

ARUBA AIOps のメリット

ネットワーキング・オペレーションの効率性
と有効性を向上させるデータ、データ科学、
専門分野の知識、実証された結果

ARUBA AI フレームワーク	3
ネットワーク環境因子を活用して信頼性の高いオートメーションを提供	4
ピア・グループを使用したネットワーク設定の最適化	6
すべて統合: 実践的な推奨事項を提示する AI インサイト	8
まとめ。AI + オートメーション = 頼りになる AIOps	10



モダンなネットワーキング・インフラストラクチャはネットワーク・サイズ、トラフィック量、多様なデバイスとアプリケーションの増大により非常に複雑になっています。これらのネットワークを手動で構成することは時間がかかり、エラーが発生しやすく、増え続ける IoT デバイスや、リモート・エッジからブランチ、キャンパス、データセンターへの分散型接続に対応するのは困難です。こうした問題を効率的に対処すべく、ネットワーク・オペレーターはオペレーションとユーザーの豊富なインサイト、さらには、オペレーターがネットワーク管理で考慮しうるあらゆる面をカバーし、知識すべてを広範囲に、今日の複雑さを増す環境に適用できる AI 駆動型のインテリジェントなオートメーションを求めています。

Aruba AIOps のメリットの基盤には優秀な AI があります。この AI は、Aruba がネットワーキングとセキュリティのテクノロジーにおける深い知識とデータ科学における功績の歴史から生まれたものです。グローバル企業から新興企業による導入まで、あらゆる業界および地域で小さなビルからキャンパスやスタジアムまで、毎日数十億のデータ・ポイントを生成する数万の導入環境から長い年月をかけて収集されてきたインサイトとデータを活用し、データ科学者の強力なチームにより開発されました。このデータと AI テクノロジーへの投資による産物は、ほんの数か月で再現できると宣伝する向きもありますが、数か月はおろか、数年でも再現できるものではありません。小規模な顧客基盤で短期間で提供される限られたデータでは信頼に足らない AI が生まれるだけです。Aruba AI なら、長い年月の学習の成果と、顧客が実証したソリューションを、導入第一日目から利用できます。

この AI 分析とアクションの融合が、AIOps です。AIOps は、数千以上の顧客環境での導入により実証されたデータ主導の成果によってのみ実現可能で、高精度のインサイトと推奨事項を個々の顧客環境に十分に提供できる包括的な次世代のネットワーキング AI ソリューションです。

このホワイトペーパーでは、Aruba がどのように AI 駆動型自己最適化ネットワークの基盤となる構成要素を提供し、顧客のネットワーキング課題の解決に信頼できる方法で取り組んでいるか解説します。

ARUBA AI フレームワーク

自己最適化ネットワークの目的は、ユーザーに安定した接続を提供し、ユーザーのトラフィック需要に応えながら、これによりユーザーが高品質のサービスを体験できるようにすることです。現実には、これは人間が感じる感覚ですから、ユーザー・エクスペリエンスを自動的に測定することは極め

AI の ROI

最近、「通行人による」トラフィックの増大がネットワーク・パフォーマンスの低下に影響していると思われるケースがありました。しかし、この顧客の環境は、こうした問題を手作業で診断し、修正するために必要なデータやベンチマークを備えていませんでした。そこで Aruba AI インサイトを導入すると、問題はすぐに検証され、推奨される構成変更により不要な「通行人トラフィック」を 98% 減らすことにより、実際に利用しているユーザーとデバイスの接続を維持できるようになりました。結果として、ハードウェアを追加する必要なく無線環境の能力が 25% 以上向上しました。

て困難です。Aruba では AI を構築、育成、評価するために、スループット、レイテンシー、リソース効率といった直接測定可能な代用指標を用いています。各ユースケースに応じて指標を選び、ネットワークが適切に機能しているか、他のネットワークと比べてどのようなパフォーマンスを達成できているかを数字で表します。

そして選択した指標に**影響する因子**を特定し、2 種類に分類します。AI が制御できるものと (制御可能因子)、そうでないもの (環境因子) に分けられます。

Wi-Fi ネットワークにおけるアクセス・ポイントの無線伝送パラメーターの最適化を例にとってみましょう。制御可能因子としては、RF チャンネル帯域幅や RF 送信パワーレベルなどがあります。Wi-Fi アクセス・ポイントのハードウェアは、これら因子のさまざまな設定で稼働できます。どの設定が最適か、その判断を AI に委ねることにします。

