (試合終了後、輻輳あり)	0.99997	達成	0.99778	達成	1	(達成)	0.99774

上記表から分かる通り、3 つの圧縮方法すべてについて、またすべての時間帯について、KPI 目標値は達成された。

以下に、各圧縮方法についてのまとめと考察を記載する。

1) 超高圧縮(JSON テキストへの変換)

a. KPI 目標

99%以上

b. 計測結果

午前の試験においては、イベント発生頻度が KPI 目標値算出時の仮定を下回った(超高圧縮データ送信量が少なかった)が、発生頻度が仮定を大幅に上回った午後・試合開始前の試験においても、圧縮率 99.9994%を達成した。

c. KPI 結果考察

よって、超高圧縮は継続的映像ストリーム送信と比較し、圧倒的にデータ送信量を削減できると結論付けられる。

2) 高圧縮(画像への変換)

a. KPI 目標

97%以上

b. 計測結果

午前の試験においては、イベント発生頻度が KPI 目標値算出時の仮定を下回った(高圧縮データ送信量が少なかった)が、発生頻度が仮定を大幅に上回った午後・試合開始前の試験においても、圧縮率 99.9961%を達成した。

c. KPI 結果考察

よって、高圧縮は継続的映像ストリーム送信と比較し、圧倒的にデータ送信量を削減できると結論付けられる。

3) 超高圧縮(映像クリップへの変換)

a. KPI 目標

94%以上

b. 計測結果

超高圧縮が使用された(ネットワーク非輻輳状態だった)午前の試験においては、イベント発生頻度が KPI 目標値算出時の仮定を下回った(超高圧縮データ送信量が少なかった)。この時の圧縮率 98.976%であった。

c. KPI 結果考察

以下は、高リスクイベント発生頻度が KPI 目標値算出時の仮定と同じ 1 カメラ・1 時間当たり 12 件であったと仮定した場合の換算値である。

送信されるはずだったデータ

①	映像送信ビットレート	2.5Mbps	
②	時間(分)	70	
③	時間(秒)	4200	②×60
④	カメラ台数	10	
⑤	本来送信されるはずだったデータ	13,125MB	①/8×③×④

実際に送信されたデータ

		件数	高リスクイベント頻度 (1カメラ・1時間当たり)	送信サイズ	圧縮率	
⑥	中圧縮(映像クリップ)	67	5.74 (67 / ④ / ② * 60)	134.38MB	0.989762	1-(⑥/⑤)
⑦	中圧縮(映像クリップ) 高リスクイベント頻度を12と仮定	140 (12 * ④ * ② / 60)	12	280.79MB (⑥ / 67 * 140)	0.978606	1-(⑦/⑤)

図 6.2-34 高圧縮データ圧縮率(頻度調整済み)

この場合も、圧縮率は 97.8606%となり、KPI 目標値(94%以上)を達成している。

よって、超高圧縮は継続的映像ストリーム送信と比較し、圧倒的にデータ送信量を削減できると結論

付けられる。

(3) ネットワーク混雑時に中圧縮方式の使用を避けることによるデータ送信削減率

1) KPI 目標

削減率：73%

2) 計測結果

以下に KPI 実績値と達成状況を記載する。

この表は 6.2.2(10)「ファエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価」に記載の、図 6.2-23 10/17 午後 試合開始前のデータ削減率(ネットワーク輻輳状態)、図 6.2-24 10/17 午後 試合終了後のデータ削減率(ネットワーク輻輳状態)」を要約したものである。

表 6.2-23 ネットワーク混雑時に中圧縮方式の使用を避けることによるデータ送信削減率

	低リスクイベント 件数	高リスクイベント 件数	定期 報告 件数	送信された 画像サイズ 合計(KB)	送信された JSON テキスト サイズ合計(KB)	送信されるは ずだった映像 サイズ合計(KB)	輻輳時に映像を 送信しないこと による削減率	達成 状況
10/17 午後(試合開始前)	4	12	0	1196.71	17.22	25351.02	95.43%	達成
10/17 午後(試合終了後)	2	6	0	597.70	8.62	12675.51	95.43%	達成

上記表から分かる通り、試合開始前、終了後ともに、KPI 目標値(73%)は達成された。また、目標値よりも大幅に削減率は高くなった。

3) KPI 結果考察

以下に KPI 目標値に対する実績値が大幅に大きくなった原因を分析する。

表 6.2-24 画像・映像クリップサイズの KPI 算出時の仮定と実際の平均値

KPI 目標算出時に使用した映像平均サイズ(仮定)	3,500.0KB
10/16-10/17 の映像平均サイズ(実績)	2,112.59KB
KPI 目標算出時に使用した画像平均サイズ(仮定)	450.0KB
10/16-10/17 の画像平均サイズ(実績)	130.35KB
10/17 午後(試合開始前)の画像平均サイズ(実績)	74.79KB
10/17 午後(試合終了後)の画像平均サイズ(実績)	74.71KB

a. KGI 算出時に使用したデータサイズ(仮定)

上記表に示す通り、KPI 算出時に仮定した画像平均サイズは 450KB であった(5.1.6 「KPI/KGI」の(3)「ネットワーク混雑時に中圧縮方式の使用を避けることによるデータ送信削減率」参照)。これは AWL 社が VMS から収集した、実際のファイル(Full HD, JPEG の画像ファイル)の平均サイズから算出されている。また映像クリップ平均サイズも同様に、VMS から収集された実際の映像クリップ(Full

HD, MP4, 10 秒)の平均サイズから算出されている。

b. データサイズ実績値

10/16-10/17 通じての平均値は 130.35MB(仮定の 28.97%)、また 10/17 午後の当計測実施時に限っては、試合開始前 74.79MB(仮定の 16.62%)、試合開始後 74.71MB(仮定の 16.60%)と非常に小さくなった。これは、実際に使用された画像解像度が 864x480 であり、KPI 算出時の仮定である Full HD(1920x1080)の 20%のサイズだったことが原因であると思われる。

これに関しては、図 6.2-31 アンケート(自由回答式)結果に示したとおり、画像が見つらいという声はエンドユーザからは上がっておらず、また 6.2.2(6)「エンドユーザアプリケーションの開発」にスマートフォンアプリのスクリーンショットを添付したが、現場の状況の把握には十分であるため、問題はないと判断できる。

同様に映像クリップ平均サイズも仮定値 3500KB と比較し実績値 2122.58KB と小さくなったが、これは仮定値の 60.36%であり、画像サイズと比較するとそれほど差分はなかった。

c. 圧縮率実績値が大きくなった原因

ネットワーク輻輳時に送信されたデータの大半を占める画像データの合計サイズは仮定値と比較し非常に少なくなり、また送信されるはずだった映像クリップの合計データサイズは仮定値と比較してそれほど小さくならなかった。

当 KPI の算出方法は「 $1 - \frac{\text{①(実際に送信されたテキストサイズ + 実際に送信された画像サイズ)}}{\text{②(実際に送信されたテキストサイズ + 実際に送信された画像サイズ + 送信されるはずだった映像サイズ)}}$ 」である。そして②が仮定と比較してそれほど小さくならず(②の大部分を占める映像サイズがそれほど小さくならず)、①が仮定と比較して非常に小さくなった(①の大部分を占める送信画像サイズが非常に小さくなった)ため、圧縮率も想定よりも非常に大きい値となった。

(4) エッジサーバでの情報集約によるデータ送信削減率

1) KPI 目標

35%以上

2) 計測結果

6.2.2(10)「ファーエッジ上映像圧縮プロセスとエッジサーバからの情報集約によるデータ削減率の評価」の 4)「エッジサーバからエンドユーザへの情報集約によるデータ削減率」に記載したとおり、エンドユーザによる映像クリップダウンロード率が 50%の場合、エッジサーバでの情報集約によるデータ送信削減率は以下の通りとなった。

- データ削減率 : 39.99%
 - KPI : 達成
- (参考)テキストデータ削減率 : 92.85%
 - 78 件の異常通知 JSON と 10 件の定期通知 JSON は、78 件の異常通知サマリと 5 件

の定期通知サマリに要約された。

3) KPI 結果考察

エッジサーバにおいて、ファーエッジから受信した映像クリップを即座にエンドユーザアプリケーションに送信せず、エンドユーザが映像再生ボタンを押下した場合のみ送信することによるデータ送信削減効果を示すことができた。

また KPI には含まれないが、SLM を用いて JSON テキストデータを集約・要約し、テキストを生成することによるデータ削減率については、92.85%を達成した。エッジサーバでのデータ削減量全体 21,933KB(集計期間中の全受信データサイズ - 全送信データサイズ)に占めるテキストデータ削減量 77.65KB(集計期間中の全受信 JSON テキストデータサイズ - 全送信テキストデータサイズ)の割合は少ない(0.35%)が、それでも、要約テキストのみをエンドユーザアプリケーションに送信するシステムを仮定するならば 92.85%テキストデータ削減率は大きな達成であると言える。

※期間中の送受信データサイズについては図 6.2-26 エッジサーバからエンドユーザへの情報集約によるデータ削減率参照。

(5) AI パイプラインによる検出の精度

AI パイプラインによる検出精度の KPI とその達成状況のまとめを以下の表に記載する。

表 6.2-25 AI パイプラインの精度に関する KPI とその達成状況

定性評価 /定量評価	番号	目標値
定量評価	1	人物検出精度 目標値：未検知率 \leq 1%、誤検知率 \leq 10% <ul style="list-style-type: none"> ● 評価件数：214 件 ● 正解率:99% ● 偽陽性(誤検知):0%。 ● 偽陰性(未検知):1%。 性能は KPI 目標(未検出率 \leq 1%、誤検知率 \leq 10%)を満たしている。
	2	マスク検出精度 目標値：未検知率 \leq 1%、誤検知率 \leq 10% <ul style="list-style-type: none"> ● 評価件数: 30 件(最低限の品質を満たすサンプルの件数) ● 正解率:40% ● 偽陽性(誤検知):3%。 ● 偽陰性(未検知):57%。 未検知率・誤検知率が KPI 基準を満たしておらず、大幅なモデル改善が必要。
	3	年齢推定精度(子ども+高齢者) <ul style="list-style-type: none"> ● 目標値：正解率\geq90% ● 評価件数：64 件 ● 総合的な正解率: 11%。 ● 偽陽性(誤検知): 0% ● 偽陰性(未検知): 89% 正解率が年齢推定の KPI 要件を満たしていない。
	4	(子ども・高齢者検出精度)(年齢推定精度の内訳) <ul style="list-style-type: none"> ● 評価件数: 子ども 40、高齢者 24 ● 正解率：子ども：16%、高齢者：4%。 ● 偽陽性(誤検知):両カテゴリとも 0%。 ● 偽陰性(未検知):子ども 84%、高齢者 96%。

5	<p>リスクアセスメント精度</p> <p>目標値：未検知率≤1%、誤検知率≤10%</p> <ul style="list-style-type: none"> ● 評価件数：高リスク：384件、低リスク：80件 ● 総合的な正解率：高リスク：40%、低リスク：100%。 ● 偽陽性(誤検知)：高リスク：30%、低リスク：0% ● 偽陰性(未検知)：高リスク：30%、低リスク：0% <p>KPI 結果：低リスクイベントについては達成、高リスクイベントについては未達成。高リスクイベントについては、マスク検知や年齢推定などの上流モデルの精度により、強い影響を受けている。</p>
6	<p>火災・煙検知精度</p> <p>目標値：未検出率≤1%、誤検知率≤10%</p> <ul style="list-style-type: none"> ● 評価件数：50件 ● 正解率：58%。 ● 偽陽性(誤検知)：36% ● 偽陰性(未検知)：6% <p>未検知率、誤検知率とも、中間評価では KPI 目標を達成したが、スタジアム試験では達成できなかった。</p>
7	<p>群衆検知(2名以上)</p> <p>目標値：正解率≥95%</p> <ul style="list-style-type: none"> ● 評価件数：80 ● 正解率：96% ● 偽陽性(誤検知)：2% ● 偽陰性(未検知)：3% <p>KPI 結果：最終的な正解率は96%となり、KPI 目標を達成した。また、中間評価から最終評価まで安定した数値を維持した。</p>
8	<p>リアルタイム AI モデルのリスクイベント処理遅延</p> <ul style="list-style-type: none"> ● リアルタイム AI モデルにおけるリスクイベント処理遅延は、KPI で定義された 200～5000 ミリ秒の範囲内で安定して動作し、一部のケースでは想定よりも低遅延となり、目標性能を上回る結果が確認された ● ファーエッジデバイスにおける複雑なリスク分析処理は、実測において 50～252 ミリ秒の範囲で完了し、安定した低遅延性能が確認された

1) 人物検知

a. KPI 目標値

偽陰性≤1%、偽陽性≤10%。

b. 測定結果

合計 214 件のテストサンプルを評価した結果、正解率は 99%、偽陽性は 0%、偽陰性は 1%であった。

なお、本 KPI の計測は、スタジアムにおける最終評価ではなく、中間評価(6.2.2(7)「ファーエッジ上 AI パイプラインの精度評価(中間)」)において実施された。

c. KPI 結果

検出精度が目標閾値を上回り、誤分類率も無視できるほど低かったため、KPI 目標を完全に達成した。

一貫して高い精度と極めて低いエラー率は、人物検出モデルが実環境下で堅牢であることを示しており、後続のリスク評価機能のための安定した基盤を提供している。

2) マスク検出

a. KPI 目標値

顔や頭部の特徴が以下に示す最低品質(照明、サイズ、角度)を満たしているケースでは、偽陰性率 $\leq 1\%$ 、偽陽性率 $\leq 10\%$ を達成しなければならない。

- 照明:照度レベル 1 - 明るい日光またはスタジアムの屋内照明下
- サイズ:識別対象者が入力動画フレームの 20%以上を占めること
- 角度:人物の顔がカメラレンズに対してヨー ± 40 度、ピッチ ± 35 度、ロール ± 30 度以内であること

b. 測定結果

合計 30 件のテストサンプルを評価した結果、正解率は 40%、偽陽性は 3%、偽陰性は 57%であった。

c. KPI 結果

検知精度が目標水準を大幅に下回り、偽陰性率が高かったため、KPI 目標は未達成となった。

今回の結果は、現在のマスク検知モデルが実環境下において十分な堅牢性を欠いていることを示している。特に、マスクの形状、着用位置、顔の向きの変異、および上流工程である顔検知への依存性が要因として挙げられる。

3) 年齢推定(子ども・高齢者検知)

a. KPI 目標値

正解率 $\geq 90\%$ 。

b. 測定結果

子ども 40 サンプル、高齢者 24 サンプルの合計 64 サンプルを評価した結果、正解率は子どもで 16%、高齢者で 4%であった。また、偽陽性は 0%であったが、偽陰性は子どもで 84%、高齢者で 96%に達した。

c. KPI 結果

年齢ベースの分類精度が不十分であり、有効な子ども・高齢者テストケースの大部分が検知されなかったため、KPI 目標は未達成となった。

高い偽陰性率は、年齢推定モデルが子どもや高齢者を頻繁に成人と誤分類したことを示しており、適切なリスクのエスカレーション(報告)を妨げる要因となっている。

4) リスクアセスメント

a. KPI 目標値

検知された事象を「低リスク」および「高リスク」のカテゴリに正しく分類する精度を測定。

目標値：偽陰性 \leq 1%、偽陽性 \leq 10%。

b. 測定結果

低リスク評価：80 件のテストサンプルを評価した結果、精度 100%、偽陽性 0%、偽陰性 0%を達成した。

高リスク評価：384 件のテストサンプルを評価した結果、精度は 40%にとどまり、偽陽性 30%、偽陰性 30%であった。

c. KPI 結果

低リスク評価については KPI 目標を達成したが、高リスク評価については誤分類率が著しく高かったため、目標未達成となった。

低リスク評価においては安定した信頼性の高いパフォーマンスが示されたが、高リスク評価の精度は大幅に低下した。これは主に、マスク検知や年齢推定といった上流モデルへの依存が原因である。これら上流工程での検知エラーがリスク評価段階に波及しており、高リスク評価の改善には、前提となる検知モデルの精度と堅牢性の向上が不可欠であることが示されている。

5) 火および煙の検知

a. KPI 目標値

偽陰性 \leq 1%、偽陽性 \leq 10%。

b. 測定結果

中間評価においては、合計 52 件のテストサンプルについて、精度 94%、偽陽性 6%、偽陰性 0%を達成した。

しかし最終評価においては、合計 50 件のテストサンプルを評価した結果、精度 58%、偽陽性 36%、偽陰性 6%となった。

c. KPI 結果

中間評価においては KPI 目標を達成したが、最終評価においては、偽陽性率・偽陰性率ともに目標閾値を下回り、達成できなかった。最終評価においては、ノート PC に表示された模擬火・煙には、画面反射や動きの現実性低下など、実際の火災では見られない視覚的アーティファクトが存在し、これらが偽陰性や複数の偽陽性を引き起こした。

一方、中間評価においては、当検知モデルが、特に偽陰性が発生していないという点において、安全性が重視されるユースケースで有効であることを示している。

スタジアム環境における検知精度の向上および誤検知の削減のためには、追加のドメイン固有トレー

ニングと閾値のチューニングが必要である。

6) 群衆検知

a. KPI 目標値

2名以上の人物がその場にいる状況を確実に特定するため、低い偽陽性率および偽陰性率を維持しつつ、95%以上の群衆検知正解率を達成する。

b. 測定結果

合計80件のテストサンプルを評価した結果、正解率96%、偽陽性2%、偽陰性3%を達成した。

c. KPI 結果

正解率が目標閾値を上回り、誤分類率も極めて低かったため、KPI 目標を達成した。

今回の結果は、テスト環境下において群衆検知機能が非常に高い信頼性を備えていることを示しており、実運用に適した安定したパフォーマンスを提供している。稀に人数を少なくカウントすることがあるが、その影響も無視できる程度である。

