

La ventaja de Aruba AIOps

CÓMO LOS DATOS, LA CIENCIA DE DATOS,
EL CONOCIMIENTO DE DOMINIO Y
RESULTADOS COMPROBADOS AUMENTAN
LA EFICIENCIA Y LA EFECTIVIDAD DE LAS
OPERACIONES DE RED



TABLA DE CONTENIDO

LA INFRAESTRUCTURA DE ARUBA AI	3
CÓMO APROVECHAR LOS FACTORES DEL ENTORNO DE RED PARA OBTENER AUTOMATIZACIÓN CONFIABLE	4
USO DE GRUPOS DE PARES PARA OPTIMIZAR LA CONFIGURACIÓN DE RED	6
EN RESUMEN: LAS PERCEPCIONES DE IA PROPORCIONAN RECOMENDACIONES ACCIONABLES	8
RESUMEN. AI + AUTOMATIZACIÓN = AIOps CONFIABLES	10



La infraestructura de las redes modernas es extremadamente compleja debido al aumento de tamaño de las redes, el volumen de tráfico y la diversidad de dispositivos y aplicaciones. La configuración manual de esas redes se ha convertido en una tarea que consume mucho tiempo, que puede inducir a errores, y que es difícil de mantener con la explosión de dispositivos IoT y la conectividad distribuida desde la periferia remota a la sucursal, campus y centro de datos. Para ser eficientes, los operadores de redes necesitan conocer mejor la percepción de los usuarios y la información operativa; o mejor aún: automatización inteligente impulsada por IA, que conoce todos los aspectos que un operador humano consideraría al manejar una red, y que se aplican a la suma de su conocimiento a una escala mayor con la mayor complejidad de los entornos de la actualidad.

La ventaja de Aruba AIOps empieza con una excelente IA. Nuestro profundo conocimiento de la tecnología de redes y seguridad y nuestra historia de éxito en el campo de ciencia de datos, bajo el comando de un fuerte equipo de científicos de datos respaldados por la información y los datos recopilados durante años, desde decenas de miles de instalaciones que generan miles de millones de puntos de datos por día, que abarcan desde pequeños edificios, campus de universidades y estadios, con datos verticales y diversas geografías, desde implementaciones globales hasta empresas emergentes. A pesar de las promesas anunciadas, esta inversión en tecnología de datos e IA no se puede replicar en meses, ni siquiera en años; bases de clientes pequeñas suministrando datos limitados por cortos períodos de tiempo, ofrecen resultados que no son confiables. Cuando usa Aruba AI, el resultado de años de aprendizaje con soluciones para clientes comprobadas están disponibles desde el primer día.

De la combinación de análisis de y acciones IA, surge AIOps. AIOps es la próxima generación de soluciones de IA para redes que solo pueden realizarse con resultados impulsados por datos comprobados en miles de instalaciones de clientes, lo suficientemente completos para aplicar información y recomendaciones precisas para entornos de clientes individuales.

Este informe técnico describe cómo Aruba proporciona los bloques de construcción esenciales para una red operada por IA que se auto-optimiza y cómo funcionan juntos para hacer frente a los desafíos de la red del cliente de modo confiable.

LA INFRAESTRUCTURA DE ARUBA AI

El **objetivo** de una red que se auto-optimiza es proporcionar a los usuarios una conectividad estable y satisfacer la demanda de tráfico de los usuarios para que experimenten la

El retorno de la inversión (ROI) de la IA

Recientemente, un cliente observó lo que él creía que fuese una cantidad significativa de tráfico de “transeúntes” que estaba disminuyendo el rendimiento de la red. Sin embargo, no tenía los datos ni las referencias necesarias para diagnosticar y corregir el problema manualmente. Cuando instaló Aruba AI Insights, el problema fue validado inmediatamente y un cambio de configuración recomendado eliminó 98 % del tráfico de transeúntes, manteniendo la conectividad de los usuarios legítimos y sus dispositivos. El resultado: un aumento del 25 % de la capacidad inalámbrica sin adicionar hardware.

más alta calidad de servicio. En la práctica, esta experiencia de usuario percibida por humanos es muy difícil de medir automáticamente. Para construir, capacitar y evaluar la IA, usamos medidas sustitutas que son directamente mensurables, como rendimiento, latencia y eficiencia de recursos. Para cada caso de uso, utilizamos una medida: una representación numérica del rendimiento de la red comparada a otras redes.

Identificamos **los factores que influyen** las medidas elegidas y los separamos en dos tipos: los que la IA puede controlar (factores controlables) y los que se asumen como dados (factores del entorno)

Tomemos como ejemplo un caso de uso de optimización de parámetros de transmisión de radio para los puntos de acceso de una red Wi-Fi. Los factores controlables incluyen el ancho de banda de los canales de RF y los niveles de potencia de la transmisión por RF. El hardware del punto de acceso de Wi-Fi puede operar físicamente en diversas combinaciones de esos factores, y nosotros dejamos que la IA decida cual es la situación ideal.