環境因子としては、導入環境における隣接アクセス・ポイント間距離、カバレッジ・エリアにおける建物の資材により異なる RF 信号の伝搬特性、接続するクライアント・デバイスの RF 特性、などが考えられます。これらの因子は、AI が自由に変更するというわけにはいきません (これらは経時的に変化する因子でもあります)。

測定可能な目的関数、そしてその計算に使用される制御可能因子および環境因子を定義して、ネットワークに組み込み、**データを継続的に収集し**、クラウドに報告します。これによりクラウドの AI は、ネットワークごとに、そして時間単位ごとに、ネットワークの稼働状況、制御可能因子の現在の設定、そして環境因子の現在の値を把握できます。



パフォーマンスを客観的に評価できるよう、各ネットワークをピア・グループの中でランク付けします。ピア・グループとは、共通の環境因子を持つネットワークの集まりです。例えば、ピア・グループにおいて 10 パーセントのネットワークは、ピア・グループの 90% よりもパフォーマンスが劣っていることを意味します。ピア・ネットワークの間の主な違いは、制御可能因子の設定の違いであるため、AI アルゴリズムが制御可能因子を調整することによってネットワークのランクを上げることができます。

制御可能因子の最適な設定は、次の 2 つのモードのいずれかで判定されます。

教師あり学習モードでは、すべてのネットワークの過去データが抽出されて AI モデルに流し込まれます。その AI モデルは、現在の環境因子、そして制御可能因子に可能なあらゆる設定に基づいて、ネットワークの目的関数値を予測します。これらの予測を使用すれば、可能なあらゆる設定の中から最適な設定を見つけ出すことは簡単です。このモードでは、AI は その時点で利用可能なデータに潜在する知識を活かして、ネットワークを最適化します。

一方、アクティブ・ラーニング・モードでは、AI は過去のデータからは得られない新しい知識を活用できます。目的に沿って慎重に、制御可能因子の値を、これまで試したことがない組み合わせとなるように設定します。このモードでは、AI は未知の最適化の可能性を探ります。

AI 駆動型自己最適化ネットワークの**基盤となる構成要素**は、効果的で測定可能な目的関数、制御可能因子と環境因子、多様で大規模なデータ・コレクション、比較するピア・グループの定義、個々のオペレーション環境に応じて制御可能因子の最適な割り当てを自動的に選択する AI モデルとアルゴリズムです。

ネットワーク環境因子を活用して信頼性の高いオートメーションを提供

ネットワークの環境因子は AIOps の主要要素です。ネットワークの制御不可能な特性を表しています。外部環境パラメーターとして AI によるアクションのために使用されるデータです。環境因子は、AI が最適化できる影響範囲を定義するものです。

データはなぜこれほど重要視されるのでしょうか？

人工知能の原理は、数学モデルが、処理されるデータの継続的なトレーニングに基づいて特定のタスクを実現するために学習するものであることは良く知られています。機械学習モデルを育てるために、データが正確でなかったり、少なかったりすると、そのモデルは役に立ちません。例えば、小規模なオフィスからしかデータが収集されないネットワーク管理モデルでは、大規模で複雑な環境では信頼に足るものではありません。犬の写真を認識するために設計されたモデルを例にとってみましょう。茶色の犬の写真に集中して訓練されたモデルでは、黒色の犬の写真を認識できません。これはネットワークについても同様です。AI がネットワークに適した十分なデータに基づいていない構成の変更ばかりしては、パフォーマンスの改善を期待できません。

この概念を具体的に説明するために、特定の環境因子を取り上げ、これが何を意味し、どのように測定されるか見ていきましょう。Aruba Central AI インサイトの主要機能である、Wi-Fi ネットワークの自動パフォーマンス最適化を例にとります。

ここでは、物理環境、ネットワーク・レイアウト、ユーザーの動作、トラフィック特性を捕捉する 4 種類の環境因子があります。

物理環境を表す因子は、Wi-Fi インフラストラクチャの観点から見たアーキテクチャ、間取り、建物の資材に関連するものです。まず、建物の面積、これは平方フィートで測定され、重要な因子であることは明らかです。Wi-Fi アクセス・ポイントが設置された階がわかっている場合、天井による Wi-Fi 信号の影響が測定可能です (天井を通過する信号の損失)。あらゆる建物の資材による信号伝搬への影響は、伝搬損失指数により測定可能です。これは、Wi-Fi 信号強度が減衰する平均指数です。