(6) エンドユーザの反応時間

1) KPI 目標値

スマートフォンアプリユーザは、スマートグラスアプリユーザとは異なり、スマートフォンを手に取り、通知を確認する必要があるため、以下のようになることが期待される。

表 6.2-26 エンドユーザの反応時間 KPI 目標値

	測定項目	KPI 目標値
1	通知への反応時間	スマートグラスアプリの方がスマートフォンアプリよりも短い
2	映像クリップ表示までの時間(映像再生ボタンクリックまでの時間)	スマートグラスアプリの方がスマートフォンアプリよりも短い

2) 測定結果

6.2.2(11)「警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定」に記載したとおり、以下のような結果となった。

表 6.2-27 エンドユーザの反応時間 測定値(KPI 以外も含む)

	測定項目	測定値	KPI
1	通知への反応時間	スマートグラスアプリ平均(7.45 秒) < スマートフォンアプリ平均(11.59 秒)	達成
2	映像クリップ表示までの時間(映像再生ボタンクリックまでの時間)	スマートグラスアプリ平均(17.89 秒) > スマートフォンアプリ平均(13.74 秒)	未達成
3	(参考)通知タップ(イベント詳細画面の表示)から映像再生ボタンタップまでの時間	スマートグラスアプリ平均(9.79 秒) > スマートフォンアプリ平均(2.96 秒)	-

3) KPI 結果考察

6.2.2(11)「警備担当者がエンドユーザアプリケーションを使用した場合の反応時間の測定」の試験結果考察と重複する内容も多いが、以下に KPI 結果についての考察を記す。

3.「(参考)イベント詳細画面の表示から映像再生ボタンタップまでの時間」は、スマートグラスアプリの方がスマートフォンアプリよりも大幅に長くなった。このことから、警備担当者が、Apple Vision Pro に固有の UI クリック方法である「ピンチ」操作に手間取ったことが読み取れる。

また 1.「通知への反応時間」(スマートフォンアプリ)については、ユーザが通知を確認してからスマートフォンを手に取るまでに 11.6 秒も要するとは考えづらいため、この時間の大半は、イベントが発生してからスマートフォンに通知が表示されるまでの時間が占めていると考えられる。

よって、KPI 結果については以下のように考察できる。

表 6.2-28 エンドユーザの反応時間についての考察

	測定項目	考察
1	通知への反応時間	KPI は達成した(スマートグラス < スマートフォン)。 <ul style="list-style-type: none"> しかし、スマートグラスアプリの方が Firebase Cloud Messaging (FCM)メッセージ到達・表示までの時間が余計にかかることなどが原因の可能性が高い。 つまり、スマートグラスアプリの利点である「端末を手に取る必要がない」ことが原因ではない可能性が高い。
2	映像クリップ表示までの時間(映像再生ボタンクリックまでの時間)	KPI は達成できなかった(スマートグラス > スマートフォン)。 <ul style="list-style-type: none"> ユーザが映像再生ボタンの「ピンチ」操作に手間取ったことが原因の可能性が高い。

来年度以降は、これらの問題への対応策として、以下のようなものが考えられる。

- ユーザ反応時間を正確に測定するために、KPI として、イベント発生からの時間ではなく通知表示からの時間を採用することを検討する。
- 被験者がスマートグラスの操作に慣れるための時間を十分に確保する。
- 映像再生ボタンを大きくするなどの対応により、スマートグラスアプリの使い勝手を向上させる。

(7) ファーエッジ推論の遅延時間

1) KPI 目標値

適時なりリスク事象の検知および通知を確実にを行うため、エンドツーエンドのリアルタイム推論レイテンシ(遅延時間)を 200~5000 ミリ秒以内に維持する。

2) 測定結果

実際のエンドツーエンド推論レイテンシを測定した結果、50~252 ミリ秒の範囲内であった。

3) KPI 結果

すべての測定値が定義された目標範囲内に十分に収まったため、KPI 目標を達成した。

目標を大幅に下回るレイテンシは、システムの高い効率性を示している。これにより、リアルタイムの応答性に影響を与えることなく、追加の処理負荷や将来的なモデル拡張をサポートするための十分なパフォーマンスの余力が確保されている。

6.2.4 考察

(1) エッジ AI 技術の将来的な活用展望

実証実験により、エッジ AI モデルが特定の検知タスク、特に身体が存在や動きといった粗い特徴に依存するタスクにおいて高い精度を達成できることが確認された。侵入(人物)検知や群衆(2人以上)検知といった機能は、スタジアム内の厳しい照明条件下でも一貫して 95%以上の精度を達成した。これは、高帯域幅接続やクラウド処理を必要とせず、ファーエッジデバイス上で直接リアルタイム安全機能を実装する実現可能性を裏付けるものである。

また、エッジ AI によるデータ送信量の低減効果については、超高圧縮、高圧縮、中圧縮ともに、継続的な映像送信に比べ、97%以上という非常に大きな削減率を示した。またネットワーク輻輳時に中圧縮方式を避けることによる削減率は、KPI 目標値 79.47%を大幅に上回る約 95.43%を記録した。これらは、エッジ AI による通信量低減効果と、ネットワーク状況に応じて圧縮方式を変更する手法の有効性を裏付けるものである。

一方、マスク検知、年齢推定、火災・煙検知といったより微細なタスクへの適用においては、エッジ AI の限界も明らかになった。これらの制限から、本格的な社会実装にはハイブリッドアーキテクチャが必要となることが示唆されている。

- リアルタイムかつ高速なタスク(侵入検知、人流検知)は、ファーエッジに留める。
- 高精度または複雑なタスクは、モデルの強化による精度向上、もしくは高性能エッジサーバでの処理を行う。

このハイブリッドアプローチは、多様な施設や地域にわたる社会的展開に向けた現実的で拡張性のある道筋を示すものである。

またエッジサーバでの SLM 要約によるテキストデータ削減率が 92.85%を、正解率が 99%を記録していることも、ハイブリッドアプローチの有効性を示唆している。

(2) 代替手法と比較した AI×通信技術の優位性

本プロジェクトで実証したアーキテクチャ(ローカル推論とテレメトリ通信の組み合わせ)は、通信量の低減や、モデルの精度と運用効率に直接影響する複数の利点を提供する:

- 圧倒的な通信量低減効果:
大容量のカメラ映像をそのまま集中型サーバやクラウド環境に配信するシステムと比較し、大幅な通信量の削減が可能である。
- ネットワーク品質への依存度低減:
推論がエッジ側で実行されるため、ネットワーク遅延やパケット損失による精度への影響を受けない。クラウドベースのアプローチでは遅延が未検知を引き起こす可能性があるのとは対照的である。
- プライバシー保護の強化:
AI 推論に使用される映像データはファーエッジデバイスから決して外に出ない。つまり、個人データの露出を増やすことなく精度向上を図れる。
- モデル動作の一貫性向上:

ローカル推論によりフレームタイミングが安定するため、ネットワークのジッターの影響を受けず、予測可能な精度でモデルを動作させることができる。

集中型サーバへの動画ストリーミングに依存するシステムと比較して、この構成は、通信量の大幅な低減を実現し、さらに AI の精度とシステムの信頼性において、より堅牢で拡張性の高い基盤を提供する。

また本プロジェクトで実証した、ファーエッジとエッジサーバを組み合わせたシステム構成は、2 段階での通信量の低減と、ネットワーク状況に応じた通信量の最適化に威力を発揮する。

- 2 段階での通信量低減効果:
エッジサーバ上で SLM によりテレメトリ JSON を要約することにより、さらなる通信量の低減が可能である。
- 通信量最適化:
エッジサーバが取得したネットワーク輻輳度をファーエッジに配信することにより、ファーエッジはネットワーク輻輳度に応じた映像圧縮方式を選択し、通信量を最適化することが可能である。これにより、一般の利用者のネットワーク利用に影響を与えずに社会資源である電波を有効利用できることが期待される。

(3) 国内市場拡大と地域課題解決への貢献

実環境で確実に動作するエッジ AI 技術は、公共・民間機関の幅広い分野で強い適用性を持つ。正確なリアルタイム侵入検知、群衆監視、危険検知は以下を支援できる：

- 自治体における安全対策
- スタジアム・イベント管理
- 都市インフラ（交通拠点、公園、学校）
- 商業施設・小売店舗

特にマスク検知、火災・煙検知、迷子分類（年齢推定）におけるモデル精度の向上は、導入可能な範囲を拡大し、地方政府やセキュリティ事業者によるさらなる採用を促進する。さらに、実証されたアーキテクチャは日本の DX イニシアチブと整合しており、国内の AI 開発者や通信事業者が競争力のあるエッジベース監視ソリューションを提供できる立場にあることを示している。

本調査結果は、エッジ AI が計算処理の強みに合致したタスクに適用される場合、実世界での展開に高い潜在能力を有することを裏付ける。複雑な視覚認識タスクでは精度制限が残るものの、実証されたアーキテクチャは改善と社会的な普及拡大に向けた明確な道筋を示す。AI モデルの継続的な改良、データセットの拡充、システム構成の最適化を進めることで、AI×通信ソリューションは公共の安全強化と日本全体のデジタル変革を支える強力なツールとなり得る。

(4) RIC, ネットワークスライシングなどの通信技術の将来的な活用展望

本年度採用した予測アルゴリズムでは、短時間で大きく変化する実環境のネットワーク状況を正確に予測することが困難であることが示された。

将来的には RIC プラットフォームと連携して、リアルタイムに近いネットワーク状況を取得し、それを使用した圧縮アルゴリズム制御を実現することにより、通信利用者への影響を最大限抑止した形で、ファアエッジからエッジサーバの間の無線化を実現していく。

楽天モバイルは、²⁸2025 年 5 月に国内で初めて RIC を大規模 Open RAN 商用ネットワークへ導入し、ネットワーク消費電力の削減を実現している。導入した RIC においては、rApp（非リアルタイム RIC アプリケーション）に機械学習アルゴリズムを搭載することで、トラフィックのパターン解析から、需要予測、基地局の使用率調整まで自動化を実現し、ネットワークの最適化を図っている。現在楽天モバイルは、既に数千セルに RIC を導入済みであり、数万セルへの全国展開が進行中である。

RIC を使用して、現状に近いネットワーク状況を取得する方法としては rApp、xApp（準リアルタイム RIC アプリケーション）などと連携してネットワーク状況を取得する方法などが候補として考えられる。

また、AI が検知した事象が重大である場合は、ネットワークが混雑していても高解像度の映像を安定的に送信する必要がある。その場合はネットワークスライシング技術を活用し、映像配信に必要な帯域を RIC アプリケーション経由で動的に異なるサービスレベルを本ソリューションに割り当てることで、高い監視能力を維持することができる。

(5) エンドユーザアプリの成果・課題

警備担当者からのフィードバック結果は、エンドユーザアプリケーションが警備業務の効率性向上、ひいては警備分野の労働力不足問題の解決に貢献する可能性を強く示した。しかし、特にスマートグラスアプリの利便性については、ユーザ体験上の明確な課題が認められ、被験者 2 名ともに、スマートフォンアプリに対する満足度の方が高かった。Apple Vision Pro のクリック操作はスマートフォンと比較して慣れるのに時間がかかるため、操作経験の少ないユーザは不満を感じた可能性が高い。

その一方で、スマートグラスアプリがユーザの周囲の空間全体を情報提示のキャンバスとして利用できる利点や、端末を手にとらずに異常を確認できる利点を評価する声もあった。これらにより、スマートグラスを警備業務に使用する利点が存在することを示せた。

今回スマートグラスアプリについて寄せられた改善点・要望は、すべて実装による対応が可能な項目である。そのため、今回寄せられた意見を踏まえて細部の作り込み、改善、機能追加を行うことにより、スマートグラスアプリの使い勝手を向上させ、社会実装レベルまで実用性を向上させられる余地が十分にあると言える。

また今後の社会実装に向けては、ユーザがスマートグラスに慣れるための時間を十分に確保するなどの対応が考えられる。

6.3 ユースケース②:山間部や海中等の携帯電話網不感地域における通信の確立

当該ユースケースは実施しなかった。

6.4 ユースケース③:多種多様なデバイスに対する通信リソースの最適化

²⁸ [楽天モバイルと楽天シンフォニー、大規模 Open RAN 商用ネットワークへの AI を活用した RIC 導入を国内初で実現:](https://corp.mobile.rakuten.co.jp/news/press/2025/0528_01/)
https://corp.mobile.rakuten.co.jp/news/press/2025/0528_01/

当該ユースケースは実施しなかった。

6.5 ユースケース④:分散ネットワークにおける新たな AI ソリューションの創出

当該ユースケースは実施しなかった。

6.6 拡張性に関する検証

6.6.1 実証スケジュール

拡張性に関する検証は以下のスケジュールで実施した。

ユースケース	項目	2025年										2026年			
		5月	6月	7月	8月	9月	10月	11月	12月	1月	2月				
共通						▲ 9/19 政務官視察会			中間報告			▲ 1/16 視察会	最終報告		
		機器調達				ファアーエッジ上AIシステム開発				エッジサーバ上AIシステム開発				エンドユーザアプリケーションの開発	
ユースケース② 拡張性	実証					▲ 現地実証									
				AIモデル構築	データ取得・分析										
ユースケース② 拡張性 (可搬性)								▲ 現地実証	▲ 現地実証						
								データ取得・分析							
共通	実証 評価								中間報告 書作成						
												報告書作成			

図 6.6-1 実証スケジュール

6.6.2 評価項目の結果

(1) AI モデル拡張性の検証

本検証では「人物転倒」「暴力検知」「特定人物の顔認識」を選定し、オフライン環境下での精度を測定実施、以下の表 6.6-1 に評価項目を示す。

表 6.6-1 AI モデル拡張性検証の評価項目

番号	評価項目
1	人物転倒の AI 異常検知の精度および処理時間
2	暴力検知の AI 異常検知の精度および処理時間
3	特定人物の顔認識の AI 異常検知の精度および処理時間

1) AI 検出精度

様々な AI モデル拡張性の検出精度については以下の表 6.6-2 の通りである。

- 真値: ロールプレイングにおけるイベント発生総数 (検知数+未検知数)
- 検知数: AI カメラが検出対象を検知した数 (検知数+未検知数)
 - 正検知: 検知対象を正しく判別した数
 - 誤検知: 検知対象を誤って判別した数
- 未検知数: 本来検知すべき対象を見逃す数

表 6.6-2 人物転倒、暴力検知、顔認識の AI 検出精度

		人物転倒	暴力検知	顔認識
真値		30	45	56
検知数	正検知	29	44	56
	誤検知	1	1	0
未検知数		0	0	0
誤検知(率)		3.33% (1/30)	2.22% (1/45)	0% (0/56)
未検知(率)		0% (0/30)	0% (0/45)	0% (0/56)

2) 処理時間

各 AI モデルの処理時間は以下の表 6.6-3 の通りである。

表 6.6-3 人物転倒、暴力検知、顔認識の AI 処理時間

	人物転倒	暴力検知	顔認識
平均処理遅延時間	800~1200ms	900~1500ms	500ms 未満

(2) システム可搬性の検証

本検証では、可搬性カメラの導入における実運用上の効率性を確認するため、以下の表 6.6-4 に示す項目を評価する。

表 6.6-4 システム可搬性検証の評価項目

番号	評価項目
1	環境変化に伴う AI 検出精度
2	設置・撤去時間
3	運用効率性評価

1) 環境変化に伴う AI 検出精度

本評価では、2 箇所(エリア A とエリア B)にカメラを設置し、クロス検証を実施した。検証場所の明るさについては図 6.6-2 に示すように 3 つのパターンを設定する。各エリアにおいて、これら 3 つの明るさ条件の下で検出精度を測定した。実証の結果は以下の通り。

a. エリア A




図 6.6-2 エリア A の照度:左から照度 Lev.1:381lx、照度 Lev.2:5.2lx、照度 Lev.3:0lx

エリア A における明るさが AI の精度に与える影響※Axis P1385-E の最低照度:0.05lx(カラー), 0.02lx(白黒)

- 図 6.6-3 に示す。
- 照度が高いほど検知精度が高い傾向

※Axis P1385-E の最低照度:0.05lx(カラー), 0.02lx(白黒)

- 図 6.6-3 に示すように照度 Lev.1 (381 lx) で最も高い精度を示し、照度が下がるにつれて全体的に検知精度が低下する傾向がある。
- 照度 Lev.3 (0 lx) における AI 精度性能低下
 - 照度 Lev.3 (0 lx) では、すべての検知アイテム(マスク、炎、立ち入り 10 秒未満)の精度が大幅に低下し、システムがほとんど機能しない状態である。
- 特に「立ち入り 10 秒未満」は精度が 12.5%、「炎」は 20%、「マスク」は 33.3%と、極めて低い数値を示す。



※Axis P1385-E の最低照度:0.05lx(カラー), 0.02lx(白黒)

図 6.6-3 照度による AI 検知精度の検証結果(エリア A)

表 6.6-5 エリア A における明るさが AI の精度に与える影響

照度	検知アイテム	総件数	成功	失敗	精度 (%)
照度 Lev.1 (381 lx)	マスク	3	3	0	100.0
	炎	5	3	2	60.0
	立ち入り 10 秒未満	8	8	0	100.0