Los factores del entorno incluyen, por ejemplo, el espacio entre puntos de acceso adyacentes en la implementación, las características de propagación de las señales de RF dependiendo del material de construcción del área de cobertura y las características de RF de los dispositivos del cliente que se conectan. La IA no tiene la capacidad de modificar esos factores (que naturalmente pueden variar con el tiempo).

Equipados con las definiciones de una función objetiva mensurable y los factores del entorno controlables, brindamos a la red herramientas para **recopilar esos datos de forma continua** y dirigirlos a la nube. Para cada red y



cada instante en el tiempo, la IA de la nube está al tanto del rendimiento de la red, el conjunto actual de factores controlables y el valor actual de los factores del entorno.

Para evaluar el rendimiento de manera justa, clasificamos a cada red en comparación con las del **grupo de pares**, que es un conjunto de redes con los mismos factores de entorno. Por ejemplo, una red puede estar en el décimo percentil en su grupo de pares, lo que significa que su rendimiento es peor que el de 90 % de las redes. Como la principal diferencia entre las redes del grupo de pares es la asignación de factores controlables, el algoritmo de IA puede mejorar la clasificación de esta red modificando los factores controlables.

El **conjunto ideal de factores controlables** se puede determinar de dos maneras:

Con aprendizaje supervisado, los datos pasados de todas las redes se destilan en un modelo de IA que puede predecir el valor objetivo de función de una red con sus factores de entorno actuales con *cualquier conjunto posible* de factores controlables. Usando esas predicciones, es fácil seleccionar el mejor conjunto entre todos los posibles. De esta manera, la IA aprovecha el conocimiento que contienen los datos disponibles para optimizar cada red.

De modo alternativo, con aprendizaje activo, la IA puede adquirir conocimiento nuevo, que no está disponible en los datos pasados. El algoritmo, deliberadamente y con precaución, ajusta los factores controlables en combinaciones de valores que nunca se intentaron antes. Y así, la IA explora el espacio de oportunidades para identificar un potencial de optimización para cada red desconocido hasta entonces.

Los **bloques de construcción clave** de una red autoconducida operada por IA son: una función objetiva mensurable y significativa, factores controlables que influyen el entorno, un gran conjunto de datos diversos, la definición de un grupo de pares para comparación, y modelos de IA y algoritmos que seleccionen automáticamente la asignación óptima de factores controlables en cada condición operativa.

CÓMO APROVECHAR LOS FACTORES DEL ENTORNO DE RED PARA OBTENER AUTOMATIZACIÓN CONFIABLE

Los factores del entorno de una red son un elemento clave para AIOps, ya que capturan las características de una red que no son controlables. Para el propósito de la IA y las acciones que puede tomar, son parámetros dados externamente. Los factores del entorno definen la extensión del área dentro de la cual se permite que la IA aplique mejoras.

¿Por qué los datos son tan importantes?

Es un principio bien conocido de la inteligencia artificial que los modelos matemáticos aprenden a realizar una tarea específica con base en la práctica continua con los datos que se procesan en su entorno natural. Cuando los modelos de aprendizaje automático reciben datos erróneos o en pequeñas cantidades para construir los modelos, los resultados son inutilizables. Por ejemplo, si el modelo de administración de la red solo recibió datos de pequeñas oficinas, los resultados no serán confiables en entornos más grandes y complejos. Por ejemplo, pensemos en un modelo diseñado para reconocer imágenes de perros. Si el modelo está construido exclusivamente con fotos de perros marrones, fallará cuando aparezca un perro negro. Lo mismo se aplica a su red. Si la IA usada para hacer cambios de configuración no recibe datos suficientes que coincidan con su red, no podrá confiar en ella para mejorar su rendimiento.

Para concretizar este concepto, veremos ahora factores del entorno específicos, su significado y cómo se miden. Los ejemplos se tomaron de la optimización automática de rendimiento para redes Wi-Fi, una característica esencial de la Información de IA de Aruba Central.

Existen cuatro tipos distintos de factores de entorno que capturan el entorno físico, la disposición de la red, el comportamiento móvil del usuario y las características del tráfico.

Los factores que representan el **entorno físico** se relacionan con la arquitectura, el plano y los materiales de construcción, todo esto visto desde la perspectiva de la infraestructura de Wi-Fi. En primer lugar, *el tamaño del edificio*, medido en metros/pies cuadrados, es un factor de gran importancia. Cuando se sabe en qué piso de un edificio está instalado cada punto de acceso de Wi-Fi, podemos medir el efecto de los techos en la señal de Wi-Fi (*pérdida de señal a través del techo*). El efecto combinado de todos los materiales de construcción en la propagación de la señal puede representarse por el *exponente de pérdida de trayecto*, que es la tasa promedio por la cual la señal de Wi-Fi pierde su fuerza.