ネットワーク・レイアウト因子は、導入されるネットワーク・インフラストラクチャの構成に関連します。これには Wi-Fi アクセス・ポイントの密度とアクセス・ポイントの Wi-Fi ハードウェア機能が含まれます。エンドユーザーの視点を得るために、アクセス・ポイント側で受信したクライアント・デバイスの信号強度を測定し、時間、スペース、クライアントごとに未加工データを集計し、通常のアップリンク SN 比を計算します。最後に、他の Wi-Fi 機器によるリソース競合レベルがアクセス・ポイントの管理対象外アクセス・ポイントの密度として捕捉されます。

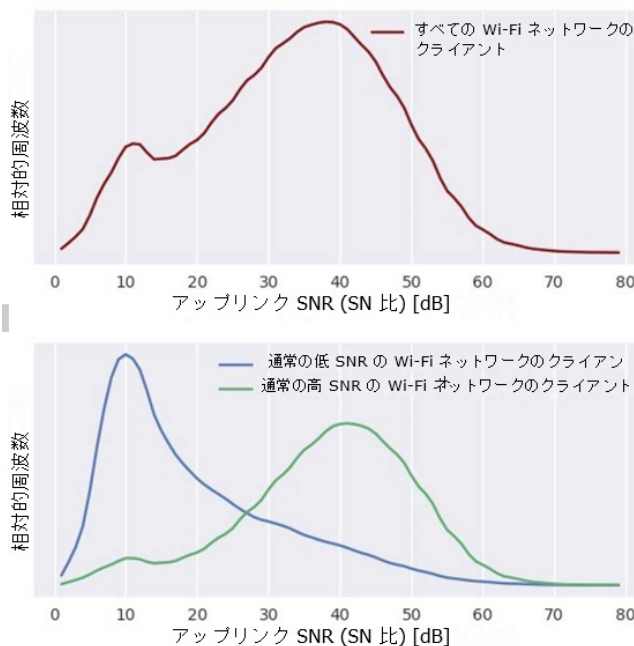
ユーザーの行動を表す因子には、ピーク・クライアント密度が含まれます。これは、ネットワークはかかりうる最大の負荷と、ユーザーの動作を数値化する通常のクライアント滞留時間を処理できるよう設計されている必要があるためです。クライアント・デバイスの統計情報は、ノート PC、スマートフォン、IoT デバイス、(旧式の Wi-Fi プロトコルを使用する) レガシー・デバイスといったカテゴリに、クライアント・デバイスの種類別に分類されます。

最後に、**トラフィック特性**は、ネットワークで実行しているアプリケーションの種類を捕捉します。これには、接続クライアントあたりの通常のトラフィック量とアプリケーション・タイプ別のトラフィック構成が含まれます。これら

の機能により、AI は、ユーザー・エクスペリエンスに直接影響を与えるアプリケーションに優先的にネットワーク・リソースを割り当てることができます。

これらすべての環境因子により 自己駆動型ネットワークをサポートする AIOps の影響範囲を定義します。同じ環境因子をもつ導入ならその影響範囲も同じで、これによりピア・グループが自然と生まれ、ネットワーク間のベンチマークに活用できます。AI が同じ環境で働いているなら、そのパフォーマンスも毎回同じであるはずですが。

Aruba のネットワーキング・ハードウェアは、環境因子の高精度測定のために未加工データを提供することを重視して設計されています。Aruba のクラウド・アーキテクチャは、すべての顧客ネットワークで環境因子の設計、実装、検証をサポートしており、これらの因子はくまなく計算され、(似通った因子ばかりでなく) さまざま物理的な影響を考慮し、ネットワーク・パフォーマンスに選択した指標との高い関連性を維持しています。Aruba の AIOps は、ハードウェアとクラウド・インフラストラクチャ上に構築され、環境因子を計算してこれらを有益なピア・グループに変換し、個々の顧客ネットワークを最適なオペレーティング・ポイントで実行します。



すべてのネットワークにおいて、クライアントからアクセス・ポイントの SN 比 (アップリンク SNR) は広く変化し、2つのモードに分けられます (上の図)。各ネットワークは、通常のアップリンク SNR により特徴付けることができます。類似のネットワークのグループ化により、同じグループのネットワーク間の同種比較が可能となり、2つのモードに分けられます (下の図を参照)。