照度 Lev.2 (5.2 lx)	マスク	3	3	0	100.0
	炎	5	2	3	40.0
	立ち入り 10 秒未満	8	8	0	100.0
照度 Lev.3 (0 lx)	マスク	3	1	2	33.3
	炎	5	1	4	20.0
	立ち入り 10 秒未満	8	1	7	12.5

b. エリア B



図 6.6-4 エリア B の照度:左から照度 Lev.1:261lx、照度 Lev.2:6lx、照度 Lev.3:0lx

- エリア B における明るさが AI の精度に与える影響は図 6.6-5 に示す。
- 照度が高いほど検知精度が高い傾向
 - 図 6.6-5 に示すように照度 Lev.1 (216 lx) で最も高い精度を示し、照度が下がるにつれて全体的に検知精度が低下である。
- マスク検知は最も安定しており、Lev.1 および Lev.2 では精度 100%を維持し、Lev.3 では 66.7%までの中程度の低下にとどまった。
- 立ち入り(10 秒未満)の検知は高照度下では安定しているが、Lev.3 では精度が 50%まで急落する。低照度の影響を受けやすい。
- 炎検知は照度の影響が最も大きい。精度は Lev.1 で 60%、Lev.2 で 50%、Lev.3 で 20%まで低下し、現状の性能は低照度環境では不十分である。



※Axis P1385-E の最低照度:0.05lx(カラー),0.02lx(白黒)

図 6.6-5 照度による AI 検知精度の検証結果(エリア B)

表 6.6-6 エリア B における明るさが AI の精度に与える影響

照度	検知アイテム	総件数	成功	失敗	精度 (%)
照度 Lev.1 (216 lx)	マスク	6	6	0	100%
	炎	10	6	4	60%
	立ち入り 10 秒未満	16	16	0	100%
照度 Lev.2 (6 lx)	マスク	6	6	0	100%
	炎	10	5	5	50%
	立ち入り 10 秒未満	16	16	0	100%
照度 Lev.3 (0 lx)	マスク	6	4	2	66.7%
	炎	10	2	8	20%
	立ち入り 10 秒未満	16	8	8	50%

※マスク検知については、図 6.6-6 に示すように 8 方向サンプルのうち人物の顔がカメラに見えるサンプル(①、②、③)のみを使用した。

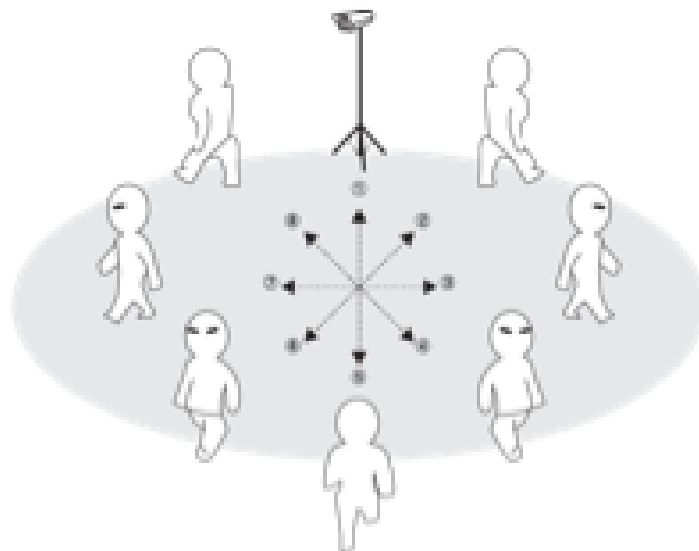


図 6.6-6 カメラビューに立ち入り方向

2) 設置・撤去時間

本検証では、カメラシステムの可搬性を把握するため、エリア A において実際の利用者がマニュアルの Step①～⑤(図 6.6-7)に基づく設置および撤去に要した時間を測定した。評価結果は以下の通りである。

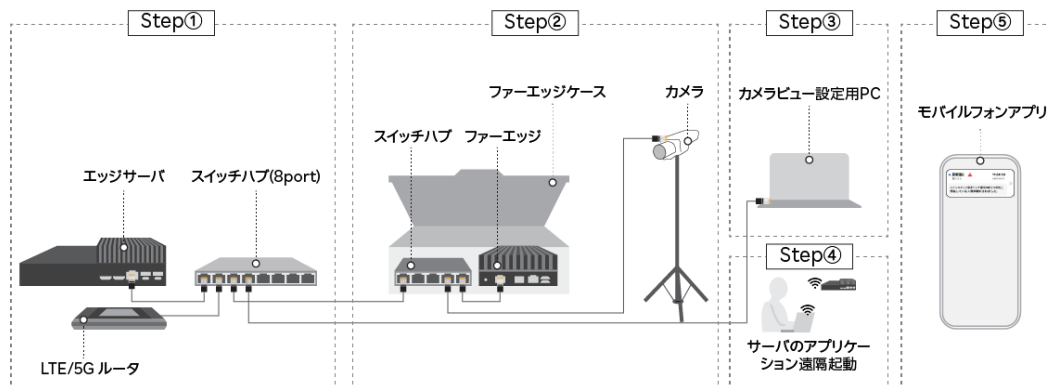


図 6.6-7 カメラシステム設置のステップ

表 6.6-7 に示すように設置作業における全所要時間は 15 分 58 秒であった。撤去作業の所要時間は 3 分 38 秒であった。各ステップにおいて、Step4 の遠隔アプリケーション起動が最も時間を要し、次いで Step3 のカメラビュー調整に時間を要した。

- 設置時間:15 分 58 秒
- 撤去時間:3 分 38 秒

表 6.6-7 設置・撤去時間の測定

ステップ	設置時間	撤去時間
Step①	3 分 15 秒	3 分 38 秒
Step②	1 分 13 秒	
Step③	4 分 39 秒	
Step④	4 分 51 秒	
Step⑤	2 分	
合計	15 分 58 秒	3 分 38 秒

事前検証に要した時間と本検証に要した時間を比較した結果、本検証においては、図 6.6-8 に示すように約 3 分 37 秒の時間短縮が確認された。

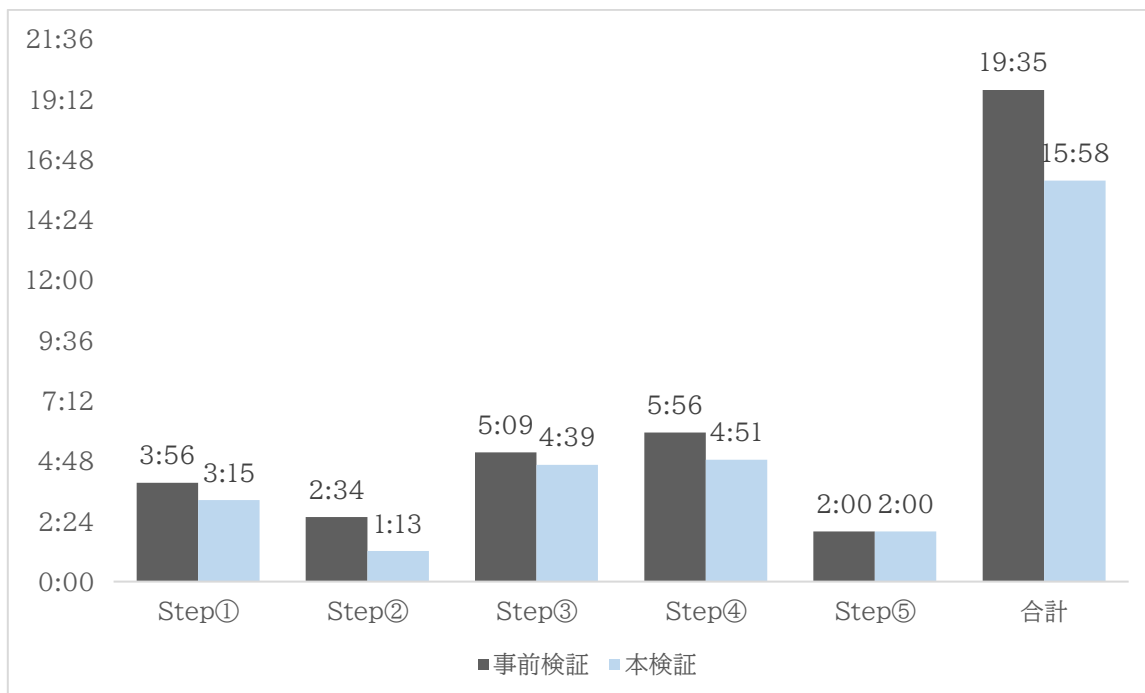


図 6.6-8 事前検証と本検証における設置時間の比較

3) 運用効率性評価

本実証の運用統括者よりシステムにおける実際に導入を検討する場合に関わる項目についてアンケートを実施、インタビューとヒアリングを行った可搬式監視システムソリューションのメリットや導入の際の課題等を整理した。

表 6.6-8 システム利用者(警備担当者)向けインタビュー項目

システム利用者(警備担当者)向けインタビュー			
カテゴリ	質問	回答	コメント/具体的な内容
設置	カメラおよびシステムの設置にかかった時間	10分	-
	設置作業の難易度	普通	使うものと使わないものを明確にしてほしい、パッケージを分ける、マニュアルもパッケージごとに存在する。
	必要な人員数と実際の作業人数	1人	もう少し細かく順序だてて記載してほしい、写真や画像をもう少し大きく目立つようにしてほしい、エッジサーバ、ファーエッジ&カメラなど種類別のマニュアルにしてほしい
	設置マニュアルの分かりやすさ	少し分かりにくい	-
撤去	システムの撤去にかかった時間	5分	-
	撤去作業の難易度	普通	-
	撤去時に困難だった点、改善すべき点		入れる箱さえ分かれば問題ない
	機器の収納・保管のしやすさ	普通	-
移動	機器の移動のしやすさ(重量)	とても軽い	-
	機器の移動のしやすさ(サイズ・形)	とてもよい	-
	機器の移動のしやすさ(可搬性)	とてもよい	-
	移動時の機器の破損リスクへの懸念	全く懸念がない	-
	移動に必要な人数	必要2名、実際2名	※理想は1名
	可搬性についての課題、ご意見		-
運用	可搬式システムの運用上のメリット・デメリット	メリット:イベントの種類や警戒したい場所に合わせて柔軟に場所を変えられる デメリット:移動時の破損のリスク、エッジサーバとカメラ・ファーエッジを結ぶケーブルの設置の手間が生じる	-
	固定式のカメラと比較した際の利便性	可搬式の方がはるかに便利	-
	上記で回答した理由を教えてください。		日常警備に加えて限定的な用途でも使用できるため。ただ、監視警戒する上で常時設置しなければならない場所のカメラは固定の方が望ましい
	他の業務との兼任のしやすさ	しにくい	-
	その理由について教えてください。		有線であることやPCをそばでつないで画角を確認するなどのアナログな作業があるため、他業務と並行して行うのは難しい。無線かつリモートでコントロールできるようになれば業務は格段にしやすいくなる
	システムの操作性・使いやすさ	非常に使いやすい	-
その理由を教えてください。		軽量で機材も多くないため	

表 6.6-9 施設利用者向けヒアリング項目

施設利用者向けヒアリング項目			
カテゴリ	質問	回答	コメント/具体的な内容
動線への影響	システム設置による通行の妨げの有無	妨げにならない	-
	景観への影響	影響がある	場所を選べば妨げになることはない。ただ、床面の LAN ケーブルの養生などの対策は必要。安全上の懸念はゼロにならない。風で転倒するリスクや人や機材が当たってカメラが壊れたり倒れてきたカメラが通行人に当たるなどの物理的リスクはゼロにはならない。ポール、カメラ、ケーブルなどがある関係でドーム型のカメラに比べるとスマートな印象ではないので、VIP エリアなどには向かない。一方で明らかに監視カメラと見てわかるので抑止力になる可能性がある。
	来場者からの苦情・問い合わせの有無(想定される苦情、問い合わせ等)		-
	来場者からの苦情・問い合わせの内容		カメラ自体、ケーブルなどが作業の邪魔になると言われる可能性はある。また、選手エリアや VIP エリアなどではカメラがはっきり見えてしまう故に撮影されていること自体をよく思わない人も存在すると思う。
施設利用者への影響全般	イベント運営への支障の有無	支障がない	-
	施設の多目的利用への対応のしやすさ(他のイベントやエリアで活用できそうか)	対応しやすい	-
	どういったイベント、エリアで活用できそうでしょうか。具体的に教えてください。(あまり混雑しないイベント等)		使用制限区域と自由に行き来できる場所がしっかり定まっているイベント。人がいないはずのエリアでは今回のように不審者検知に使える。人が多く集まる場所ではライブビューイングを確認することで混雑度やトラブル発生状況などを確認することができる。
	設置場所の変更の必要性和頻度	普通	-
	既存の施設運營業務との干渉	全く干渉しない	-
プライバシー・安全性	カメラやセンサーの設置について不快感や不安の有無	不快感・不安がある	-
	セキュリティ強化による安心感の変化	安心感が増した	-
	個人情報の取り扱いについての懸念	普通	-
	上記でそのように感じた理由	(回答なし)	-

6.6.3 KPI/KGI との比較結果

(1) AI モデル拡張性の検証

本検証は、オフライン環境下における「転倒検知」「暴力検知」「特定人物の顔認識」の各 AI モデルの精度の判断基準および KPI 目標値として「未検出率」「誤検出率」「処理遅延」を設定し、その詳細を以下の表 6.6-10 に示す。

表 6.6-10 AI モデル拡張性検証の KPI 目標値

定性評価 /定量評価	番号	目標値
定量評価	1	人物の転倒検知 <ul style="list-style-type: none"> 未検出率: ≤ 1% 誤検知率: ≤ 10% 処理遅延: 200~5000 ミリ秒
	2	暴力検知 <ul style="list-style-type: none"> 未検出率: 1%以下 誤検知率: ≤ 10% 処理遅延: 200~5000 ミリ秒
	3	特定人物の顔認識 <ul style="list-style-type: none"> 未検出率: ≤ 1% 誤検知率: ≤ 10% 処理遅延: 200~5000 ミリ秒

1) 人物の転倒検知

本検証は、スタジアム内の特定エリアにおいて人物の転倒をロールプレイングにより再現し、オフライン環境下における AI の検知精度を測定することを目的とする。結果は以下の通りである。

表 6.6-11 人物の転倒検知

項目	KPI	結果	達成状態
未検知	≤ 1%	0%(0/30)	達成
誤検知	≤ 10%	3.33%(1/30)	達成
処理時間	200~5000 ミリ秒	800~1200ms	達成

2) 暴力検知

本検証は、スタジアム内の特定エリアにおいて暴力をロールプレイングにより再現し、オフライン環境下における AI の検知精度を測定することを目的とする。結果は以下の通りである。

表 6.6-12 暴力検知

項目	KPI	結果	達成状態
未検知	≤ 1%	0%(0/45)	達成
誤検知	≤ 10%	2%(1/45)	達成
処理時間	200~5000 ミリ秒	900~1500ms	達成

3) 特定人物の顔認識

本検証は、スタジアム内の特定エリアにおいて特定人物の顔認識をロールプレイングにより再現し、オフライン環境下における AI の検知精度を測定することを目的とする。結果は以下の通りである。

表 6.6-13 特定人物の顔認識

項目	KPI	結果	達成状態
未検知	≤ 1%	0%(0/56)	達成
誤検知	≤ 10%	0%(0/56)	達成
処理時間	200~5000 ミリ秒	500ms 未満	達成

(2) システム可搬性の検証

本検証は、システムの可搬性、および設置環境の変化に伴う AI 検知精度の安定性を評価する。以下の表は KPI 目標値を示す。

表 6.6-14 システム可搬性検証の KPI 目標値

定性評価 /定量評価	番号	目標値
定量評価	1	環境変化に伴う AI 検出精度 • 場所 A と場所 B の検出差(誤差率の差):10%未満
	2	設置・撤去時間
定性評価	3	運用効率性評価

1) 環境変化に伴う AI 検出精度

AI 監視システムの検知精度は環境変化に伴い変動するため、本検証ではエリア A とエリア B を同等の照度条件下に設定し、精度の差異を確認することを目的とする。エリア A とエリア B の AI 検出差は以下、表 6.6-15 環境変化に伴う AI 検出精度に示す。

表 6.6-15 環境変化に伴う AI 検出精度

明るさ	検知項目	エリア A	エリア B	KPI	結果	達成状態
照度 Lev.1 A: 381 lx B: 216 lx	10 秒未満立ち入り	100%	100%	10%未満	0%	達成
	マスク	100%	100%	10%未満	0%	達成
	炎	60%	60%	10%未満	0%	達成
照度 Lev.2 A: 5.2 lx B: 6 lx	10 秒未満立ち入り	100%	100%	10%未満	0%	達成
	マスク	100%	100%	10%未満	0%	達成
	炎	40%	60%	10%未満	20%	未達成
照度 Lev.3 A: 0 lx B: 0 lx	10 秒未満立ち入り	12.5%	87.5%	10%未満	75%	未達成
	マスク	33.3%	100%	10%未満	66.7%	未達成
	炎	20%	20%	10%未満	0%	達成

2) 設置・撤去時間

a. カメラ 1 台あたりの設置時間

少なくとも 1 回以上の設置経験を有する利用者を前提とした場合、カメラ 1 台あたりの設置時間は約 16 分であった(表 6.6-7 設置・撤去時間の測定参照)。ただし、Step4 のサーバアプリケーション起動フェーズを利用者が直接関与できない部分として除外した場合、約 11~12 分に短縮されると推定される。

b. カメラ 1 台あたりの撤去時間

カメラ 1 台あたりの撤去時間は 3~4 分であった。

c. 考察

本検証では、エッジサーバからカメラまでの距離を 5m 以内と想定していたが、しかし、実際の設置距離がそれを超える場合は、(図 6.6-9 の①)に示すように Step①と Step②におけるケーブル配線の作業に要する時間の考慮が必要である。

実際に 150m×150m の面積に 10 箇所設置した場合、配線などの設置に時間を要し、約 6 時間を要したことから、設置時間のさらなる短縮が今後の課題である。また、有線ケーブル配線時間の短縮について、以下の主な課題が確認された。

