


A Vantagem do Aruba AI Ops

COMO DADOS, CIÊNCIA DE DADOS,
EXPERTISE NO DOMÍNIO E RESULTADOS
COMPROVADOS AUMENTAM A EFICIÊNCIA
E A EFICÁCIA DAS OPERAÇÕES DE REDE



A ESTRUTURA DE IA DA ARUBA

3

APROVEITANDO OS FATORES DO AMBIENTE DE REDE PARA FORNECER AUTOMAÇÃO CONFIÁVEL

4

USANDO GRUPOS DE PARES PARA OTIMIZAR AS CONFIGURAÇÕES DE REDE

6

JUNTANDO TUDO: INSIGHTS DE IA OFERECEM RECOMENDAÇÕES PRÁTICAS

8

RESUMO. IA + AUTOMAÇÃO = AIOps - VOCÊ PODE CONFIAR

10



A Infraestrutura de rede moderna é extremamente complexa, por causa do aumento do tamanho das redes, volume de tráfego e diversidade de dispositivos e aplicativos. Configurar manualmente essas redes demora muito tempo, facilita a ocorrência de erros e dificulta a tarefa de acompanhar o ritmo da explosão dos dispositivos IoT e da conectividade distribuída, desde a borda remota até as filiais, campi e data centers. Para serem eficientes, os operadores de rede precisam de insights melhores, tanto das operações, quanto dos usuários, ou, melhor ainda, automação inteligente conduzida por IA que detecte todos os aspectos que um operador humano iria considerar na hora de gerenciar uma rede e que aplique a soma de seu conhecimento para a enorme escala e complexidade dos ambientes de hoje.

A vantagem do Aruba AIOps já começa por aí, com uma IA incrível. Ela é resultado de nossa profunda compreensão das tecnologias de rede e segurança e de nossa história de sucesso em ciência de dados – mérito de uma forte equipe de cientistas de dados que contam com os insights e dados coletados durante muitos anos, das dezenas de milhares de instalações que geram bilhões de pontos de dados por dia, indo desde pequenos edifícios até campi e estádios, em todas as verticais e regiões, de implantações globais até empresas emergentes. Apesar do que as equipes de marketing dizem, esse investimento em dados e tecnologia de IA não pode ser simplesmente replicado em meses ou até anos – bases pequenas de clientes fornecendo poucos dados por curtos períodos de tempo fazem com que os resultados da IA não sejam confiáveis. Quando você usa a IA da Aruba, tudo o que foi acumulado em muitos e muitos anos de aprendizados bem-sucedidos e soluções aprovadas pelos clientes já está disponível para você desde o primeiro dia.

Nós chamamos a combinação de análises e ações de IA de AIOps. O AIOps é a próxima geração de soluções de IA para redes, que pode ser obtido somente com os resultados conduzidos por dados que foram testados e aprovados em milhares de instalações de clientes, sendo abrangentes o bastante para aplicar insights e recomendações precisos para cada ambiente de cada cliente.

Este documento técnico descreve como a Aruba oferece os blocos essenciais de uma rede auto-otimizável conduzida por IA e como eles funcionam juntos para, com absoluta confiança, vencer os desafios trazidos pelas redes dos clientes.

A ESTRUTURA DE IA DA ARUBA

O **objetivo** de uma rede com auto-otimização é fornecer, aos seus usuários, conectividade estável, além de dar conta da demanda de tráfego dos usuários, de modo que eles possam

O ROI da IA

Recentemente, um cliente começou a ver o que acreditou ser uma quantidade significativa de tráfego “de passagem” que estava diminuindo o desempenho da rede. Mas eles não tinham os dados ou benchmarks necessários para diagnosticar e corrigir manualmente o problema. Quando eles instalaram os Insights de IA da Aruba, o problema foi validado imediatamente, e foi recomendada uma mudança de configuração que, quando aplicada, eliminou 98% do tráfego “de passagem” indesejado, mantendo a conectividade dos usuários e dispositivos legítimos. O resultado: aumento de 25% na capacidade sem fio, e ele não precisou instalar qualquer hardware extra.

ter a mais alta qualidade de serviço possível. Na prática, é muito difícil medir automaticamente a experiência do usuário como percebida pelos humanos. Para criar, treinar e avaliar a IA, usamos métricas substitutas que são diretamente mensuráveis, como rendimento, latência ou eficiência de recursos. Para cada caso de uso, escolhemos uma métrica – uma representação numérica de quão bem a rede está funcionando e de como ela está em comparação com outras redes.