ピア・グループを使用したネットワーク設定の最適化

さまざまなサイトの挙動とパフォーマンスの数値化に使用可能な環境要素について説明しました。続いて、どのようにこれらの環境要素を使用してサイトをピア・グループにクラスタリングするか説明しましょう。


かつてないほどモバイル・デバイスは積極的に使用されており、データ・トラフィックは限りなく増え続けています。昨今では、信頼性の高いネットワークだけでは対応しきれなくなりました。特定のユースケースに合わせて最適化できるネットワークが求められています。最適化については次のセクションで詳しく説明します。ここでは、AI がお客様のネットワーク・パフォーマンスを改善するために必要な条件、**ピア・グループ**の定義について見ていきましょう。

最も基本的なレベルのピア・グループは、特定のネットワークの比較とベンチマークが行われる、ネットワーク、サイト、さらには AP (アクセス・ポイント) のグループです。すべてのネットワークをお互いに比較することも確かに可能で


すが、実際にはそれほど有効ではありません。ローカルの小さなカフェのオペレーション環境は、大きな大学や病院の環境とは異なると思われます。これらの環境は区別して比較することが望ましいでしょう。また、AIOps 機構が、こうした比較から学習して、ピアの設定やパフォーマンスに基づいてパフォーマンス改善に推奨される方法を提示することができます。こちらは Aruba のサイトのサブセットの AIOps 環境ピア・グループ・クラスタリングのワンパス平面図です。

左側の図はクラスタの自動グループ化を示しており、Aruba のサイトは異なる環境を展開していることがわかります。右側の図は、それぞれ大学とレストランを示す黒色と茶色の十字を追加して、市場と顧客業界の特徴を表しています。十字はピア・グループ・クラスタリングについて何も知らないため、十字が少数のクラスタにグループ化されることは、それぞれのサイトは異なる環境があるといった推測を裏付けるものです。