- 試合時におけるスタッフおよび選手の動線を確保するため、ケーブルは天井配線とすることを原則とする(図 6.6-9 の②を参照)。天井への配線にあたっては、屋内外の環境変化(湿度、温度など)に影響されず、LAN ケーブルを確実に固定できる方法を採用する必要がある。また、カメラへの物理的な接触や衝突を防ぐため、強固に固定できるポール等の設置を検討する必要がある(図 6.6-9 の③を参照)。
- 試合時には一部のドアが施錠されるため、施錠時においても配線ルートが確保できるよう、隙間用ケーブルなどの特殊なケーブルの使用を検討する必要がある。(図 6.6-9 の④を参照)。



図 6.6-9 現場で有線 LAN ケーブル配線の写真

3) 運用効率性評価

本実証の運用統括者より、システム利用時の操作感や運用負荷に関するフィードバックを収集する。これにより、実証を通じて明らかになった課題を特定し、将来的な社会実装に向けた具体的な対応策を検討することを目的とする。

a. インタビューの結果(運用統括者:ヴィッセル神戸担当者)

運用統括者にアンケートおよびインタビューを実施し、その結果得られた可搬式監視システムの運用

におけるメリットを以下の表 6.6-16 に示す。

表 6.6-16 インタビュー内容の整理(メリット)

項目	内容
設置と撤去	設置に 10 分、撤去に 5 分と短時間で完了し、イベント警備や一時的な監視強化において高い運用柔軟性を提供できる。これは、固定式カメラでは実現できない迅速な対応力を示している。
可搬性	機器の重量、サイズ、形状、可搬性がいずれも「とてもよい」と評価され、破損リスクへの懸念も「全くない」とされており、物理的な移動の容易さが確認された。これにより、運搬時の負担が軽減され、効率的な運用に寄与すると想定できる。少人数での運用：設置にかかった人員は 1 名であり、少人数での作業が可能。移動時の理想人員も 1 名とされており、移動時の手段や梱包方法を改善することで、1 名での運搬を可能とする。
セキュリティ	監視カメラであることが明確なため「抑止力になる可能性がある」というポジティブな側面も評価されている。
施設への影響	動線への影響は限定的：適切な設置場所を選定すれば、通行の妨げにはならないと評価されている。
多目的利用への高い対応性	可搬性が高いことから、使用制限区域と自由に行き来できるイベントや、人がいないエリアでの不審者検知、混雑状況やトラブル確認など、多様なイベントやエリアでの活用可能性が示された。
既存業務への干渉なし	既存の施設運営業務とは「全く干渉しない」と評価されている。
プライバシーと安心感	「苦情・問い合わせリスク」の結果でも述べたように、カメラやセンサーの設置に対し「不快感や不安がある」と回答された一方で、「セキュリティ強化による安心感が増した」という回答もあり、監視システム導入に伴うプライバシー懸念と安心感向上という両側面が混在している。 個人情報の取り扱いに関する懸念は中程度であり、適切な情報管理と透明性の確保が重要となる。

運用統括者にアンケートおよびインタビューを実施し、その結果得られた可搬式監視システムの運用における課題を以下の表 6.6-17 に示す。

表 6.6-17 インタビュー内容の整理(課題)

項目	内容
マニュアルとパッケージの改善要望	設置マニュアルの分かりにくさや、使うものと使わないものの区別、パッケージの分離、マニュアルの種類別化といった改善点が指摘された。マニュアルには写真や図を活用するなど、初期導入時の学習コストや作業効率向上に関し、改善の余地がある。
移動時の利便性向上	移動時の理想人員は 1 名であるにもかかわらず検証ではカメラ、ポール運搬も含め 2 名での対応となった。利用者の運用方法や要望に合わせて、今後機器収納ケースの大型化や LAN ケーブル・カメラ・三脚の一体収納など、運搬効率のさらなる改善が求められる。
他業務との兼任の困難さ	有線接続や画角確認のためのパソコン操作といったアナログ作業が原因で、他業務との兼任が難しいという課題がある。これは無線化とリモートコントロールなどによる画角調整機能の検討・強化により、運用負荷の軽減が期待される。
ケーブル配線の手間	エッジサーバとカメラ・ファアエッジを結ぶケーブルの設置に手間がかかる点がデメリットとして挙げられた。つなげたままで運搬可能なものを区別するなど、マニュアルへの記載や知見を積むなどの改善が必要とされる。
安全上の懸念	風による転倒リスクや機器との接触による破損、通行人への危険性といった物理的リスクが「ゼロではない」と懸念されており、設置安定性と安全対策の強化が不可欠である。特に LAN ケーブルの養生が重要視されている。
景観への影響	ポール、カメラ、ケーブルなどがあるため「景観に影響がある」と認識されており、ドーム型カメラに比べてカメラの存在感が大きいことが指摘された。
苦情・問い合わせリスク	来場者から、「カメラやケーブルが邪魔になる」「撮影されていること自体を好まない」といった苦情が来ることが想定されている。プライバシーへの配慮や設置場所の検討、事前の周知が求められる。一方で監視カメラが配置されることで

	安心感が増すという意見もあることから、利用者によって印象が異なることが想定される。
--	---

6.6.4 考察

(1) AI モデル拡張性の検証

- 本検証で得られた知見
 - 拡張性の検証により、システムが計画通りに構築されていることを確認した。ファーエッジデバイスでのリアルタイム処理と、エッジサーバでの高度な分析が明確に分離されていた。この構成により、既存のリアルタイム処理の安定性を損なうことなく、新しい AI 機能を追加できる。つまり、ファーエッジのハードウェアを交換せずに、サーバ側の改善によってシステムを拡張できる。
 - もう一つの重要な知見として、オフライン評価がシステム拡張に極めて有効である理由が明確になった点である。これは、エッジサーバが有する十分な計算資源を活用することで、リアルタイム制約を受けることなく高度な AI モデルの評価が可能となるためである。具体的には、転倒検知、暴力検知、顔認証などのモデルについて、記録データを用いたオフライン評価により、精度や処理特性を詳細に確認でき、反復的な検証や調整を効率的に実施することができた。このような評価手法は、スタジアム環境に限らず、他の施設や用途への展開においても有効である。
- 課題
 - 今回定義したすべての KPI は達成された。しかし、いくつかの潜在的な課題が確認された。高度な AI モデルは、ハードウェアの制約により、ファーエッジデバイスでリアルタイムに動作させることが依然として困難である。また、カメラや AI 機能の数が増えると、エッジサーバのシステム負荷や処理遅延が増加する可能性がある。
- 今後の対応:解決策と前提条件
 - これらの課題に対応するため、さらなる取り組みが必要である。AI モデルを最適化し、処理時間とリソース使用量を削減する必要がある。オフライン処理からリアルタイム運用に移行できるモデルを決定するための明確なルールを定義することも重要である。さらに、より多くのカメラと高負荷条件でのテストを実施する必要がある。これらのステップは、オフラインでの拡張性検証から、将来の安定したリアルタイム運用への移行に不可欠である。

(2) システム可搬性の検証

1) 環境変化に伴う AI 検出精度

本評価では、場所 A と場所 B の検出差(誤差率の差)10%未満を KPI として判定を行った。その結果、照度 Lev.1 および照度 Lev.2 においては、「炎」検知を除き、すべての検出項目で両エリア(エリア A・エリア B)とも KPI を満たすことが確認された。一方で、「炎」検知については、照度 Lev.1 および Lev.2 の段階から KPI 未達となっており、設置環境に依存しない構造的な課題が示唆される。この要

因としては、学習データと実環境における炎・煙の見え方の差異や、スタジアム特有の背景・照明条件に対するモデルの適応不足が影響している可能性が高い。

照度 Lev.3 では、すべての検知項目において KPI 未達となった。特に「マスク」および「10 秒未満立ち入り」では、エリア間で性能差が顕著であり、エリア B において大幅な精度低下が確認された。一方、「炎」検知は両エリアで同程度に低い精度を示しており、低照度環境下における検知性能が根本的に不足していることが明らかとなった。

以上より、照度 Lev.3 は本システムの運用条件として非適合であり、低照度環境に対するアルゴリズム改善、カメラ設置条件の最適化、または運用上の制約条件の明確化が必要である。

2) 設置・撤去時間

- 拡張性の検証で得られた結果に基づく、社会実装に向けた今後の活用見通し
 - 設置・撤去作業における定量的な時間計測は、類似の技術やソリューションの導入検討において、具体的な指針となる。これらの定量的な知見は、AI カメラシステムの導入効果を具体的に示すことで、ユーザとなる企業や地方公共団体の意思決定を支援し、通信事業者の新たなサービス開発やソリューション提供事業者の製品改善の根拠となる。
 - ソリューション実装を念頭に置いた上で、ユーザとなる企業・地方公共団体や通信事業者、ソリューション提供事業者等にとって、検証した技術の導入を促す等、定量的な目安や指針となる具体的な知見に係る考察。以下は、企業や地方公共団体が AI カメラシステムの導入を検討する際に、初期導入コストおよび運用費(人件費)を試算するための定量的な目安となる。
 - カメラ 1 台あたりの設置時間:約 16 分
 - 撤去時間:3~4 分
 - 150m×150m の面積に 10 箇所設置した場合、約 6 時間を要した。

表 6.6-18 本カメラシステムを設置・撤去場合課題の整理

項目	課題	対策
有線ケーブル配線に伴う物理的制約	5m 以内の短距離配線が可能な環境では有線接続が優れた選択肢となるが、150m×150m のような広範囲での設置においては、ケーブル配線にかかる時間と労力が大きな課題となる。	より簡単な配線ソリューションの開発および無線通信を併用したハイブリッド構成や、メッシュネットワークによる無線接続の活用。
カメラビューの調整	カメラ設置後は、ノートパソコンにインストールされた専用ソフトウェアで各カメラビューの設定を行う必要がある。	AI による自動キャリブレーション機能の強化における設置時間の短縮
AI アプリケーション起動	エッジサーバ側で AI アプリケーションを起動するには、利用者がソリューション提供業者に遠隔に依頼する必要がある。利用者観点にはアプリケーションの操作がボトルネックになる。	アプリケーション起動の自動化や簡素化

3) 運用効率性評価

本検証で得られた設置・撤去時間、運用効率性、システム利用者(警備担当者)および施設利用者観点からの評価結果を踏まえ、本ソリューションが持つ「拡張性」に焦点を当て、その社会実装に向けた意義と今後の展望について評価考察する。

(1) 迅速な展開と撤去がもたらす運用上の拡張性

本ソリューションは、カメラ 1 台あたり約 16 分(サーバアプリケーション起動フェーズを除く場合は約 11~12 分)という短時間での設置、および 3~4 分での撤去が可能であることが実証された。これは、固定式のカメラシステムでは実現困難な高い運用柔軟性を示しており、イベント警備、一時的な監視強化、災害時における緊急監視など、短期間で監視環境の構築と解体が必要とされる多様なシーンでの活用において、極めて高い拡張性を有する。

しかし、150m×150m の面積に 10 箇所設置した場合に、配線などの設置に時間を要し、約 6 時間を要したという実証結果は、大規模環境における設置時間のさらなる短縮や省力化が課題であることを示唆している。特に、ケーブル配線作業が設置時間のボトルネックとなっていることが明らかになった。また、施設利用者の動線や景観へ配慮したケーブル設計も必要となる。将来的には、本ソリューションを Wi-Fi 化した場合のコスト検証結果(5 年間総コスト: ¥14,570,000)が示すように、通信手段の無線化はケーブル配線の手間を解消し、設置時間を大幅に短縮することが見込める。これにより、本ソリューションの設置・撤去の迅速性はさらに向上し、より広範な用途への拡張が期待できる。

(2) 運用効率性と省力化による人的資源の拡張性

警備担当者観点でのインタビュー結果から、本ソリューションは「優れた可搬性」と「少人数での運用(1 名での設置が可能)」という点で高い評価を得た。これは、人手不足が深刻化する警備業界において、限られた人員でも広範囲を効率的に監視業務が行えるという、人的資源の拡張性を提供する。AI による検知と生成 AI によるレポート作成は、監視員の常時監視の負担を軽減し、他業務との兼任を可能にする方向性を示唆する。

一方で、「マニュアルとパッケージの改善要望」、「移動時の利便性向上(現状 2 名での運搬)」、「他業務との兼任の困難さ(有線接続、パソコン操作)」といった課題も浮上した。これらの課題は、本ソリューションの運用効率性をさらに高め、より広範な現場での「使いやすさ」を向上させるための改善点である。特に、有線接続による他業務との兼任の困難さは、前述の通信手段の無線化によって解消され、監視員のリモートコントロール機能が強化されることで、真の意味での「他業務との兼任」を可能にし、限られた人員の多能工化を促進する。これは、警備業務だけでなく、施設管理、建設現場の安全管理など、様々な産業における省力化と効率化に貢献し、本ソリューションの適用範囲を大きく拡張する。

(3) 施設環境への適応性と社会受容性による市場拡張性

施設利用者観点でのヒアリング結果からは、本ソリューションが適切な設置場所を選定すれば「動線への影響は限定的」であると評価された一方で、「風による転倒リスク」、「景観への影響」、「苦情・問い合わせリスク」、「プライバシーへの懸念」といった物理的・社会的な課題も明らかになった。これらの課題は、本ソリューションの市場拡大と社会受容性を高める上で検討、克服すべき点である。

しかし、「多目的利用への高い対応性」や「既存業務への干渉なし」というポジティブな側面も強く評価されており、特に「セキュリティ強化による安心感が増した」という回答は、プライバシー懸念と安心感向

上の両側面が混在する中で、セキュリティ強化の価値が認識されていることを示唆する。これらの結果は、本ソリューションが、イベント会場、商業施設、公共空間、建設現場など、多様な施設環境において、特定の用途に限定されず、柔軟な監視ニーズに応える高い市場拡張性を有することを示している。

(4) 拡張性を最大化するシステム構成と社会実装への見通し

本検証を通じて、AI×通信の組み合わせによる可搬式監視システムは、従来の固定式監視システムや人手による監視では対応しきれない、多様な監視業務のニーズに応える高い拡張性を有することが明らかになった。

他の通信手段との比較：既存のモバイル回線を利用した本ソリューションは、固定式カメラに接続するケーブル配線の手間を省き、設置の柔軟性を高める点で、固定式カメラ固定式カメラケーブル型と比較して優位性を持つ。また、本ソリューションを Wi-Fi 化した場合のコストは、他の Wi-Fi ソリューション(市販 Wi-Fi カメラ型)と比較しても経済的優位性があり、通信手段の選択肢の広さも拡張性の一因となる。ローカル 5G 新規構築型と比較すると、既存の通信インフラを活用する点で初期投資を大幅に抑えられ、導入のハードルが低いことも拡張性を支える。

先進性と新規性：ファーエッジ AI によるリアルタイム処理、エッジサーバでの統合、生成 AI によるレポート化、そして既存モバイル網を通じた配信は、従来の「映像ストリーミング監視」とは一線を画す。特に、ネットワーク状況に応じたデータ圧縮の動的変更機能は、限られたリソース下での最適な情報伝達を可能にし、先進的である。

最適なシステム構成の知見：設置時間のさらなる短縮や運搬効率の向上には、カメラとエッジサーバ間の完全無線化や、機器収納ケースの一体化・小型化が有効である。また、安全上の懸念(転倒リスク、ケーブル養生)や景観への影響を考慮した設置方法の標準化、プライバシー保護と安心感のバランスを取るための情報開示の徹底が、社会実装を加速させるための具体的な知見として導き出された。

マーケット拡大への貢献：設置の容易さ、運用の省力化、多様な環境への適応性は、警備業界だけでなく、建設、物流、農業、インフラ点検など、様々な産業分野での新たな監視ソリューションとしての需要を喚起し、国内マーケットの拡大に大きく貢献する可能性を秘めている。特に、人手不足に悩む地域社会や産業の課題解決に直結する。

以上の考察から、本ソリューションは、その高い拡張性を活かし、継続的な改善と知見の蓄積を通じて、社会の多様な監視ニーズに応える次世代の監視システムとして、社会実装に向けた大きな見通しと可能性を秘めている。

6.7 効果検証

6.7.1 実証スケジュール

効果検証の実証スケジュールは下記の通り。

ユースケース	注項目	2025年						2026年			
		5月	6月	7月	8月	9月	10月	11月	12月	1月	2月
共通						▲ 9/19 政務官視察会		■ 中間報告		▲ 1/16 視察会	■ 最終報告
		■ 機器調達									
		■ ファアエッジ上AIシステム開発									
		■ エッジサーバ上AIシステム開発									
		■ エンドユーザアプリケーションの開発									
コスト削減効果							▲ 現地実証 データ 取得	▲ 現地実証 データ 取得			
投資対効果(ROI)							■ データ 取得		■ データ 解析		
共通	実証評価						■ 中間報告 書作成			■ 報告書作成	

図 6.7-1 効果検証の実証スケジュール

6.7.2 評価項目の結果

本検証は、本ソリューション導入時における既存施設の運用コストおよび一般的なソリューションの費用を比較し、その導入効果を明らかにすることを目的とする。以下の表 6.7-1 に効果検証の結果を示す。

表 6.7-1 効果検証の結果

番号	評価項目
1	コスト削減効果
2	投資対効果(ROI)

1) コスト削減効果

本項では、AI 監視システムの導入が、従来の有人監視体制と比較してどの程度の投資対効果を持つかを検証した。検証の結果、AI による検知の自動化により、現場の監視業務員が 1/5 削減の前提で算出するとこれにより、図 6.7-2 に示すように本ソリューションは初期導入時投資回収が見込まれる。