Identificamos os **fatores que influenciam** a métrica escolhida e os separamos em dois tipos: os que podem ser controlados pela IA (fatores controláveis) e os que são do jeito que são (fatores ambientais).

Pense no caso de uso de otimizar parâmetros de transmissão de rádio para os pontos de acesso em uma rede Wi-Fi. Dentre os fatores controláveis, temos a largura de banda do canal de radiofrequência e os níveis de potência da transmissão de radiofrequência. O hardware do ponto de acesso Wi-Fi é fisicamente capaz de operar as várias configurações desses fatores, e optamos por deixar que a IA decida qual a melhor configuração.

Já os fatores ambientais incluem, por exemplo, o espaço entre os pontos de acesso adjacentes, na implantação, as características de propagação dos sinais de RF, dependendo dos materiais de construção usados na área de cobertura, e as características de RF dos dispositivos clientes que vão se conectar. A IA não tem como modificar esses fatores (e eles ainda podem variar naturalmente, de quando em quando).

Equipados com as definições de uma função de objetivo mensurável e seus fatores controláveis e ambientais, preparamos a rede para **coletar esses dados**



continuamente e enviá-los à nuvem. Para cada rede e cada momento, a IA da nuvem fica sabendo, assim, quão bem a rede está funcionando, a configuração atual dos fatores controláveis e o valor atual dos fatores ambientais.

Para avaliar bem o desempenho, comparamos a rede com seu **grupo de pares**, que é constituído de outras redes com os mesmos fatores ambientais. Por exemplo, uma rede pode ficar no 10o percentil dentre seus pares, ou seja, ela tem o desempenho pior do que 90% de seus pares. Como a principal diferença entre as redes pares é a atribuição de fatores controláveis, o algoritmo da IA pode fazer essa rede subir no ranking, modificando os fatores controláveis.

A **configuração ideal dos fatores controláveis** é determinada de um dentre dois modos:

Com aprendizagem supervisionada, os dados anteriores de todas as redes são destiladas em um modelo de IA que pode prever o valor da função objetiva de uma rede, com seus fatores ambientais atuais e **qualquer configuração possível** dos fatores controláveis. Usando essas previsões, é fácil selecionar a melhor configuração dentre todas possíveis. Nesse modo, a IA explora o conhecimento integrado aos dados disponíveis, para otimizar cada rede.

Outra possibilidade, com o aprendizado ativo, é permitir que a IA adquira novos conhecimentos que não estavam disponíveis nos dados anteriores. O algoritmo define, proposital e cuidadosamente, os fatores controláveis para as combinações de valores que nunca foram experimentados antes. Nesse modo, a IA explora o espaço de oportunidade para identificar o potencial de otimização anteriormente desconhecido para cada rede.

Os **principais blocos fundamentais** de uma rede operada por IA e conduzida automaticamente são: uma função objetiva, significativa e mensurável; seus fatores influenciadores controláveis e ambientais; uma coleção de dados grande e diversificada; uma definição de grupos de pares, com os quais será comparada; e modelos e algoritmos de IA que selecionam automaticamente a atribuição ideal dos fatores controláveis em cada condição operacional.

APROVEITANDO OS FATORES DO AMBIENTE DE REDE PARA FORNECER AUTOMAÇÃO CONFIÁVEL

Os fatores ambientais de uma rede são um elemento fundamental do AIOps: eles capturam as características não controláveis de uma rede. Para as finalidades às quais a IA se destina e as ações que ela pode tomar, eles são parâmetros fornecidos externamente. Os fatores ambientais definem a extensão do “campo de jogo” dentro do qual a IA pode fazer otimizações.

Por que os dados são tão importantes?