環境別のサイトのピア・グループ・クラスタリングの図




環境別のサイトのピア・グループ・クラスタリングと数値ラベルの図



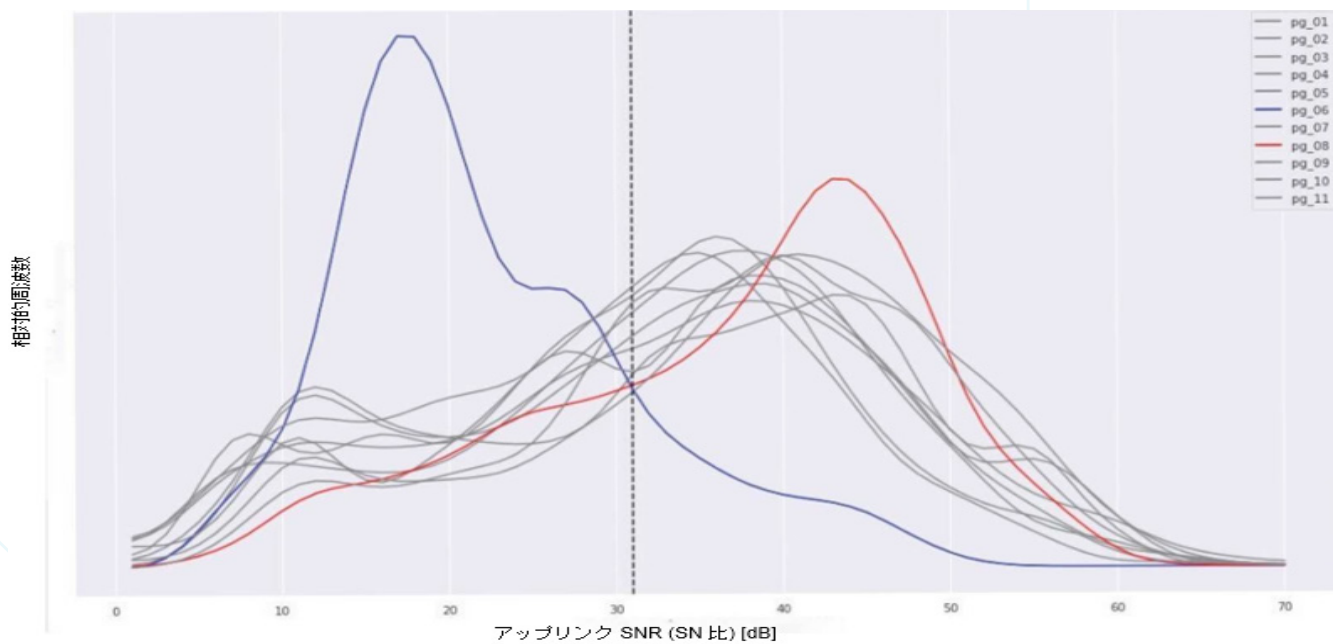


類似の環境をグループ化できることは素晴らしいことですが、広範な影響は何でしょうか？前のセクションのアップリンク SNR (SN 比) の例を再び見てみましょう。



これは、あるお客様の多くのサイトで AP に接続されているクライアント・ステーションの平均アップリンク SNR です。前述の通り、複数のモードがあり、一部のクライアント・ステーションは低アップリンク SNR、その他は高アップリンク SNR で接続されています。お客様のサイトの一つにおいてク

ライアント・ステーションが 31 dB の平均アップリンク SNR (黒色の点線) の場合、これは良いことでしょうか？実際、これは全体分布図の中央にあります、言えることはそれだけです。しかし、Aruba AIOps ワークフローにより作成されたピア・グループを使用してデータをさらに活用できます。



ここでは、お客様のサイトが実際は、異なる多くの環境ピア・グループに分類されることがわかります。(注: これは、高次元空間のほんの一片であるため、多くの分布図が同様であると思われます。)2つのグラフ線が際立っており、ピア・グループ6と8がそれぞれ青色と赤色で表示されています。大まかに説明すると、ピア・グループ6は、屋外拠点に設置された古いAPで、ピア・グループ8は、混合モデルと中規模環境の導入で構成されています。クライアント・ステーションが31 dBの平均アップリンクSNRである、上記と同様のテストサイトは、ピア・グループ6では73パーセンタイルですが、ピア・グループ8では21パーセンタイルとなるでしょう。この情報から、お客様は、問題のサイトに注視できます。さらに、次のセクションでご紹介するように、Aruba AIOps ソリューションでは、サイトとそのピアの相対的パフォーマンスを使用してサイトの機能を改善し、最適化するための変更点や改善点を提示することもできます。

ピア・グループを AIOps ソリューションに追加することにより、より正確なサイトの相互比較が可能となり、ピアのパフォーマンスや設定に基づいて、サイトまたはネットワークの改善に推奨される方法を提供する機能を構成する重要な要素となります。Aruba Central を使用してテラバイト規模のデータが継続的に収集され、数千サイトのプロファイルが作成されるため、最適な結果へと推奨事項を高度に調整することができます。

すべて統合: 実践的な推奨事項を提示する AI インサイト

強力な AI フレームワーク、環境データやピア・クラスタリングの使用に関する説明に続いて、どのようにこれらの技術を統合して信頼性が高く実用的な AI インサイトをお客様に届けているか解説します。Aruba AI インサイトは、さまざまな有線、無線、WAN インフラストラクチャにおいて問題に速やかに対処し、問題を予防し、ネットワークを継続的に最適化するために IT チームが必要とする分析、データ、推奨事項を提供します。

AI インサイトの性能とその仕組みについて説明するために、重要な概念である、「エアタイム効率」を定義します。「**エアタイム効率**」は、アクセス・ポイント (AP)、建物、さらにはお客様全体の総合的な Wi-Fi パフォーマンスの測定に使用される Aruba の指標です。アクセス・ポイントが、多くのクライアント・デバイスがアクセス可能な帯域で高速の高 SNR リンクを提供している場合、エアタイム効率が高いと言えます。

エアタイム効率の例として、下の図1の2つのAP (「AP A」は赤色、「AP B」は青色) を見てみましょう。これらの AP は同じモデル、類似の環境で導入されており、接続する1日あたりのクライアント・ステーション数もほぼ同じです。ある日における、エアタイム効率に関連した2つの指標を見えます。クライアント・アップリンク SNR (SN 比) とクライアント・アップリンク速度です。