試算にあたっては、試合開催時など、スタジアム内で一時的に監視業務が必要となるケースを想定し、以下の前提条件を設定した。

- スタジアムの監視業務形態は、試合がない日の「常時監視」と、試合などが開催される日の「イベント監視」に大別される。
- 「常時監視」では、1 名体制による 24 時間の巡回監視および既設カメラのモニタリングを行う。
- 「イベント監視」は、スポーツ試合やコンサートなどの大規模イベント開催時に適用される。現行の監視体制に加え、監視カメラが未設置で一時的な監視が必要となるエリアを対象とする。

- 本投資対効果(ROI)の検証範囲は「イベント監視」における「リスク検知」に限定し、リスク発生後のセキュリティ対応は除外する。
- 「イベント監視」において一時的な監視が必要な場所:スタジアム内 10 箇所
- 「イベント監視」の発生頻度:年 40 日(スポーツ:30 日、コンサート等のイベント:10 日)
- 現行体制で上記 10 箇所をカバーするために必要な警備員数:1 日あたり 5 名
- 本ソリューションにて必要な警備員数:1 日あたり 1 名




図 6.7-2 本ソリューションと現行システムの年間総コスト比較

以下の表 6.7-2 には本ソリューションと現行システムの 5 年間累積総コスト(初期導入+運用コスト)を示す。

表 6.7-2 本ソリューションと現行システムの総コスト比較(5 年間)

	コスト	1年目	2年目	3年目	4年目	5年目	合計 (千円)
本ソリューション	初期導入	2,740	0	0	0	0	2,740
	運用	2,316	2,316	2,316	2,316	2,316	11,582
	累積	5,056	2,316	2,316	2,316	2,316	14,322
現行システム	初期導入	0	0	0	0	0	0
	運用	7,600	7,600	7,600	7,600	7,600	38,000
	累積	7,600	7,600	7,600	7,600	7,600	38,000

以下の表 6.7-3 に、本ソリューションの総コストの詳細な内訳を示す。

表 6.7-3 本ソリューションの総コスト(導入コスト+1 年間の運用コスト)

コスト	項目	金額(円)
初期導入	AI システム機材・設備	2,739,675
	回線工事	0
運用(1 年間)	通信費	28,560
	ソフトウェアのライセンス	738,000
	データの保存	0
	電気代	29,828
	人件費	1,520,000
	合計	5,056,063

以下の表 6.7-4 に、現行システムの総コストの詳細な内訳を示す。

表 6.7-4 現行システムの総コスト(1年間の運用コスト)

コスト	項目	金額(円)
初期導入	AI システム機材・設備	0
	回線工事	0
運用(1年間)	通信費	0
	ソフトウェアのライセンス	0
	電気代	0
	人件費	7,600,000
	合計	7,600,000

2) 投資対効果(ROI)

本項では、AI 監視システムの導入が、従来の有人監視体制と比較してどの程度の投資価値を持つかを検証した。本実証では、「業務負荷(監視業務時間)軽減効果」、「カメラ設置柔軟性向上」、「消費電力削減の効果」の観点で検証を行い、検証の結果、AI による一次検知の自動化、可搬型カメラの導入により、監視業務の負荷軽減およびカメラ設置の柔軟性向上が見込めることが確認された。

- 業務負荷(監視業務時間)軽減効果の検証
 - 本検証は、常時監視業務をリスクイベント発生時の自動通知へ置き換えた場合の、業務負荷軽減効果を確認することを目的とする。結果は以下の通りである。
 - 監視業務時間削減効果:合計 118 時間/日
 - 従来:120 時間(24 時間×5 名)
 - 本ソリューション:2 時間(2 時間 × 1 名)※計算式は 8 章参照
- カメラ設置の柔軟性向上の検証
 - 一般的な固定式のカメラソリューションは 500,000 円程度であった。
 - 固定式のカメラソリューション設置のコスト:500,000 円
- 消費電力削減効果
 - 本検証では、通信データの削減が消費電力にもたらす削減効果を確認する。ただし、システム全体の電力を算出するには時間および費用の制約から計算モデルを基に削減量を把握する。

6.7.3 KPI/KGI との比較結果

KPI/KGI について、本実証では番号 1 については本ソリューションに係るコストを算出して他のソリューションと比較を行うこと、番号 2、3、4 については検証結果のデータ収集を目標とし、実証結果で得られた結果と類似ソリューションと比較を行うことで今回の取り組みの評価を行った。

表 6.7-5 効果検証の KPI/KGI 目標値

定性評価 /定量評価	番号	目標値
定量評価	1	コスト削減効果(総コスト)

	2	業務負荷軽減効果の検証
	3	カメラ設置の柔軟性向上の検証
	4	消費電力削減効果

(1) コスト削減効果(総コスト,5年間)

本検証では、本ソリューション導入による現行運用コストに対する投資対効果の確認に加え、一般的な監視カメラソリューションを導入した場合とのコスト比較を行うことを目的とする。

以下、表 6.7-6 に示すように本ソリューションと一般的なソリューションの5年間総コストを比較した結果、コスト面でのメリットが確認された。結果は以下の通りである。

- ②-1 固定式のカメラとの比較:約 1,198 万円の削減
- ②-2 Wi-Fi 型との比較:約 2,716 万円の削減
- ②-3 ローカル 5G 新設との比較:約 3,913 万円の削減

表 6.7-6 本ソリューションと一般ソリューションの5年間コスト比較

コスト	①本ソリューション(AI型)	②一般ソリューション(非AI型)		
		②-1 固定式のカメラ	②-2 Wi-Fi 型	②-3 ローカル 5G 新設
合計(円)	14,202,303	26,191,503	41,372,192	53,340,047
①と差分		-11,989,200	-27,169,889	-39,137,744

以下の表 6.7-7 に5年間総コスト詳細を示す。

表 6.7-7 5年間総コストの詳細

コスト	項目	①	②-1	②-2	③ - 3
初期導入	ハードウェア	2,731,675	2,731,675	4,706,000	18,942,210
	回線工事(有線)	不要	500,000	不要	不要
	回線工事(無線)	不要	不要	11,250,000	1,342,880
運用 (5年間)	通信費	142,800	不要	561,000	561,000
	ソフトウェアのライセン	3,690,000	不要	0	7,326,000
	データの保存	8,000	130,000	1,320,000	1,600,800
	電気代	29,828	29,828	735,192	767,157
	人件費	7,600,000	22,800,000	22,800,000	22,800,000
合計	¥	14,202,303	26,191,503	41,372,192	53,340,047

(2) 業務負荷軽減効果の検証

現行システム運用時と本ソリューションを導入した場合の監視業務時間の比較を行った。現行システムに対し、本ソリューションを導入した場合の方が1日あたり118時間の総監視稼働時間削減が見込める結果となった。

- 総監視稼働時間軽減:118時間(時間/日)
 - 計算式:① - ② (2に示す)
 - 現行システムの監視業務時間合計:①
 - 本ソリューションの監視業務時間合計:②

表 6.7-8 業務負荷軽減

	現行システム	本ソリューション
人員配置数(人/日)	5	1
運用工数時間(時間/人)	24	2
合計(時間/日)	① … 120	④ … 2
総監視稼働時間軽減(時間/日)		118

※前提条件:150 m × 150 m の範囲内にカメラを 10 台設置し、監視業務中に 120 件のリスクイベントが発生すると想定する。

(3) カメラ設置の柔軟性向上の検証

一般的な固定式のカメラソリューションは 500,000 円程度であった。これに対し本ソリューションは固定式ではないため、設置工事が不要である。

表 6.7-9 固定式カメラとのコスト比較

	固定式のカメラ	本ソリューション
回線工事(LAN ケーブル)(円)	500,000	不要

(4) 消費電力削減効果

本検証では、以下の表 6.7-10 に示す通り、通信デバイスにおけるデータ量の削減が消費電力にもたらす削減効果を確認する。ただし、システム全体の電力を算出するには時間および費用の制約から計算モデルを基に削減量を把握する。

表 6.7-10 消費電力量にかかる計算の内訳

通信デバイス	結果
スモールセル	③ - ④(図 6.7-3 参照)
ルータ	③ - ④(図 6.7-3 参照)

- 前提条件
 - カメラ、ファアエッジ、エッジサーバ、ルータ、スモールセルなどの通信の送受信を行う機器は、送受信時に高電力モードとなり、消費電力が通常時より高くなることを前提とする。
 - 図 6.7-4 に示すように通常より AI 圧縮アルゴリズムを使った場合の方は消費電力が少ない。($P_1 > P_2$)
 - 本検証では、通信データ量の削減および基地局側の消費電力削減量の算出は行わない。これは、基地局のトラフィックが 0 の状態でもパワーアンプ(PA)、ベースバンド(BB)、冷却、デジタルユニットが稼働し続け、相応の電力を消費するためである。

以下の図 6.7-3 に、通信デバイスによる通常の映像を伝送する時と本ソリューション適用の消費電力量の差分を比較して示す。

- 消費電力削減量:③ - ④(図 6.2-3 参照)




図 6.7-3 伝送デバイスからの消費電力の削減量

- ①: P_1 通常映像を伝送する場合の電力(W)
- ②: P_2 AI 圧縮した映像を伝送する場合の電力(W)
- ③: ①の場合電力量($P_1 * t_1$)
- ④: ②の場合電力量($P_2 * t_2 * n$)
- t_1 : ①の映像送信に所要時間
- t_2 : ②の映像送信に所要時間
 - n : ②にリスクイベントの発生数

以下の図 6.7-4 には前述の通信デバイスによるデータ送受信における、通常時は消費電力が高くなるのに対し、AI 圧縮アルゴリズムを適用した場合は消費電力が低減されることを示す。




図 6.7-4 通常と本ソリューションの AI 圧縮アルゴリズム利用の場合の消費電力の比較

6.7.4 考察

本検証では、AI を用いた通信負荷の低減・通信量の確保などの効果検証を行った。提案する AI に

よる映像圧縮と無線通信を組み合わせるソリューションは、既存の有線・無線ソリューションと監視業務において以下の効果を確認した。

【主な成果】

- 1) 今後の社会実装に向けた AI 監視カメラ導入検討時におけるコスト面のハードル低減の可能性
- 2) 深刻化する警備業界の労働力不足への対応としての AI 監視システム活用による監視業務の自動化、業務負荷の軽減および人件費の最適化
- 3) 可搬型カメラの一時的設置が求められる場面における導入ハードル低減の可能性
- 4) AI 圧縮による伝送データ量削減に伴う通信機器の消費電力削減可能性の理論的確認

(1) 今後の社会実装に向けた AI 監視カメラ導入検討時におけるコスト面のハードル低減の可能性

検証結果によると、本ソリューションは現場の監視業務時間を 1/5 に軽減し、初期導入時から投資回収が見込まれる。さらに、一般的なソリューションと比較しても、固定式のカメラに対して約 1,198 万円、Wi-Fi 型に対して約 2,716 万円、ローカル 5G（新設）に対して約 3,913 万円の総コスト削減効果が期待できる。この削減効果は、AI 圧縮によるデータ伝送量の抑制（通信費削減）と、無線化による回線工事費用の不要化によって実現される。特に、有線ケーブル敷設に伴う大規模工事や高価な通信インフラ導入が不要となる点は、導入障壁の低減に大きく寄与する。

(2) 深刻化する警備業界の労働力不足への対応としての AI 監視システム活用による監視業務の自動化、業務負荷の軽減および人件費の最適化

監視業務の負荷が 1 日あたり 118 時間削減することを確認した。これは、従来のシステムにて大量の映像データを常時監視していた業務を AI がリスクイベントのみを抽出し、監視員が確認すべき映像を大幅に絞り込むことで、監視員の業務時間を大幅に軽減する。

(3) 可搬型カメラの一時的設置が求められる場面における導入ハードル低減の可能性

回線工事が不要になることで、カメラの設置場所の制約が大幅に緩和される。これにより、地形や既存インフラに左右されず、必要な場所に迅速にカメラを設置できる。従来の有線システムでは、ケーブル敷設の物理的・経済的制約が大きく、設置場所が限定される課題があった。

(4) AI 圧縮による伝送データ量削減に伴う通信機器の消費電力削減可能性の理論的確認

AI 圧縮により伝送データ量が削減されるため、通信機器の消費電力も削減される。これにより、運用コストの低減だけでなく、環境負荷の低減にも貢献する。特に、バッテリー駆動の監視カメラなど、電源供給が限られる環境での運用において、この効果は非常に重要となる。

【課題の整理】

- 1) 有線ケーブル配線の物理的・経済的制約
- 2) 基地局側の消費電力削減効果の限定性
- 3) クラウド活用時の消費電力の考慮

(1) 有線ケーブル配線の物理的・経済的制約

監視カメラの設置範囲が広く、カメラ間の距離が長い場合、有線ケーブルの配線には多大な時間と労力を要する。距離が伸びるほど作業は複雑化し、現場作業者の負荷を著しく高める。その結果、システム導入までの期間が長期化し、人件費を含む初期導入コストが大幅に上昇する。今後は、有線配線に伴う設置時間と業務負荷の課題を軽減できる無線化などの手段を検討する必要がある。

(2) 基地局側の消費電力削減効果の限定性

基地局側の消費電力削減効果の限定性:基地局(基地局、スモールセル、ルーターなど)の消費電力は、データ伝送量だけでなく、パワーアンプ(PA)、ベースバンド(BB)、冷却、デジタルユニットの常時稼働による影響が大きいため、データ削減のみでは全体の消費電力削減に与える影響が限定的となる場合がある。現状のシステム構成では、データがゼロの状態でも相応の電力を消費するため、基地局側の電力削減を評価するには、システム全体の設計や機器構成を考慮する必要がある。

(3) クラウド活用時の消費電力の考慮

本ソリューションがエッジ処理を重視する一方で、将来的に AI モデルの学習や高度な分析のためにクラウドを活用する場面が増えることが想定される。その場合、クラウド側のデータ転送量やコンピューティングリソースの消費電力も考慮に入れた、システム全体での消費電力最適化の計算モデルと評価が必要となる。

7. 本実証の総括

7.1 本実証の成果・課題

本実証では、スタジアム環境においてエッジ AI を活用した監視システムを構築し、通信量の削減、システムの拡張性、および導入効果の検証を行った。以下に、主要な 3 つの観点における成果と課題、および本実証全体を通じた総括を記載する。

7.1.1 ユースケース①:エッジ AI による通信量の低減(6章2節)

本実証において、エッジ AI を用いた映像圧縮技術は高い有効性を示した。テキストへの変換(超高圧縮)、画像への変換(高圧縮)、映像クリップへの変換(中圧縮)のいずれにおいても、KPI 目標値を上回る 98.88%以上のデータ削減率を達成した。特にネットワーク輻輳時には輻輳状況を加味した処理を行うことで中圧縮の使用を回避する制御が機能し、約 95.43%の削減率を維持した。これは試合日等、ネットワークが混雑する状況においても一般のネットワークに影響を与えず、スタジアムで発生した事象を確実に検知、警備員に通知することでスタジアムの監視能力を向上できることが証明された。

また、AI 検知精度に関しては、侵入検知(10 秒未満/10 秒以上)や群衆検知(2 名以上)といった機能は、スタジアム内の厳しい照明条件下でも一貫して 95%以上の精度を達成した。これは、高帯域幅接続やクラウド処理を必要とせず、ファーエッジデバイス上で直接リアルタイム安全機能を実装する実現可能性を裏付けるものである。さらに、SLM(小規模言語モデル)を用いて開発した「AI 異常レポート要約エージェント」においては、当初 47%程度であった要約精度が、自動評価およびフィードバックループの実装により 99%以上にまで向上した。これにより、映像メタデータのテキスト化による大幅な通信量削減と、高精度な状況報告の両立が可能であることを実証した。

一方で、エッジ AI の分析においては、微細な特徴識別を必要とするタスクには課題が残った。「マスク検知」の正解率は 40%、「子ども・高齢者の分類」は 10%台と低迷し、誤検知や未検知が確認された。また、「火災・煙検知」においては照明の反射等を誤認するケースが 36%発生し、AI モデル側の認識特性に加え、カメラ撮像性能や照明条件といった環境要因の影響が大きいことが明らかになった。これらは学習データの拡充、閾値調整、暗所向けの撮像条件最適化などを組み合わせることで改善可能であり、本実証で課題要因が明確化されたことで、今後の社会実装・横展開に向けた具体的な改善方向が得られた。

システム運用面では、ユーザ体験のアンケート・ヒアリング結果において、スマートフォンのアプリケーションは評価が高かったものの、スマートグラスのアプリケーションの操作性や視認性に対し、被験者から改善を求める声が挙がった。

これらの課題に対し、まずエッジ AI のシステム構成において今後は「ハイブリッドアーキテクチャ」の採用を推進する。リアルタイム性が求められる侵入検知等はカメラ側のファーエッジ側で処理を行い、高精度が求められる複雑なタスクは高性能のエッジサーバ側で処理する構成とすることで、精度と即応性の両立を図る。また、通信技術において、将来的には RIC プラットフォームと連携して、リアルタイムに

近いネットワーク情報を取得し、それを使用した圧縮アルゴリズム制御を実現することにより、通信利用者への影響を最大限抑止した形で、ファーエッジからエッジサーバの間の無線化を実現していく。このアプローチは、スタジアムのみならず、都市インフラや商業施設など多様な環境への社会実装を可能にする現実的かつ拡張性の高い道筋であるといえる。

スマートグラスアプリについては、本年度得られたフィードバックを元に細部の作り込み、改善、機能追加を実施し、ユーザ満足度を向上させ、かつスマートグラスアプリの利点である、ユーザの周囲の空間全体を情報提示のキャンバスとして利用できること、端末を手にとらずに異常を確認できることを最大限活用できるように改修する。