Um princípio bem conhecido da Inteligência Artificial é que os modelos matemáticos aprendem a executar uma tarefa específica, com base no treinamento contínuo sobre os dados que eles devem processar, onde estiverem. Quando os modelos de machine learning recebem os dados errados ou pouquíssimos dados, para treinar os modelos, os resultados são inúteis. Por exemplo, se um modelo de gerenciamento de rede apenas tiver dados de escritórios pequenos, os resultados não são confiáveis para uso em ambientes maiores e mais complexos. Pense em um modelo feito para reconhecer fotos de cachorros. Se ele tiver sido treinado exclusivamente com fotos de cachorros marrons, ele irá falhar, quando vir uma foto de um cachorro preto. O mesmo vale para a sua rede. Se a IA usada para fazer as mudanças de configurações não tiver dados suficientes, de acordo com a sua rede, você não poderá confiar na IA para melhorar o seu desempenho.

Para mostrar como esse conceito se traduz na realidade, vejamos fatores ambientais específicos, o que eles significam e como são mensurados. Os exemplos são tirados da otimização automática do desempenho de redes Wi-Fi, um dos principais recursos dos Insights de IA do Aruba Central.

Há quatro tipos distintos de fatores ambientais que capturam o ambiente físico, o layout da rede, o comportamento de mobilidade do usuário e as características de tráfego.

Os fatores que representam o **ambiente físico** estão relacionados à arquitetura, planta e materiais de um edifício, por meio das lentes da infraestrutura de Wi-Fi. Primeiro, o **tamanho do edifício**, medido em termos de área, é um fator importante, claramente. Se tivermos a informação de em quais andares de um prédio cada ponto de acesso Wi-Fi está instalado, poderemos medir o efeito do teto de cada andar no sinal do Wi-Fi (**perda de sinal ao atravessar o teto**). O efeito combinado dos materiais de um prédio na propagação do sinal pode ser representado pelo **expoente de perda no percurso**, que é a taxa média na qual a potência do sinal de Wi-Fi diminui.

Os fatores de **layout de rede** estão relacionados ao jeito como a infraestrutura de rede está implantada em um espaço. Isso inclui a **densidade de pontos de acesso** de Wi-Fi e as **capacidades de hardware** de Wi-Fi dos pontos de acesso.



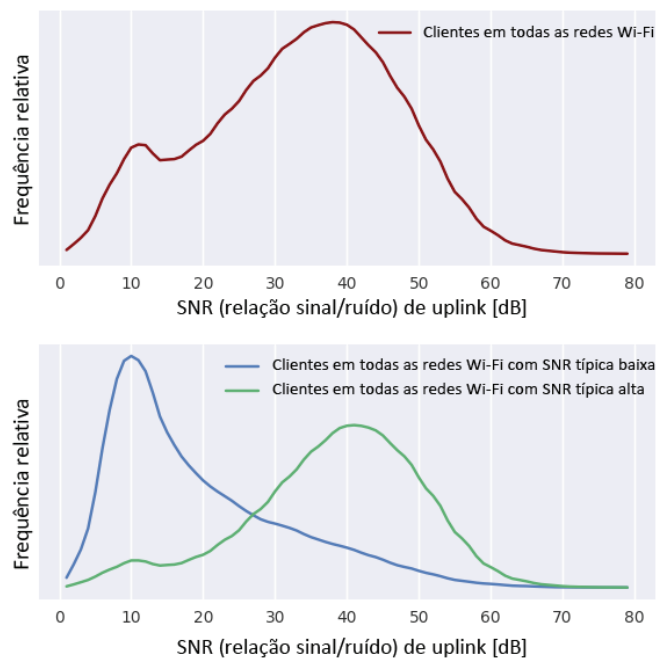
Para capturar a perspectiva do usuário final, medimos a potência dos sinais do dispositivo do usuário, quando recebidos pelos pontos de acesso, e agregamos essas medições brutas quanto a tempo, espaço e clientes, para computar a **relação sinal/ruído de uplink** típica. Finalmente, o nível de competição por recursos causada por outro equipamento de Wi-Fi pode ser capturada, bem como a **densidade dos pontos de acesso não gerenciados**.