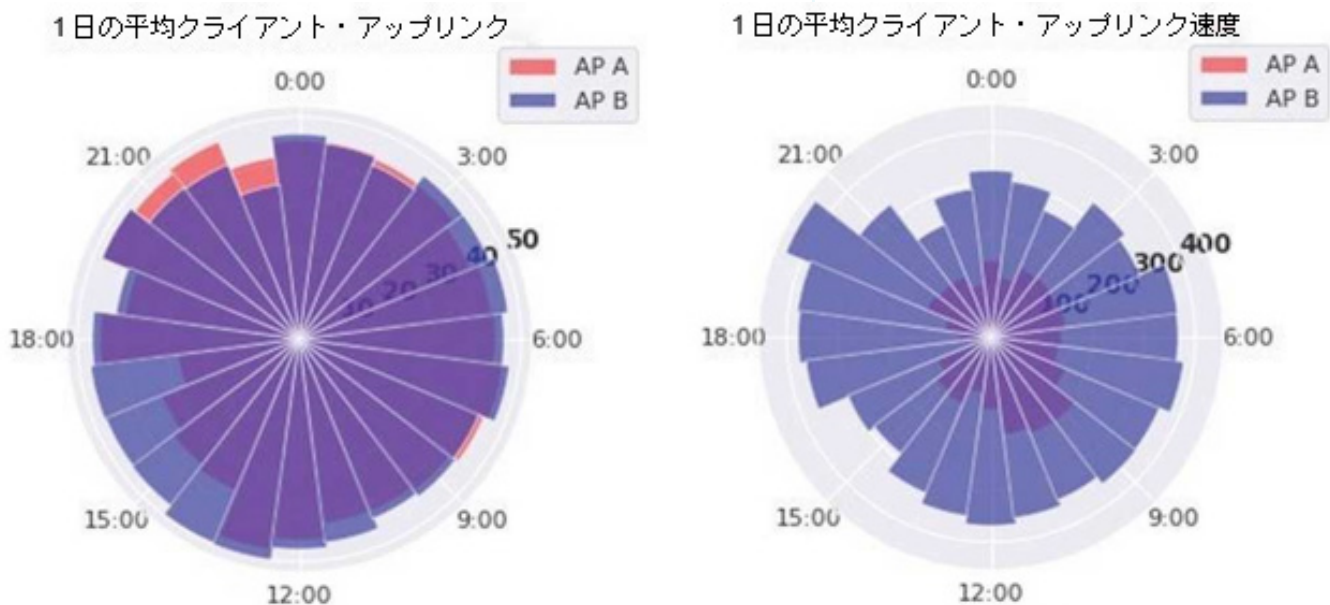


図1 (左): ある1日の時間別に見た、すべての接続クライアントの平均クライアント・アップリンク SNR。
 (右): ある1日の時間別に見た、すべての接続クライアントの平均クライアント・アップリンク速度。



2つのAPはSNRにおいてはかなり密接しており、1日の多くは、平均30～40dBとなっています。APBの方がAPAよりも優れている時間帯はありますが、1日を通して見たときにそれほど重要ではありません。しかし、APBとAPAのクライアント・アップリンク速度を比較したときに、APBの方が平均2～3倍の速度であることから、その差は歴然です。これは、ハードウェアの問題による可能性があり、これを確認するシステムも備えていますが、このケースでは、実際にこれら2つのAPの唯一の違いは、構成の設定です。さてAPに戻り、建物のパフォーマンスを見てみましょう。

建物でWi-Fiをセットアップするには、多くの専門知識と労力が必要です。クライアント・ステーションの平均数とピークパフォーマンスの需要を概算する必要があります。カバレッジ・ホールがないよう十分にAPを設置する必要がありますが、多すぎるとお互いを干渉してしまいます(コストもかさみます)。その他にも考慮すべき点はいくつもありますが、それらを考慮したとしても、最初の導入は、ネットワーク構築の全体プロセスのほんの一部にすぎません。クライアントの動作や需要が変われば、十分に設計されたネットワークでも負担が大きくなります。Aruba AIOPSオペレーションの一つ、「**構成の推奨事項**」について見ていきましょう。

送信パワーやチャンネル数など、無線ネットワークのパフォーマンスを最適化するために調整できるノブは約十数個あります。長い年月と共に収集されてきたWi-Fiパフォーマンスのインサイトに関する大規模なデータセットとAIを活用することにより、ネットワーク最適化における推測的作業を排除でき、構成に推奨される最適な設定を提示できます。

お客様のネットワークのエアタイム効率を計算し、各建物について環境要素と構成設定と共にこれを保存します。続いて、対象の建物について、環境上類似の建物をすべて見つけ、AIを使用して、上位パフォーマンスを達成しているピア・グループの建物で設定されている各構成に切り替えながら、パフォーマンス面で改善しうる点を検討します。有効な改善点が見つかり、AIモデルでこれが有効であると判定された場合に、新しい設定がお客様に提案されます。図2はそうしたプロセスによる結果を示しています。