7.1.2 拡張性に関する検証(6章6節)

システムの拡張性については、オフライン環境下での検証により、「人物転倒」、「暴力検知」、「顔認識」のすべてのモデルにおいて、検知精度および処理時間の KPI を達成した。前節で検証したとおり、ファーエッジデバイスでのリアルタイム処理と、エッジサーバでの高度な分析が明確に分離した構成により、リアルタイム性を損なうことなく、新しい AI 機能を追加できる柔軟なシステムであることが確認された。これにより、エッジデバイスのハードウェアを変更することなく、サーバ側の機能追加のみでシステムの高度化が可能となる、拡張性の高いアーキテクチャの有効性が示された。

可搬性に関しては、カメラ 1 台あたりの設置時間が約 16 分、撤去が 3 分程度であり、一度設置を経験することで、次回以降は迅速に行えることが確認された。運用担当者へのインタビューでも、イベントでの警備や一時的な監視強化における柔軟性が高く評価された。

環境変化への適応性において、照度 0lx の暗所環境では「炎検知」を含む複数タスクで性能低下が見られ、設置環境による制約が明らかになった。これは AI モデルだけではなく、カメラの撮像性能・照明条件など撮像側の影響も大きいことが判明した。今回の結果を踏まえることで、暗所に強いカメラ選定や撮像条件の最適化、低照度専用モデルの強化など、改善の方向性が具体化したといえる。また、エッジサーバとファーエッジおよびカメラを接続する有線ケーブルの配線作業が、広範囲(150m×150m)に展開する場合に、設置に要した時間の多くを占め、設置に約 6 時間を要したことも確認された。今後は、配線の物理的制約を解消するため、無線通信やメッシュネットワークを併用したハイブリッド構成によりさらなる効率化を図る。また、カメラビュー調整の自動化(AI による自動キャリブレーション)やアプリケーション起動の自動化などを進めることで、設置・運用の完全省力化を目指す。さらに、オフライン検証で得られた知見をリアルタイム運用へ移行する判断基準(モデルの切替ルール)を整備することで、より多様な環境へ迅速に適応し、社会課題に応える柔軟なプラットフォームとして発展できる基盤が形成できると考える。

7.1.3 効果検証(6章7節)

コストおよび業務効率化の観点において、本ソリューションは顕著な成果を上げた。AI による自動検知の導入により、10 箇所を 5 人で監視する想定での業務時間と比較して、本ソリューションを導入した

場合は2時間に対応が可能となり、1日あたり118時間削減できることが試算された。コスト面では、一般的な固定式監視システムと比較して5年間(初期導入費+運用費)で約1,198万円、ローカル5G新設型と比較して約3,913万円の削減効果が見込まれ、投資回収は初期導入から早期に完了することが見込まれた。また、AI圧縮によるデータ通信量の削減は、通信機器の消費電力削減にも理論的に寄与することが確認された。

一方、基地局の消費電力削減効果については、データ通信量が減少しても基地局のベースバンド処理や冷却機能等が常時稼働するため、システム全体での削減効果が限定的になる側面がある。

本実証で示されたコスト削減効果と業務負荷軽減の実績は、深刻化する警備業界の人手不足に対する強力な解決策となる。初期導入コストの低減と高い投資対効果(ROI)は、ユーザとなる自治体や企業の導入ハードルを大幅に引き下げるものである。

7.1.4 総括

本実証実験は、スタジアムという高密度かつ環境変動の激しい実フィールドにおいて、エッジAI技術と通信技術を融合させた監視ソリューションの技術的実現性とビジネス価値を検証するものであった。

技術的側面においては、カメラに近い装置であるファールエッジ側での「超高圧縮」等のデータ処理とエッジ側でのデータ統合による二段階のデータ圧縮、および通信状況に応じた圧縮方法の変更により、通信帯域が混雑する場合でも事象に対してリアルタイムでの検知および初期対応が可能であることを実証した。これは、通信網が脆弱な環境や災害時においても、必要最小限のデータ量で状況把握が可能であることを示唆しており、社会インフラとしての強靱性を示すものである。

社会的・ビジネス的側面においては、深刻化する警備業界の人手不足という課題に対し、AIによる「人の目の代替」と「業務の自動化」で警備業務経験の浅い従事者でも本ソリューションを活用することで熟練者とのスキル差を埋めることができ、有効な解決策となり得ることが定量的に確認された。また、大幅なコスト削減効果と迅速な投資回収見込みは、ユーザとなる自治体や民間企業によるDX推進を後押しする強力な材料となる。

微細な認識タスクにおける精度向上や、設置運用のさらなる省力化といった課題は残るものの、これらはハイブリッドアーキテクチャへの進化や無線技術の活用によって解決可能なものである。無線技術においては、将来的にはRICプラットフォームと連携したリアルタイムの圧縮アルゴリズム制御や、ネットワークスライシングによる高リスクイベント映像の専用帯域による配信なども想定する。

よって、本ソリューションは日本の社会インフラにおける安全性向上とデジタル変革(DX)を支える基盤技術として、高い実用性と将来性を有していると結論付けられる。

本取り組みを通じて、今後は、深刻化する警備業界の労働力不足という社会課題に対し、様々な施設環境において本ソリューションが強力な解決策となるよう推進する。無線化技術との融合により「工事不要・即時設置」を実現することで導入ハードルをさらに下げ、通信量削減とコストメリットを両立させた次世代のAI監視ソリューションとして、事業の横展開や社会実装を目指していく。

8. 参考資料

8.1 システム構成図・設計書

8.1.1 エッジサーバまでのシステム構成図

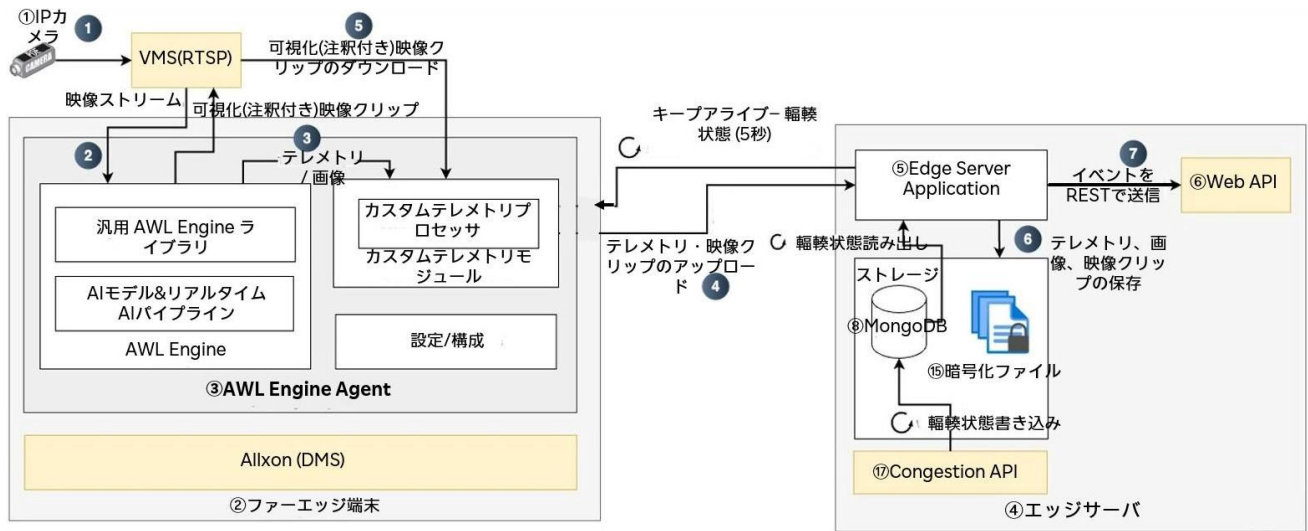


図 8.1-1 エッジサーバまでのシステム構成図・データフロー

8.1.2 エッジサーバ以降のシステム構成図

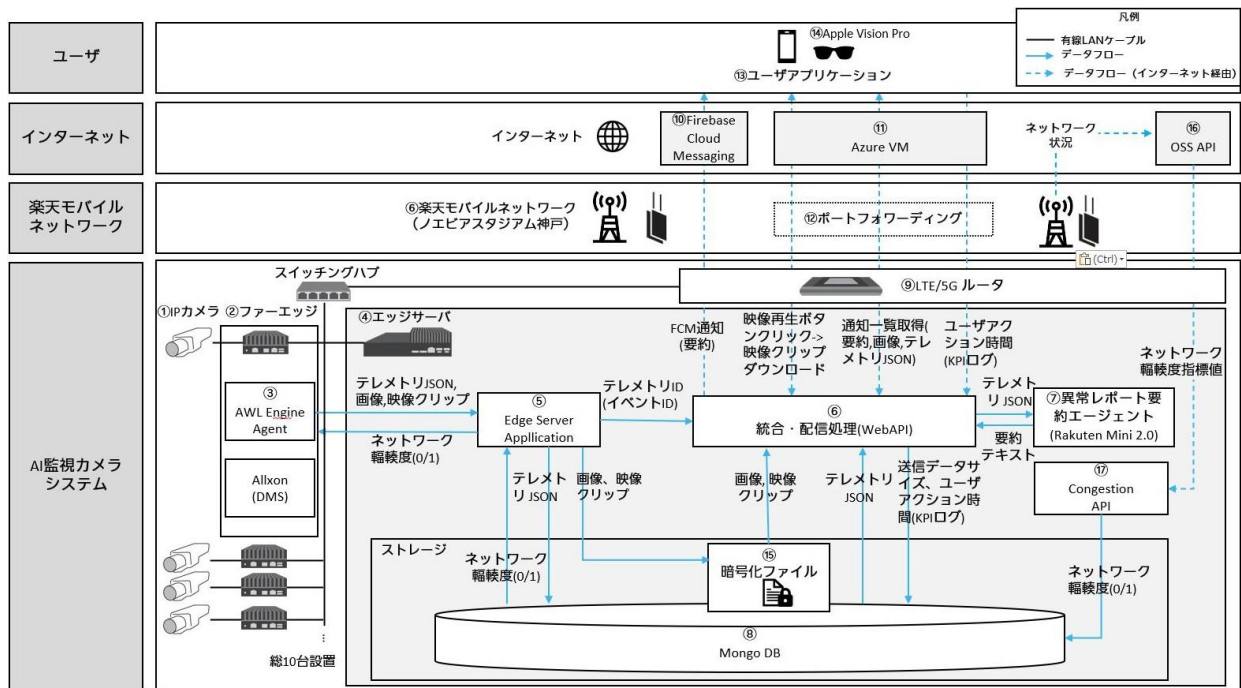


図 8.1-2 エッジサーバ以降のシステム構成図・データフロー

8.2 ネットワーク構成図・設計書

本検証におけるネットワーク構成図を以下の図 8.2-1 に示す。AI 監視カメラシステムは、スタジアム既設のモバイルネットワークに接続し、インターネット経由でユーザーのアプリへ通知を送信する。

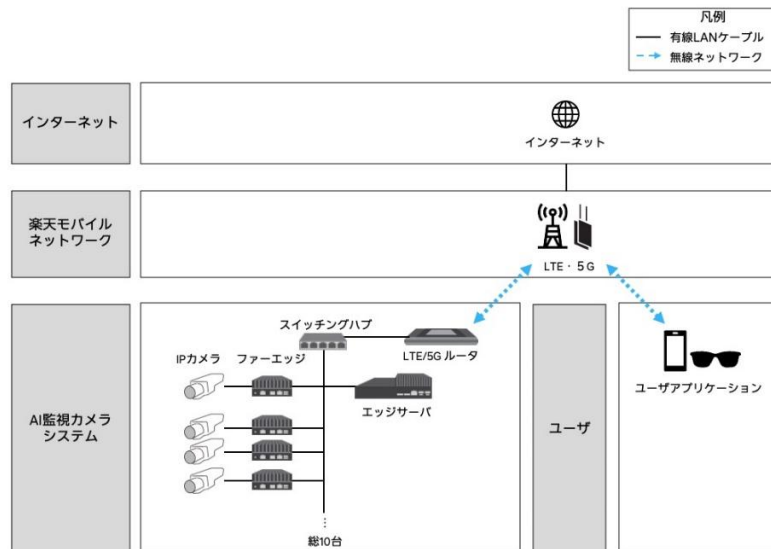


図 8.2-1 ネットワークの構成図

8.3 使用機器・ソフトウェア一覧

本実証で使用した機器一覧を以下に記載する。見出しの先頭の番号は、図 8.1-1 エッジサーバまでのシステム構成図・データフロー」、図 8.1-2 エッジサーバ以降のシステム構成図・データフロー」内の番号に対応している。

8.3.1 データ取得に関する機器・ソフトウェア(センサ類)

(1) ① IP カメラ(Axis M1135 Mk II)

- 使用台数 : 10 台。

a. 選定理由

信頼性、高画質性能、そしてスタジアムなどの複雑な環境におけるエッジ AI ベースの映像分析への適合性から、本実証のメインカメラとして選定された。様々な照明条件や天候下でも鮮明で安定した映像ストリームを提供できるため、人物検知、頭部・顔検知、火災・煙検知、人口統計分析といったリアルタイム検知タスクにおいて特に効果的である。

カメラのハードウェア特性により、フレームロスを最小限に抑えた安定した動作が保証される。これは、追跡、姿勢推定、行動認識といった下流モジュールにとって非常に重要である。さらに、オープンスタンダードに対応し、ファーエッジコンピューティングデバイスとの統合が容易なため、専用プロトコルを必要とせずに効率的なデータ取得が可能である。

b. 主な機能

ア) 高解像度 5MP (500 万画素) イメージセンサ

被写体が遠く離れている場合や部分的に隠れている場合でも、人物、頭部、顔の検出に適した詳細な画像を提供する。

イ) ライトファインダーと WDR (ワイドダイナミックレンジ)

スタジアムの通路、日陰のスタンド、屋内外が混在する場所など、照明条件の厳しい環境でも安定した画質を確保する。

ウ) 統合型赤外線照明

追加の外部照明を必要とせず、夜間や低照度でも動作し、常に高い検出精度を保証する。

エ) 屋外対応の堅牢な筐体 (IP66/IK10)

雨、ほこり、振動、温度変化、物理的衝撃に耐える設計である。

オ) 複数のビデオストリームと効率的なエンコーディング (H.264/H.265) のサポート

帯域幅使用量を管理しながら、人によるモニタリングと AI パイプラインの両方を柔軟に構成できる。

カ) 低遅延ストリーミング

ファアーエッジデバイスでのリアルタイム AI 推論に適した、安定したフレーム配信を提供する。

キ) オープン API および ONVIF 互換性

独自の制約なしに、ファアーエッジ上のキャプチャソフトウェア、テレメトリパイプライン、エッジサーバのインフラストラクチャとのシームレスな統合を実現する。

ク) リモート設定とヘルスマニタリング

実証期間中の設置とメンテナンスを簡素化し、物理的なアクセスなしでの設定 (ROI、露出、IR モード) 調整を可能にする。

ケ) 高トラフィックおよび混雑時における安定した動作

高混雑環境における実績があり、混雑したスタジアムイベント中の運用というプロジェクト要件を満たしている。



図 8.3-1 AXIS M1135 Mk II Box Camera 外観

8.3.2 データ処理に関する機器・ソフトウェア

(1) ② ファアーエッジデバイス (AVerMedia QL601 Box PC)

- 使用台数: 10 台 (1 台の IP カメラに 1 台のファアーエッジデバイスが対応する)

- OS: Ubuntu 22.04 LTS
- CPU: Qualcomm® QCS6490 プロセッサ

a. 選定理由

スタジアム規模の導入に必要な AI 推論能力、産業用耐久性、そして統合柔軟性のバランスを備えているため、ファーエッジコンピューティングプラットフォームとして選定された。

このデバイスは、最大 12.5 TOPS の AI コンピューティング性能を提供する Qualcomm® QCS6490 プロセッサを搭載しており、人物検知、追跡、頭部分析、火災・煙検知、マスク検知など、複数のリアルタイムモデルを低遅延で同時に実行できる。コンパクトでファンレスな産業用設計により、継続的な稼働が求められ、メンテナンスのための物理的なアクセスが制限される環境でも安定した運用を実現する。

このプラットフォームは、コンテナ化された AI サービスに適した Ubuntu 22.04 LTS 環境を実行可能で、それにより AWL のリアルタイム AI パイプラインを再現性のある形で展開できる。このハードウェアは、有線イーサネット、Wi-Fi 6E、Bluetooth 5.2、複数の USB インターフェース、オプションの 4G/5G モジュール用拡張スロットなど、幅広い接続オプションをサポートしており、スタジアムのネットワーク構成に柔軟に対応できる。ローカル NVMe/UFS ストレージは、必要に応じて映像フレーム、イベント情報テレメトリログ、イベント画像を一時的にバッファリングできる。

またオプションの OOB モジュールを装備することで、Out-of-Band(OOB)リモート管理をサポートできる。これにより、オペレーターはリモートからデバイスの状態を監視し、電源のオン/オフや再起動を実行したり、OS が応答しない場合でもシステムを復旧したり、現場にアクセスすることなくトラブルシューティングを行ったりできる。スタジアムにおいて、デバイスが高層スタンド、立ち入り制限のある部屋その他のアクセスが困難な場所に設置されている場合、OOB 機能により運用停止時間が大幅に短縮され、サービスの信頼性が向上する。

b. 主な機能

ア) Qualcomm® QCS6490 AI プロセッサ (最大 12.5 TOPS)

低遅延なエッジ推論を複数モデルで同時に実行できる。

イ) 8GB LPDDR4 メモリと 128GB UFS 2.2 ストレージ

連続処理でも安定したパフォーマンスを提供し、ローカルでのビデオバッファリングとログ記録を可能にする。

ウ) 産業グレードの動作温度範囲 (-10°C~60°C)