Os fatores que representam o **comportamento do usuário** incluem o **pico de densidade do cliente**, já que as redes precisam ser projetadas para lidar com a maior carga possível, e o **tempo de intervalo de cliente típico**, que quantifica o comportamento de mobilidade dos usuários. A população de dispositivos clientes pode ser caracterizada pela **composição de tipos de dispositivo de cliente** em categorias como laptops, telefones, dispositivos IoT e dispositivos legados (que usam protocolos de Wi-Fi ultrapassados).

Finalmente, as **características de tráfego** capturam o tipo de aplicativos sendo executados na rede. Isso inclui o **volume de tráfego típico por cliente conectado**, bem como a **composição do tráfego dentre os tipos de aplicativos**. Esses recursos ajudam a IA a alocar os recursos de rede, dando preferência aos aplicativos que impactam diretamente a experiência do usuário.

A combinação de todos os fatores ambientais define o “campo de jogo” para o AIOps, que alimenta a rede de condução automática. Implantações com os mesmos fatores ambientais têm o mesmo campo e formam um grupo de pares natural para benchmarks entre redes: se a IA “joga” no mesmo campo, ela deve conseguir o mesmo desempenho, todas as vezes.

O hardware de rede da Aruba foi especialmente projetado para fornecer dados brutos, para a medição dos fatores ambientais. A arquitetura de nuvem da Aruba suporta o design, a implementação e a validação dos fatores ambientais entre todas as redes de nossos clientes, para garantir que eles sejam computados de forma robusta, correspondam a uma grande variedade de efeitos físicos (isso é, não estejam muito correlacionados) e estejam fortemente vinculados à métrica de desempenho de rede escolhida. O AIOps da Aruba se baseia no hardware e na infraestrutura de nuvem, para computar os fatores ambientais, traduzi-los em grupos de pares significativos e fazer funcionar cada rede única de cliente no ponto operacional ideal.



Comparando todas as redes, a relação sinal/ruído do cliente para o ponto de acesso (SNR, signal-to-noise ratio, de uplink) varia muito, e há dois modos distintos (diagrama superior). Cada rede pode ser caracterizada por seu SNR de uplink típico.

Agrupar redes similares é que o que diferencia os dois modos, permitindo uma comparação nos mesmos termos entre redes no mesmo grupo (diagrama inferior).



USANDO GRUPOS DE PARES PARA OTIMIZAR AS CONFIGURAÇÕES DE REDE



Agora que já descrevemos as características ambientais que podem ser usadas para quantificar o comportamento e o desempenho de sites diferentes, vamos explicar como usamos essas características para criar clusters de sites que formem grupos de pares.

Há muitos mais dispositivos móveis agora do que nunca, e o tráfego de dados continua a crescer - e não parece que isso vai parar. Atualmente, não basta mais ter uma rede confiável: a rede também precisa estar otimizada para casos de uso específicos. Vamos tratar da otimização em mais detalhes, na próxima seção, mas, antes, vamos nos concentrar em um pré-requisito importante para ajudar nossa IA a melhorar o desempenho das redes de nossos clientes: as definições de **grupos de pares**.

Os grupos de pares, basicamente, são grupos de redes, sites ou mesmo PAs (pontos de acesso), em relação aos quais são feitos o benchmark e a comparação de uma determinada rede. Certamente, é possível comparar todas as redes umas


com as outras, mas essa não é uma boa ideia. O ambiente operacional de uma pequena cafeteria de bairro é, em tese, muito diferente do ambiente de uma grande universidade ou de um hospital. O que faz sentido é comparar esses ambientes separadamente e, no final, permitir que as máquinas do AIOps aprendam com eles, para fazer recomendações de modo a melhorar o desempenho, com base nas configurações e desempenho dos pares. Eis uma projeção 2D de uma passagem de união em cluster de grupo de pares por ambiente, para um subconjunto de nossos sites:

A imagem à esquerda mostra o agrupamento automático de clusters, o que significa que nossos sites realmente têm ambientes diferentes. Na imagem à direita, adicionamos verticalidade de mercado e cliente, com cruzes pretas e marrons para indicar alguns colegas e restaurantes classificados, respectivamente. As cruzes não estão relacionadas aos clusters de grupo de pares, de modo que o fato de nossas cruzes se agruparem em alguns clusters confirma a nossa ideia acima de que tipos diferentes de sites teriam ambientes diferentes.