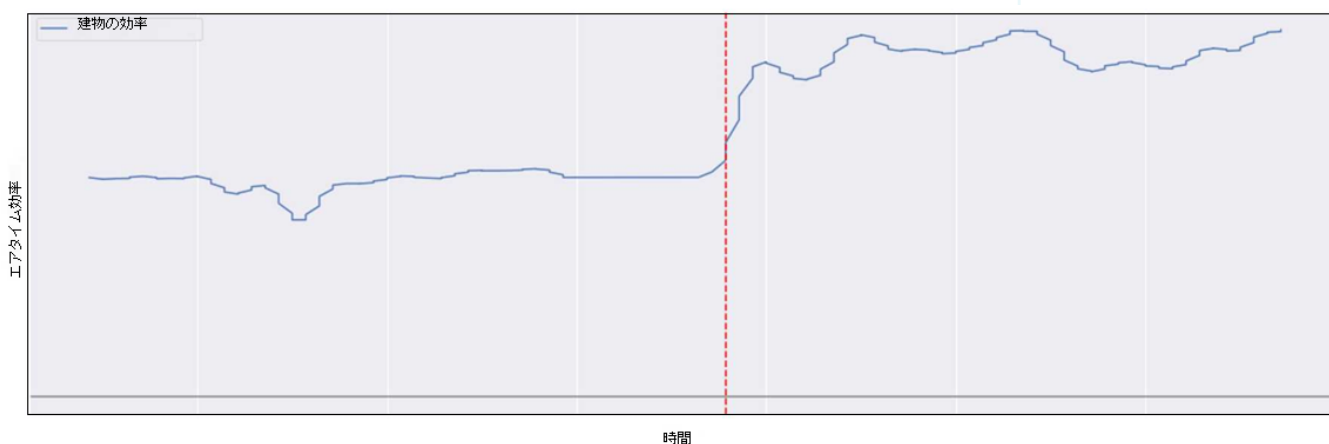


図2. エアタイム効率の経時的変化。灰色の線はスタートラインです。赤色の線は、構成の変更に関する推奨事項が適用された時間を示します。



ある 1 つの建物のエアタイム効率の経時的変化を表した図です。このエリアにフォーカスした AI インサイトは、Aruba のデータセットの数万の顧客環境から、この建物のネットワーク・パフォーマンスを改善するための有効な構成設定を見つけ、お客様に変更を提案しました。赤色の線で表示されたタイミングで変更が実装され、直ちにパフォーマンスに変化が見られました。このケースでは約 50% 向上しました。さらに素晴らしいことに、Aruba とお客様はネットワークを改善したことにより、AI もより優れた方法を学習することになります。将来的に状況が変わった際も建物は再度最適化することができます。また、建物の使用状況の変化に応じて、Aruba のアルゴリズムはこれを検出し、適切な変更を提示します。さらに、こうしたプロセスはお客様にとってより簡単になります。AI インサイトを自動的に適用することができます。

最後に、図 1 のこれら 2 つの AP をもう一度見てみましょう。これらは 2 つの異なる AP ではなく、実際は同じ曜日に記録された同じ AP です。図 2 で示された Aruba のアルゴリズムで推奨された構成の変更の 1 週間前 (AP A) と 1 週間後 (AP B) のものです。Aruba の AIOps ソリューションを使用することにより、お客様は、速度を 3 倍改善し、建物のエアタイム効率の測定で捕捉された効果、接続の信号品質 (SNR) もわずかに改善できました。

まとめ。AI + オートメーション = 頼りになる AIOps

ネットワークの診断、解決、最適化に活用される教師あり/教師なしの機械学習への迅速な情報アクセスを可能にする自然言語処理における人工知能は、IT チームにとって重要なパートナーになりうる存在です。このパワーを活用するためにデータ科学者である必要はありませんが、頼りにできる AI とそうでないものの違いを理解しておくことは重要です。

Aruba は優秀な AI を実現するために 5 つの重要な要素を提供しています。モデルを育成するために必要な多様で膨大なデータへのアクセス、対処すべき問題を知るための専門分野の知識、問題に対し適切なテクノロジーで対応できるデータ科学の専門知識、実際の顧客環境で AI オペレーションを検証してきた長年の経験、そしてあらゆる規模の組織に対応できる拡張能力です。