屋内、半屋外、機器室などの環境において信頼性の高い動作を保証する。

エ) ファンレスでコンパクトな産業用設計

メンテナンスの必要性を最小限に抑え、継続的な導入に最適である。

オ) 柔軟な接続性

GbE LAN、Wi-Fi 6E、Bluetooth 5.2、USB 3.0/2.0 ポート、HDMI/DP インターフェース、4G/5G モジュール用 M.2 拡張ポートを搭載している。

カ) デュアル MIPI-CSI カメラインターフェース

将来のユースケースで必要になった場合に、高帯域幅カメラを直接統合できる。

キ) 40 ピン拡張ヘッダー (GPIO、UART、SPI、I2C、PWM)

追加のセンサや補助制御ハードウェアとの統合が可能。

ク) セキュアなハードウェアアーキテクチャ

高信頼実行(trusted execution)とセキュアなデータ処理をサポート。

ケ) 帯域外 (OOB) リモート管理サポート

メイン OS にアクセスできなくなった場合でも、リモートからの復旧、監視、電源管理を可能にする。



図 8.3-2 AVerMedia QL601 Box PC 外観

(2) ④ エッジサーバ(Lenovo ThinkEdge SE100 + NVIDIA RTX2000E (GPU))

- 使用台数: 1 台

- GPU: NVIDIA RTX2000E
- CPU: Intel(R) Core(TM) Ultra 5 225H
- OS: Ubuntu 24.04.3 LTS

a. 選定理由

要求の厳しいエッジコンピューティング環境向けに特別に設計されているため、エッジサーバプラットフォームとして選定された。コンパクトなサイズ、堅牢な設計、そして効率的な熱特性により、スタジアムや公共施設など、スペースが限られており、埃、振動、温度変動といった環境変化への耐性が求められる施設への導入に最適である。このプラットフォームは、複数のファールエッジデバイスからのテレメトリの集約、ローカルイベント処理、データベースサービス、そしてオプションのオフライン分析ワークロードをサポートするのに十分な CPU 性能と拡張機能を備えている。また、遠隔地や半制限エリアにおける長期無人運用に不可欠な、強力なシステム管理機能とセキュリティ機能も備えている。

SE100 は、エッジ AI、分析、リアルタイム処理を低遅延で実行できるように設計されている。壁掛け、天井設置、ラックマウント、あるいは卓上設置が可能で、カメラネットワークやネットワークスイッチの近くに設置することも容易である。組み込みの管理機能により、オペレーターはハードウェアの状態を監視し、ファームウェアを更新し、リモートで問題をトラブルシューティングできるため、メンテナンスのダウンタイムが大幅に短縮され、大規模な展開全体でシステムの信頼性が確保される。

リモート管理性、強力なセキュリティ、そして拡張性を兼ね備えたこのプラットフォームは、現在のユースケースだけでなく、将来の機能拡張や複数の自治体・施設にまたがる拡張ニーズにも対応できる。

b. 主な機能

ア) コンパクトで柔軟なフォームファクター

省スペースと柔軟な設置オプションにより、サーバラックをフルに利用できない場所でも、様々なスタジアム環境に設置できる。

イ) 強力なマルチタスク性能を備えたエッジ最適化 CPU

テレメトリの取り込み、データベース操作、分析サービスを同時に実行できる最新のマルチコアプロセッサをサポートする。

ウ) 拡張可能なメモリとストレージ

最大 64GB の DDR5 メモリと複数の NVMe M.2 ストレージオプションをサポートしているため、ビデオバッファ、テレメトリログ、AI 評価出力のローカルコピーの保存に最適である。

エ) 幅広い温度および振動耐性

スタジアムの機材室や通路など、過酷な環境下でも信頼性の高い動作を実現する設計である。

オ) 豊富な I/O と接続性

1GbE オンボードネットワークを搭載し、オプションで PCIe 経由の 10GbE 拡張が可能。

複数の USB ポートにより、必要に応じて周辺機器や外部ストレージを接続可能。

PCIe 拡張スロットは、追加のアクセラレータまたはネットワークインターフェースカードをサポートする。

カ) GPU およびアクセラレータ拡張のサポート

ロープロファイル GPU をサポートし、将来的に高負荷なビデオ分析やモデルの再学習タスクに対応するためのアップグレードを可能にする。

キ) 強力なリモート管理およびセキュリティ機能

エンタープライズクラスのリモート管理コントローラーを搭載し、リモートでの電源制御、ファームウェアアップデート、ハードウェア診断が可能である。

セキュアブート、TPM、暗号化機能、およびオプションの改ざん検出をサポートする。

ク) 効率的な電力使用

消費電力に対して高いコンピューティング出力を実現するように設計されており、大規模な電気インフラを必要としない分散型インストールに適している。



図 8.3-3 Lenovo ThinkEdge SE100 外観

8.4 取得したデータの例

- マスク検知モデル学習用データセット
 - (出典:<https://www.kaggle.com/datasets/ashishjangra27/face-mask-12k-images-dataset>)



図 8.4-1 マスク着用検出データセットの例

- 火災・煙検知用学習データセット

- DFire-Dataset: 出典- [https://github.com/gaia-solutions-on-](https://github.com/gaia-solutions-on-demand/DFireDataset)



demand/DFireDataset

図 8.4-2 DFire-Dataset の例

- Kaggle の火災データセット



図 8.4-3 Kaggle の火災データセットの例

- DFS 火災・煙データセット - (出典 <https://github.com/siyuanwu/DFS-FIRE-SMOKE-Dataset>)




図 8.4-4 DFS-FIRE-SMOKE データセットのサンプル

- 転倒・暴力検知用学習データセット

NTU RGB+D 120 データセットの訓練データは、転倒、攻撃的な身体的接触、または一般的な姿勢変化に対応する動作のみを含むよう選択的にフィルタリングされた。



図 8.4-5 転倒および暴力検知の例

Le2i 転倒データセットは、日常的な屋内環境で捉えられた現実的な転倒パターンを提供するために組み込まれた。



図 8.4-6 転倒検知の例

- 評価結果データ

START TIME	END TIME	AREA	TYPE	RISK LEVEL	EVENT CATEGORY	DESCRIPTION
2026-01-06 09:24	2026-01-09 11:24	All Areas	All Types	All	All Categories	
070c0f050405	01/06/2026, 10:36:48 AM	area_5	person	low	Intrusion	エリアCに人物が検知されました。
0e0606070407	01/06/2026, 10:16:56 AM	area_10	person	high	Mask	エリアBにマスクを着用した人物が検知されました。
080e06080108	01/06/2026, 10:16:45 AM	area_9	person	high	Intrusion	エリアAに10秒以上滞在している人物が検知されました。
070407b0404	01/06/2026, 10:15:21 AM	area_2	person	high	Mask	エリアDにマスクを着用した人物が検知されました。
08000b0a0203	01/06/2026, 10:15:05 AM	area_5	person	high	Intrusion	エリアCに10秒以上滞在している人物が検知されました。
0806010a0308	01/06/2026, 10:14:56 AM	area_10	person	low	Intrusion	エリアBに人物が検知されました。
030e02040806	01/06/2026, 10:14:46 AM	area_9	person	high	Crowd	エリアAに2人が検知されました。
00c0b0c0d009	01/06/2026, 10:12:47 AM	area_2	person	high	Intrusion	エリアDに10秒以上滞在している人物が検知されました。
09c055060b04	01/06/2026, 10:12:27 AM	area_5	person	high	Intrusion	エリアCに10秒以上滞在している人物が検知されました。
000800040c08	01/06/2026, 10:12:16 AM	area_10	person	low	Intrusion	エリアBに人物が検知されました。
0a0108060b09	01/06/2026, 10:12:11 AM	area_9	person	high	Crowd	エリアAに2人が検知されました。
01040e060a02	01/06/2026, 10:12:07 AM	area_9	person	high	Crowd	エリアAに2人が検知されました。
060904070a02	01/06/2026, 10:10:40 AM	area_2	person	low	Intrusion	エリアDに人物が検知されました。
0e0b08090a09	01/06/2026, 10:10:30 AM	area_2	person	high	Mask	エリアDにマスクを着用した人物が検知されました。
0a0b0e0c0709	01/06/2026, 10:10:16 AM	area_5	person	high	Intrusion	エリアCに10秒以上滞在している人物が検知されました。

Event Preview [Image] [Video] [Show Raw Data] [Download Event]

EVENT ID: 01050e08-0801-0e09-0809-0c0805030c0c

TIMESTAMP: 01/06/2026, 10:06:39 AM

RISK LEVEL: low

TYPE: person

LOCATION: area_9

DEVICE ALIAS: 87A528AC2F3AD1CCCF9F7289818D1464

SUMMARY: エリアAに人物が検知されました。

CONFIDENCE: 88.99%

EVENT CATEGORIES:

図 8.4-7 検知・評価データの例

- SLM のファインチューニング用のデータセット(データ量が多いため、一部のみ添付する)

- ファインチューニング用データセット - 異常レポート要約用のデータ:

モデルへの入力となる指示プロンプト(prompt)と、モデルが生成すべき正解出力(completion)のペアで構成されている。フィールド”prompt_type”はスクリプトがレポート要約用のプロンプトを取得する際の種別(異常レポート/定期レポート)を示す。

あなたは、10個のエリアに設置された監視カメラから送信されるテレメトリデータを分析する専門家です。各カメラからJSON形式のテレメトリデータが提供されます。あなたのタスクは、これらのJSONデータに基づいて簡潔な要約を作成し、異常の状況を報告することで、

※要約に必要なデータは以下の通りです（推測や、JSONにない情報は一切追加しないでください。）：

- * "type": 発生したイベントの種類を示します。現在は"single_person", "multi_person", "fire", "none"の3種類のイベントがあります。
 - * "single_person": 1人が検出されたこと
 - * "multi_person": 複数人が検出されたこと
 - * "fire": 煙・炎が検出されていること
- * "location_id": カメラが監視しているエリア番号を示します。（"area_x"はエリアxを示しています）。
 - * "area_1": エリア1
 - * "area_2": エリア2
 - * "area_3": エリア3
 - * "area_4": エリア4
 - * "area_5": エリア5
 - * "area_6": エリア6
 - * "area_7": エリア7
 - * "area_8": エリア8
 - * "area_9": エリア9
 - * "area_10": エリア10
- * "detection_count": カメラで検出された人数を示します。例: "detection_count": 3のとき、3名の人物が検出されたことを示します。
- * "details": 検出された人物の詳細情報が含まれます。
 - * {"mask"}: 検出された人物がマスクを着用かどうかを示します。trueの場合、検出された人物はマスクを着用しています。
 - * {"duration_long"}: 検出された人物がカメラ画面に10秒以上滞在しているかどうかを示します。trueの場合、検出された人物がカメラ画面に10秒以上滞在しています。
 - * {"child"}: 検出された人が子供（10歳未満）かどうかを示します。trueの場合、検出された人物は10歳未満の子供です。
 - * {"senior"}: 検出された人が高齢者（70歳以上）かどうかを示します。trueの場合、検出された人物は70歳以上の高齢者です。
 - * {}: 詳細情報がなく、ただ1人が検出されたことを示します。

要約ルール:

1. 出力する要約は短い一文で記述してください。

2. 1人だけが検出された場合、その人物の詳細情報を要約に追加してください。{"details" が{}}の場合、要約は「エリアxに人物が検出されました。」のみです。）

- 例1: "location_id"が"area_1", "type"が"single_person", "details"が{"mask": true}の場合、「エリア1にマスクを着用した人物が検出されました。」と要約してください。
- 例2: "location_id"が"area_10", "type"が"single_person", "details"が{"duration_long": true}の場合、「エリア10に10秒以上滞在している人物が検出されました。」と要約してください。
- 例3: "location_id"が"area_3", "type"が"single_person", "details"が{"child": true}の場合、「エリア3に10歳未満と見られる人物が検出されました。」と要約してください。
- 例4: "location_id"が"area_2", "type"が"single_person", "details"が{"senior": true}の場合、「エリア2に70歳以上と見られる人物が検出されました。」と要約してください。
- 例5: "location_id"が"area_9", "type"が"single_person", "details"が{}の場合、「エリア9に人物が検出されました。」と要約してください。

3. 2人以上が検出された場合、詳細情報は不要で検出された人数を報告してください。

- * 例: "location_id"が"area_1", "detection_count"が3の場合、「エリア1に3人が検出されました。」と要約してください。

4. "type"が"fire"の場合、どのエリアに炎が検出されたかを要約してください。

- * 例: "location_id"が"area_4", "type"が"fire"の場合、「エリア4に煙・炎が検出されました。」と要約してください。

サンプルテレメトリデータと出力すべき文章:

例1:

* サンプルテレメトリデータ:

```
{
  "type": "single_person",
  "location_id": "area_9",
  "details": {}
}
```

出力すべき文章:

エリア9に人物が検出されました。

例2:

* サンプルテレメトリデータ:

```
{
  "type": "single_person",
  "location_id": "area_10",
  "details": {
    "mask": true,
  }
}
```

出力すべき文章:

エリア10にマスクを着用した人物が検出されました。

例3:

* サンプルテレメトリデータ:

```
{
  "type": "single_person",
  "location_id": "area_1",
  "details": {
    "child": true
  }
}
```

出力すべき文章:

エリア1に10歳未満と見られる人物が検出されました。

例4:

* サンプルテレメトリデータ:

```
{
  "type": "single_person",
  "location_id": "area_4",
  "details": {
    "senior": true
  }
}
```

出力すべき文章:

エリア4で70歳以上と見られる人物が検出されました。

例5:

* サンプルテレメトリデータ:

```
{
  "type": "single_person",
  "location_id": "area_10",
  "details": {
    "duration_long": true,
  }
}
```

出力すべき文章:

エリア10に10秒以上滞在している人物が検出されました。

例6:

* サンプルテレメトリデータ:

```
{
  "type": "multi_person",
  "location_id": "area_3",
  "detection_count": 3
}
```

出力すべき文章:

エリア9に3人が検出されました。

```

例7:
* サンプルテレメトリデータ:
{
  "type": "multi_person",
  "location_id": "area_3",
  "detection_count": 4
}
出力すべき文章:
エリア3に4人が検知されました。

例8:
* サンプルテレメトリデータ:
{
  "type": "fire",
  "location_id": "area_2",
}
出力すべき文章:
エリア2に煙・炎が検出されました。

```

図 8.4-10 異常レポート要約用のシステムプロンプト

▶ 定期レポート要約用のシステムプロンプト

15 分間隔で、エッジサーバが集約した「異常なし」メタデータを入力とし、本システムのプロンプトルールに基づいて定期レポート文を生成する。ファインチューニングデータセット内の「regular」タイプは、学習時に本テキスト内容へ変換する。

```

あなたは、10個のエリアに設置された監視カメラから送信されるテレメトリデータを分析する専門家です。提供されるJSONデータは、異常が検出されなかったエリアの情報を集約したものです。あなたのタスクは、このJSONデータに含まれる`location_id`に基づいて
要約ルール:
1. 出力する要約は短い一文で記述してください。
2. JSONデータに含まれる`location_id`に記載されたエリア番号をカンマ区切りで列挙し、最後に「:異常はありません。」を付けて報告してください。

サンプルテレメトリデータと出力すべき文章:
例1:
* サンプルテレメトリデータ:
{
  "location_id": "area_1, area_2, area_6, area_8"
}
出力すべき文章:
エリア1, 2, 6, 8:異常はありません。

例2:
* サンプルテレメトリデータ:
{
  "location_id": "area_1, area_2, area_3, area_4, area_5, area_6, area_7, area_9, area_10"
}
出力すべき文章:
エリア1, 2, 3, 4, 5, 6, 7, 9, 10:異常はありません。

例3:
* サンプルテレメトリデータ:
{
  "location_id": "area_2, area_8"
}
出力すべき文章:
エリア2, 8:異常はありません。

例4:
* サンプルテレメトリデータ:
{
  "location_id": "area_1, area_2, area_6, area_8, area_9"
}
出力すべき文章:
エリア1, 2, 6, 8, 9:異常はありません。

```

```

例5:
* サンプルテレメトリデータ:
{
  "location_id": "area_3, area_5, area_10"
}
出力すべき文章:
エリア3, 5, 10:異常はありません。

例6:
* サンプルテレメトリデータ:
{
  "location_id": "area_1, area_4, area_5, area_6, area_7, area_8"
}
出力すべき文章:
エリア1, 4, 5, 6, 7, 8:異常はありません。

例7:
* サンプルテレメトリデータ:
{
  "location_id": "area_1, area_2, area_3, area_4, area_5, area_6, area_7, area_8, area_9, area_10"
}
出力すべき文章:
エリア1, 2, 3, 4, 5, 6, 7, 8, 9, 10:異常はありません。

```

図 8.4-11 定期レポート要約用のシステムプロンプト

8.5 第 6 章における効果検証の前提条件及び計算式

番号	効果検証テーマ	項目
1	コスト削減効果	総コスト(導入費用+運用費用)
2	投資対効果(ROI)	業務員負荷軽減の検証

3	投資対効果(ROI)	カメラ設置の柔軟性向上の検証
4	投資対効果(ROI)	消費電力削減効果

8.5.1 総コスト(導入費用+運用費用)

コスト	項目	金額(円)	番号
初期導入	AI システム機材・設備	2,731,675	A-①
	回線工事	0	
運用(5年間)	通信費	142,800	A-④
	ソフトウェアのライセンス	3,690,000	A-⑤
	データの保存	8,000	A-⑥
	電気代	29,828	A-⑦
	人件費	7,600,000	A-⑧
	合計(円)	14,202,303	