Conseguir agrupar ambientes similares é ótimo, mas qual é o impacto disso, falando mais amplamente? Vamos rever o exemplo da seção anterior, a relação sinal-ruído SNR (signal-to-noise ratio) do uplink:



Este é o SNR de uplink médio das estações clientes conectadas aos PAs em muitos sites diferentes, para um cliente específico. Como já discutimos, há vários modos, com algumas estações clientes conectadas com SNR de uplink baixo e outras, com SNR de uplink alto. Se um desses sites do cliente tiver um SNR de uplink de estação cliente médio de

31 dB (a linha preta tracejada), isso é bom ou ruim? Na verdade, ele está bem no meio da distribuição, e isso é praticamente tudo o que podemos dizer, considerando a distribuição total. Entretanto, podemos ir mais longe, usando os grupos de pares criados pelo nosso fluxo de trabalho do AIOps.





Aqui, podemos ver que os sites dos clientes ficam, na verdade, em muitos grupos de pares ambientais diferentes. (Observação: isso é apenas uma parte de um espaço altamente dimensional, então, esperamos que muitas distribuições tenham aparência similar.) Duas das distribuições se destacam das outras, os grupos de pares 6 e 8, mostradas em azul e vermelho, respectivamente. Falando de modo mais abrangente, o grupo de pares 6 tende a ser composto de PAs mais antigas em locais externos, enquanto o grupo de pares 8 consiste de vários modelos e implantações de médio porte. Nosso mesmo site de teste acima, com uma SNR de uplink de estação de cliente média de 31 dB estaria no 73o percentil do grupo de pares 6, mas apenas no 21o percentil do grupo de pares 8. Essa informação, em si, permite que nossos clientes façam ajustes em seu sites problemáticos. Mais do que isso, como veremos na próxima seção, também podemos usar o desempenho relativo de um site, em comparação com seus pares, para recomendar mudanças e aperfeiçoamentos, a fim de otimizar e melhorar o funcionamento do site.

A adição de grupos de pares às nossas soluções de AIOps nos permite, com muito mais precisão, comparar sites, e esse é um bloco-chave em nossa habilidade de recomendar aperfeiçoamentos para um site ou rede, com base no desempenho e configurações dos pares. Usando o Aruba Central, coletamos continuamente terabytes de dados e fazemos perfis de milhares de sites, de modo que essas recomendações estejam altamente ajustadas, para os resultados mais positivos.

JUNTANDO TUDO: INSIGHTS DE IA OFERECEM RECOMENDAÇÕES PRÁTICAS

Com uma robusta estrutura de IA, acesso a dados do ambiente e o uso de clusters de pares, iremos ilustrar, agora, como juntamos essas técnicas, para oferecer Insights de IA confiáveis e concretos para nossos clientes. Os Insights de IA da Aruba oferecem as análises, dados e recomendações necessárias para a equipe de TI responder rapidamente a defeitos, evitar problemas e otimizar continuamente a rede, abrangendo uma vasta gama de fatores de rede com fio, rede sem fio e WAN.

Para ilustrar o poder dos Insights de IA e como eles funcionam, iremos definir um conceito-chave: eficiência de transmissão. A **eficiência de transmissão** é uma métrica da Aruba que usamos para medir o desempenho de Wi-Fi geral de um ponto de acesso (PA), um prédio ou mesmo um cliente inteiro. Se um ponto de acesso estiver oferecendo links com SNR alta, com altas velocidades nas bandas acessíveis para a maioria dos dispositivos de cliente presentes, ele ainda terá uma eficiência de transmissão alta.

Como exemplo de eficiência de transmissão, vamos ver dois PAs diferentes – O “PA A”, em vermelho, e o “PA B”, em azul, na Figura 1, abaixo. Esses PAs são do mesmo modelo, estão em ambientes similares e têm, aproximadamente, o mesmo número de estações de clientes se conectando, por dia. Em um determinado dia, podemos examinar uma dupla de métricas relacionadas à eficiência da transmissão: SNR (signal-to-noise ratio, relação sinal/ruído) do uplink de cliente e velocidade do uplink do cliente.

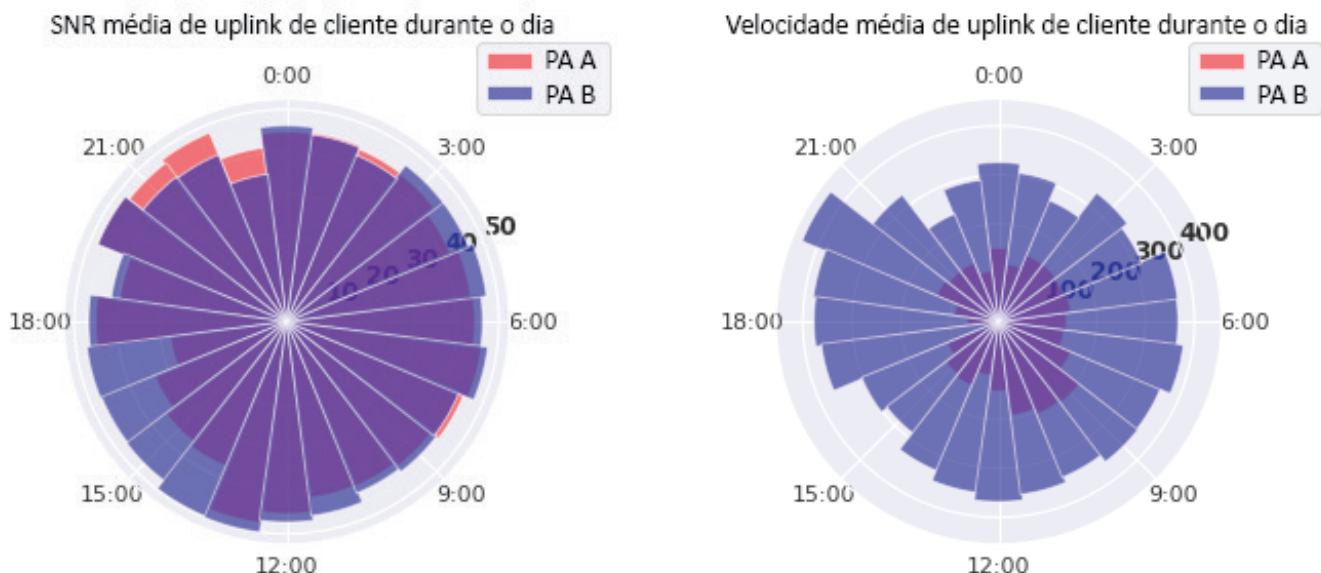


Figura 1 (Esquerda) A SNR média de uplink de cliente em todos os clientes conectados, para cada hora de um determinado dia. (Direita) A velocidade média de uplink de cliente em todos os clientes conectados, para cada hora de um determinado dia.



Esses dois PAs têm SNRs bastante próximas, com um rendimento médio de 30-40 dB, na maior parte do dia. Em alguns momentos, o PA B tem um desempenho muito melhor do que o PA A, mas a diferença, durante o dia, não é tão significativa. Entretanto, há uma diferença significativa nas velocidades de uplink do cliente conseguidas pelo PA B e pelo PA A, sendo que, em média, o PA B tem velocidades de duas a três vezes maiores. Isso pode ser devido a um problema de hardware, e temos mecanismos prontos para verificar isso, mas, neste caso, a única diferença real entre esses dois PAs está em suas **configurações definidas**. Agora, vamos deixar os PAs um pouco e ver o desempenho no edifício.