- A-① AI システム機材・設備

項目	値	番号	計算式
カメラ台数	10	①	
カメラ本体の購入費用(単価)	64,000	②	
エッジサーバ GPU 含む	486,775	③	
GPU	0	④	
カメラポールマウント 合計金額	154,168	⑤	
ファアエッジデバイス(OOB 有)(単価)	112,000	⑥	
映像保存用 SD カード合計	143,455	⑦	
スイッチングハブ(5ポート)(10 台合計)	45,859	⑧	
スイッチングハブ(8ポート)	8,000	⑨	
機器収納ボックス	29,458	⑩	
LAN ケーブル(500m)	103,960	⑪	
合計(円)	2,731,675		①*②+③+⑤+⑥*①+⑦+⑧+⑨+⑩+⑪

- A-④ 通信費

項目	値	番号	計算式
1 時間あたりデータ送信量 (KB/10 台)	44,022	①	
1ヶ月あたりデータ送信量 (GB/10 台)	32	②	①*24*30*0.000001
導入期間(年)	5	③	
導入期間(ヶ月)	60	④	④*12
月額通信費(楽天モバイル法人データ 30GB)	2,380	⑤	
合計(円)	142,800	⑥	④*⑤

- A-⑤ ソフトウェアのライセンス

項目	値	番号	計算式
導入期間(年)	5	①	
1年当たりソフトウェアのライセンス	738,000	②	
合計(円)	3,690,000	③	①*②

- A-⑥ データの保存

項目	値	番号	計算式
1時間当たりデータ送信量 (KB/10台)	44,022	①	
1ヶ月当たりデータ保存量(GB)	32	②	②*24*30*0.000001
ストレージ費用 (NVME ssd, 500GB)	8,000	③	
合計(円)	8,000		③

- A-⑦ 電気代

項目	値	番号	計算式
1日当たりカメラ10台の消費電力	864	①	3.6Wh*24h*10台
1日当たりサーバ・機器の消費電力	3,947	②	164.47Wh*24h
導入期間(年)	5	③	
電力単価	31	④	
1年当たりスタジアムのイベント数	40	⑤	
合計(円)	29,828		(①+②)/1000*③*④*⑤

※②の計算式に164.47Whはエッジサーバ1台、GPU1台、ファアエッジデバイス10台の消費電力

- A-⑧ 人件費

項目	値	番号	計算式
1年当たりスタジアムのイベント数	40	①	
1日当たり担当者の人件費単価	38,000	②	
導入期間(年)	5	③	
合計(円)	7,600,000		①*②*③

8.5.2 業務負荷軽減の検証

項目	値	番号	計算式
リスクイベント発生頻度(回/日)	120	①	全10箇所、各所とも1日あたり12件が発生する。
通知確認時間(秒/回)	60	②	警備員がアプリでリスクイベントの通知を確認するまでに要する時間
本ソリューションの監視業務員数	1	③	
本ソリューションの業務時間	2	④	①*②/(3600)
現行システムの監視業務員数	5	⑤	①を前提とした、10箇所のリスクイベントを確

			認するのに必要な人数
現行システムの監視業務時間	24	⑥	監視業務員1人当たりの業務時間
1日当たり人件費単価(円/人)	38,000	⑦	ノエビアスタジアム神戸の基準

8.5.3 一般ソリューションのコスト

コスト	項目	固定式カメラ	Wi-Fi型	ローカル5G 新設
初期導入	AIシステム機材・設備	B-①	C-①	D-①
	回線工事(有線)	B-②	-	-
	回線工事(無線)	-	C-③	D-③
運用(5年間)	通信費	-	C-④	C-④
	ソフトウェアのライセンス	-	-	C-⑤
	データの保存	B-⑥	C-⑥	D-⑥
	電気代	B-⑦	C-⑦	D-⑦
	人件費	B-⑧	C-⑧	D-⑧

- B-① AIシステム機材・設備

項目	値	番号	計算式
カメラ台数	10	①	
カメラ本体の購入費用(単価)	64,000	②	
エッジサーバ GPU 含む	486,775	③	
GPU	0	④	
カメラポールマウント 合計金額	154,168	⑤	
ファアエッジデバイス(OOB有)(単価)	112,000	⑥	
映像保存用 SD カード合計	143,455	⑦	
スイッチングハブ(5ポート)(10台合計)	45,859	⑧	
スイッチングハブ(8ポート)	8,000	⑨	
機器収納ボックス	29,458	⑩	
LAN ケーブル(500m)	103,960	⑪	
合計(円)	2,731,675		①*②+③+⑤+⑥*②+⑦ +⑧+⑨+⑩+⑪

- B-② 回線工事(有線)

項目	値	番号	計算式
回線工事(有線)	500,000		HUB×1台、無線アクセス ポイント×1台,150m
合計(円)	500,000		①

- B-⑥ データの保存

項目	値	番号	計算式
----	---	----	-----

本来の1日当たりデータ保存量 (KB/1台)	27,000,000	①	
1ヶ月当たりデータ保存量(GB/1台)	810	②	①*30*0.000001
1ヶ月当たりデータ保存量(TB/10台)	8	③	②*10*0.001
SSD (8TB,1個)	130,000	④	
合計(円)	130,000		④

- B-⑦ 電気代

項目	値	番号	計算式
1日当たりカメラ10台の消費電力	864	①	3.6Wh*24h*10台
1日当たりサーバ・機器の消費電力	3,947	②	164.47Wh*24h
導入期間(年)	5	③	
電力単価	31	④	
1年当たりスタジアムのイベント数	40	⑤	
合計(円)	29,828		(①+②)/1000*③*④*⑤

※②の計算式に164.47Whはエッジサーバ1台、GPU1台、ファールエッジデバイス10台の消費電力

- B-⑧ 人件費

項目	値	番号	計算式
1年当たりスタジアムのイベント数	40	①	
1日当たり担当者の人件費単価	38,000	②	
導入期間(年)	5	③	
監視業務員(人/日)	3	④	
合計(円)	22,800,000		①*②*③*④

- C-① AIシステム機材・設備

項目	値	番号	計算式
無線LANアクセスポイント(AP)16基5年間ライセンス料(円)	2,400,000	①	Juniper Mist AP63-WW
PoE給電用LANケーブル	1,800,000	②	
カメラ本体の購入費用	506,000	③	カメラ1台当たり50,600円
合計(円)	4,706,000		①+②+③

- C-③ 回線工事(無線)

項目	値	番号	計算式
役務費(現地調査費、設計費、工事費等)	10,500,000	①	
測定・試験費用	750,000	②	
合計(円)	11,250,000		①+②

- C-④ 通信費

項目	値	番号	計算式

月額通信費(回線使用料)5年分	561,000	①	月額利用料 9,350 円* 12ヶ月*5年
1日当たりデータ送信量(TB/10台)	8	②	B-⑥を参照
合計(円)	11,250,000		①+②

- C-⑥ データの保存

項目	値	番号	計算式
1ヶ月当たりデータ保存量(GB/1台)	150	①	録画データ量: 1台あたり 5GB/日 ∴ 5GB*30日(商 用化製品の例)
1ヶ月当たりデータ保存量(TB/10台)	1.5	②	①*10台
導入期間(年)	5	③	
導入期間(ヶ月)	60	④	③*12
5年間データ保存量(TB)	90	⑤	②*④
録画30日間プラン10台分/5年間	1,320,000	⑥	商用化製品の参照
合計(円)	1,320,000		⑥

- C-⑦ 電気代

項目	値	番号	計算式
1日当たりカメラ10台の消費電力	3,000	①	12.5Wh*24h*10台 (3.0A/台)
1日当たりサーバ・機器の消費電力	9,995	②	416.47*24h
導入期間(年)	5	③	
電力単価	31	④	
合計(円)	735,192		(①+②)/1000*31*365* ③

※②の計算式に 416.47Wh はエッジサーバ1台、GPU1台、ファアーエッジデバイス10台、AP10台の消費電力

- C-⑧ 人件費

項目	値	番号	計算式
1年当たりスタジアムのイベント数	40	①	
1日当たり担当者の人件費単価	38,000	②	
導入期間(年)	5	③	
監視業務員(人/日)	3	④	
合計(円)	22,800,000		①*②*③*④

- D-① AIシステム機材・設備

項目	値	番号	計算式
CU, DU, UPF, L3SW	11,594,000	①	
RU・アンテナ利用料、インドア RU(アンテナ一体)	1,056,000	②	
アンテナカテゴリ1	440,000	③	
基地局設備(5G)	13,090,000	④	①+②+③
ローカル 5G 端末(カメラ)	2,562,210	⑤	10 台 *256,221, Milesight 5G AIoT Network Camera
設置関連資材	990,000	⑥	
AXIS/P1385-E&faredge を 5G 対応とする場合の HW 費用(Wi-Fi 化の一部相当)	2,300,000	⑦	
合計(円)	18,942,210		④+⑤+⑥+⑦

- D-③ 回線工事(無線)

項目	値	番号	計算式
役務費(現地調査費、設計費、工事費等)	1,342,000	①	光回線 初期工事費(標準的な工事の場合)22,000 円 機器設置工事費等 1,320,000 円 ※1
測定・試験費用	880	②	契約料(1 契約ごと) 880 円
合計(円)	1,342,880		①+②

- D-④ 通信費

項目	値	番号	計算式
月額通信費(回線使用料)5 年分	561,000	①	9,350*12 か月* 5 年
1 日当たりデータ送信量 (KB)	1,056,528	②	表 8-1 を参照
合計(円)	11,250,000		①+②

- D-⑤ ソフトウェアのライセンス

項目	値	番号	計算式
基本利用料(月額利用料)	113,300	①	
RU・アンテナ利用料 インドア RU(アンテナ一体)月額利用料	8,800	②	
導入期間(5年間,60 ヶ月)	60	③	
合計(円)	7,326,000		(①+②)* ③

- D-⑥ データの保存

項目	値	番号	計算式
1ヶ月当たりデータ保存量(TB/10台)	8	①	表 8-1 を参照
Cloud ストレージ費用 (100TB/年), Amazon S3, 184\$/a month	26,680	②	184\$*145円
導入期間(5年間,60ヶ月)	60	③	
合計(円)	1,600,800		②*③

- D-⑦ 電気代

項目	値	番号	計算式
1日当たりカメラ10台の消費電力	2,400	①	
1日当たりサーバ・機器の消費電力	9,480	②	CU/DU 一体型: 300W L3 スイッチ本体: 80W その他: 15W 300W+80W+15W=395W
導入期間(年)	5	③	
電力単価	31	④	電力単価: 31円/kWh
1日当たり基地局消費電力	1,680	⑤	RU: 70W アンテナ一体型 RU
合計(円)	767,157		(① + ② + ⑤)/1000*④ *365*③

- D-⑧ 人件費

項目	値	番号	計算式
1年当たりスタジアムのイベント数	40	①	
1日当たり担当者の人件費単価	38,000	②	
導入期間(年)	5	③	
監視業務員(人/日)	3	④	
合計(円)	22,800,000		①*②*③*④

8.5.4 通信費削減

表 8-1 通信費削減計算式

項目	値	番号	計算式
定期報告送信回数(回/1日)	96	①	4 = 定期報告送信回数(回/時間)
定期報告テキストサイズ(KB)(仮)	0.5	②	

異常報告テキストサイズ(KB)(仮)	2	③	
平均画像サイズ(KB)	450	④	
平均映像サイズ(KB)	3500	⑤	
低リスクイベント発生頻度(回/1日)(仮)	12	⑥	
高リスクイベント発生頻度(回/1日)(仮)	12	⑦	
映像送信ビットレート(Mbps)	2.5	⑧	解像度 1080p (Full HD)、圧縮方法 H.264(Standard)、15FPS の場合 2.5Mbps
本来の1日当たりデータ送信量 (KB)	27000000	⑨	(⑧ * 86400sec/8*1000)
1日当たり受信画像サイズ	5400	⑩	④*⑥
1日当たり受信映像サイズ	42000	⑪	⑤*⑦
1日当たり受信テキストサイズ(定期報告)	48	⑫	①*②
1日当たり受信テキストサイズ(イベント)	48	⑬	③*(⑥+⑦)
1日当たり受信データサイズ合計(KB)	47496	⑭	⑩+⑪+⑫+⑬
通信量削減率	0.998240889	⑮	1-⑭/⑨
月額通信費(楽天モバイル法人データ 30GB)	2380	⑯	
通信費削減率			⑮*⑯

8.6 その他、当該システムを再現する上で参考となる資料

本文内にて参照資料やウェブサイト、出典を記載済。詳細は各章を参照のこと。

8.7 広報活動実績

本取り組みは報道発表やプレスリリースの他、多数のマスメディアでも取り上げられた。その中でも9月に川崎ひでと政務官にノエビアスタジアム神戸で実証デモンストレーションを視察いただき、講評をいただけたことは大きな実績と考える。その他、各種通信関連のイベント等での登壇や展示会でのパネル展示を行い、多方面で広報活動を行った。詳細は以下の通り。

	掲載日	掲載元	公開内容(タイトル)/URL
報道発表	2025/06/24	楽天モバイル株式会社	楽天モバイル、AWL、ヴィッセル神戸が総務省の「地域社会 DX 推進パッケージ事業(AI 検証タイプ)」における実証団体に採択 https://corp.mobile.rakuten.co.jp/news/press/2025/0624_01/

	2025/06/24	楽天モバイル株式会社	Rakuten Mobile, AWL and Vissel Kobe Selected for MIC Project Using Edge AI to Improve Safety in Large-scale Facilities https://corp.mobile.rakuten.co.jp/english/news/press/2025/0624_01/
	2025/06/25	AWL 株式会社	AWL、楽天モバイル、ヴィッセル神戸が 総務省の「地域社会 DX 推進パッケージ事業(AI 検証タイプ)」における実証団体に採択 https://awl.co.jp/news/20250625/
メディア	2025/06/24	BUSINESS NETWORK	楽天モバイルとヴィッセル神戸らがエッジ AI による大規模施設監視を実証、通信負荷の最適化目指す https://businessnetwork.jp/article/28587/
	2025/06/25	PR TIMES	AWL、楽天モバイル、ヴィッセル神戸が総務省の「地域社会 DX 推進パッケージ事業(AI 検証タイプ)」における実証団体に採択 https://prtimes.jp/main/html/rd/p/000000068.000046547.html
	2025/06/25	日刊工業新聞	楽天・AWL、大規模施設監視 ネット輻輳改善 https://www.nikkan.co.jp/articles/view/00752790
	2025/07/03	日経新聞電子版	北海道大学発 AWL など、ノエビアスタジアム神戸で監視システム実証事業 https://www.nikkei.com/article/DGXZQOFC2647B0W5A620C2000000/
	2025/07/04	日経新聞朝刊	監視システム効率化実証 AWL など 神戸のスタジアムで
	2025/07/16	日経 MJ	AI でスタジアム監視 実証 https://www.nikkei.com/article/DGKKZO90034960V10C25A7HD2A00/
	2025/09/19	ヴィッセル神戸	公式X「総務省政務官ご来訪 AI×通信で安心安全なスタジアムへ！」 https://x.com/visselkobe/status/1969002209200472410?s=46
	2025/09/20	川崎政務官	公式X

			https://x.com/kawasaki_hideto/status/1969204565380681870?s=46&t=pM2xniAyhOx4cwx7luugDQ
	2025/09/19	川崎政務官	Instagram https://www.instagram.com/p/DOzgGMknL3/?igsh=Nm95N3JzNGh6OXZ4
	2025/09/20	川崎政務官	note 「【視察報告】ノエビアスタジアム神戸での AI 実証実験」 https://note.com/kawasaki_hideto/n/n71ba50dbc57d
その他	2025/07/31	COMNEXT セミナー登壇	大規模 Open-RAN 商用ネットワークへのAI活用 https://biz.g-pass.jp/f/11183/comnext25_seminar/seminar_register
	2025/09/19	総務省	Web サイト「大臣・副大臣・大臣政務官の動き」 https://www.soumu.go.jp/photo_gallery/02ko_ho03_03005387.html
	2025/10/03- 2025/10/04	YRP オープンイノベーションデー	パネル展示 https://yrp.co.jp/event/open_innovationday_2025/
	2025/10/14	総務省	地域社会 DX ナビ 大規模施設の防犯 AI、脱「中央集権」の画像データ処理へ https://dx-navi.soumu.go.jp/support/dx_package/demonstration/article/001
	2025/10/15	CEATEC セッション登壇	5G/ローカル 5G の進化と発展～5G の国内外状況と展望～ 「5G 導入状況と今後の展望」 https://www.ceatec.com/ja/conference/detail.html?id=2987
	2025/10/16	CEATEC セッション登壇	5G 高度化、6G 最新状況と展望～6G and AI～ 「Beyond 5G における OpenRAN 無線通信技術の研究開発について」 https://www.ceatec.com/ja/conference/detail.html?id=3180

	2025/11/26	SSS 異分野融合 マッチングワーク シヨップ 2025年 秋	パネル展示 https://www.sss.e.titech.ac.jp/event/sss-matching-workshop-20251126/
	2026/1/19	Rakuten Career Conference 2026	パネル展示 https://corp.rakuten.co.jp/careers/graduates/event/rakutencareerconference-2026/

8.8 参考文献

本文内にて参照資料やウェブサイト、出典を記載済。詳細は各章を参照のこと。

地域社会 DX 推進パッケージ事業(AI 検証タイプ)

AI を用いた通信負荷の低減・通信量の確保等の検証に関する調査研究

(実証機関:楽天モバイル株式会社)

実証報告書

[スタジアムにおける人流監視のためのエッジ AI を用いた通信量削減の実証]

2026 年 1 月

AI04 神戸市

楽天モバイル株式会社

AWL 株式会社・ヴィッセル神戸株式会社