Configurar o Wi-Fi para um edifício envolve muito conhecimento e trabalho especializados. É necessário estimar o número médio de estações de clientes, além do pico de demanda. Deve haver PAs suficientes para que não haja “buracos” na cobertura, mas não tantos a ponto de um interferir com o outro (e levar o custo do projeto às alturas). Há muitos outros fatores que devem ser considerados, mas, ainda assim, a implantação inicial é apenas uma pequena parte do projeto geral da rede. Mudanças no comportamento e nas demandas dos clientes podem afetar até mesmo as redes com os melhores projetos. É aí que entra uma de nossas soluções de AIOps, **as recomendações de configuração**.

Há cerca de doze controles diferentes que podem ser ajustados para otimizar o desempenho de uma rede sem fio, incluindo potência de transmissão e número de canais. E não precisamos fazer “adivinhações” para otimizar a uma rede, graças à IA e ao nosso grande conjunto de dados de insights de desempenho de Wi-Fi coletados durante muitos anos, podendo recomendar as melhores configurações.

Calculamos a eficiência de transmissão de todas as redes de nossos clientes e salvamos essas informações junto às características ambientais e configurações de cada prédio. Assim, para um prédio sendo considerado, localizamos todos os edifícios similares, por ambiente, e usamos IA para considerar melhorias possíveis no desempenho obtido, fazendo ajustes em relação às configurações definidas dos prédios pares no topo da classificação. Se encontrarmos um aperfeiçoamento significativo e nosso modelo de IA tiver uma confiança alta nele, sugerimos as novas configurações ao nosso cliente. A Figura 2 mostra o resultado desse processo.




Figura 2. Gráfico de eficiência de transmissão pelo tempo. A linha cinza é a origem. A linha vermelha é a hora em que as mudanças de configurações recomendadas foram aplicadas.



A eficiência de transmissão é calculada para um edifício por vez. O Insight de IA focado nessa área encontrou uma configuração candidata para melhorar o desempenho da rede desse edifício, a partir de dezenas de milhares de ambientes de clientes em nosso conjunto de dados, e sugerimos uma mudança para o cliente. A alteração foi implementada no momento indicado na linha vermelha tracejada, e a mudança de desempenho foi imediata. Nesse caso, a melhoria foi de cerca de 50%. O que é ainda melhor é que, conforme nós e nossos clientes melhoramos as redes deles, a IA recebe mais e melhores opções para escolhermos, e um edifício pode ser reotimizado, no futuro, conforme o nosso conhecimento aumenta. Além disso, se o uso real de um prédio mudar, o nosso algoritmo irá detectar isso e sugerir as mudanças apropriadas. Indo em frente, o passo seguinte será deixar isso ainda mais fácil, para nossos clientes, aplicar Insights de IA automaticamente.

Para concluir, vamos dar uma outra olhada nos dois PAs da Figura 1. Na verdade, eles não são dois PAs diferentes, mas o mesmo PA, considerado no mesmo dia da semana, mas uma semana antes (PA A) e uma semana depois (PA B) das mudanças de configuração recomendadas pelo nosso algoritmo mostrado na Figura 2. Usando nossa solução AIOps, o nosso cliente conseguiu melhorar as velocidades fornecidas por um fator de 3, ao mesmo tempo que melhorou levemente a qualidade do sinal (SNR) das conexões, efeitos que foram capturados pela nossa medição da eficiência de transmissão do edifício.

RESUMO. IA + AUTOMAÇÃO = AIOps - VOCÊ PODE CONFIAR

A Inteligência Artificial vinda do Processamento de Linguagem Natural – para acesso rápido às informações, oferecendo machine learning supervisionado ou não, a fim de ser usada em diagnóstico, remediação e otimização de redes – pode ser uma aliada poderosa da equipe de TI. Você não precisa ser um cientista de dados, para aproveitar esse poder todo, mas é importante saber o que separa uma IA na qual você realmente pode confiar do que é apenas jogada de marketing.

A Aruba oferece os cinco elementos críticos para o sucesso da IA: acesso ao volume e à variedade de dados necessária, para treinar os modelos; expertise no domínio, para saber quais problemas atacar; expertise em ciência de dados, para usar a tecnologia certa no problema certo; anos de validação dos clientes de operações de IA em ambientes ativos; e a capacidade de dimensionar, para organizações de qualquer tamanho.