Los factores de **disposición de la red** se relacionan con el modo en que la infraestructura de la red está instalada dentro de un espacio. Esto incluye *la densidad de puntos*



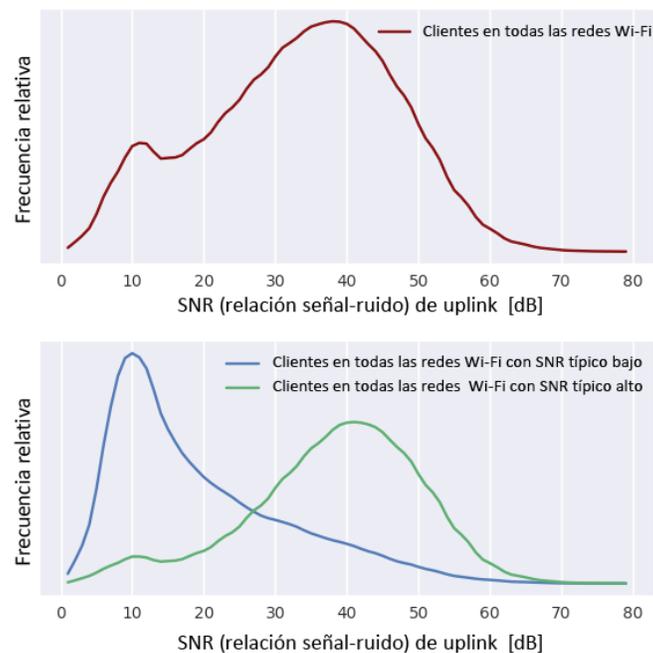
de acceso y la *capacidad de Wi-Fi del hardware* de esos puntos de acceso. Para capturar la perspectiva del usuario final, medimos la fuerza de las señales del dispositivo de los clientes cuando se reciben de los puntos de acceso y sumamos estas mediciones en bruto considerando tiempo, espacio y clientes para computar la *relación típica de señal a ruido de uplink*. Finalmente, el nivel de competición de recursos causado por otro equipamiento de Wi-Fi puede capturarse como la *densidad de puntos de acceso* no administrados.

Los factores que representan **el comportamiento de los usuarios** incluyen la *densidad de pico del cliente*, ya que las redes necesitan diseñarse para manejar la mayor carga posible y *el tiempo de permanencia típico del cliente*, que cuantifica el comportamiento de movilidad de los usuarios. La población de dispositivos de clientes se pueden caracterizar por la *composición de los tipos de dispositivo de cliente* en categorías como laptops, teléfonos, dispositivos IoT y dispositivos heredados (que utilizan protocolos de Wi-Fi antiguos).

Y finalmente, **las características de tráfico** capturan el tipo de aplicaciones que se ejecutan en la red. Esto incluye *el volumen de tráfico típico por cliente conectado*, además de la *composición del tráfico por tipos de aplicaciones*. Estas funciones ayudan a la IA a asignar recursos de red de forma preferencial a las aplicaciones que impactan directamente la experiencia del usuario.

La combinación de todos esos factores del entorno define el campo de acción de la AIOPS que impulsa la red autoconducida. Las implementaciones con los mismos factores de entorno tiene el mismo campo de acción y forman un grupo natural de pares para establecer puntos de referencia entre redes: si la IA actúa en el mismo campo, debería obtener el mismo rendimiento siempre.

El hardware de red Aruba está diseñado especialmente para ofrecer datos en bruto y proporcionar una medición precisa de los factores de entorno. La arquitectura de nube de Aruba ofrece soporte para el diseño, la implementación y la validación de los factores del entorno en todas las redes de nuestros clientes para asegurar que se computen con solidez, que correspondan a una gran variedad de efectos físicos (o sea, no demasiado correlacionados) y fuertemente vinculados a la medida elegida para el rendimiento de la red. La AIOPS de Aruba se basa en hardware e infraestructura de nube para computar los factores del entorno, los transforma en grupos de pares significativos y administra la red individual de cada cliente en el punto operativo óptimo.



Por todas las redes, la relación señal a ruido (SNR de uplink) del punto de acceso al cliente puede variar mucho, y existen dos modos distintos (diagrama superior). Cada red puede caracterizarse por su típica SNR de uplink. La agrupación de redes similares separa los dos modos, permitiendo una comparación "like-for-like" entre redes del mismo grupo (diagrama inferior).



USO DE GRUPOS DE PARES PARA OPTIMIZAR LA CONFIGURACIÓN DE RED

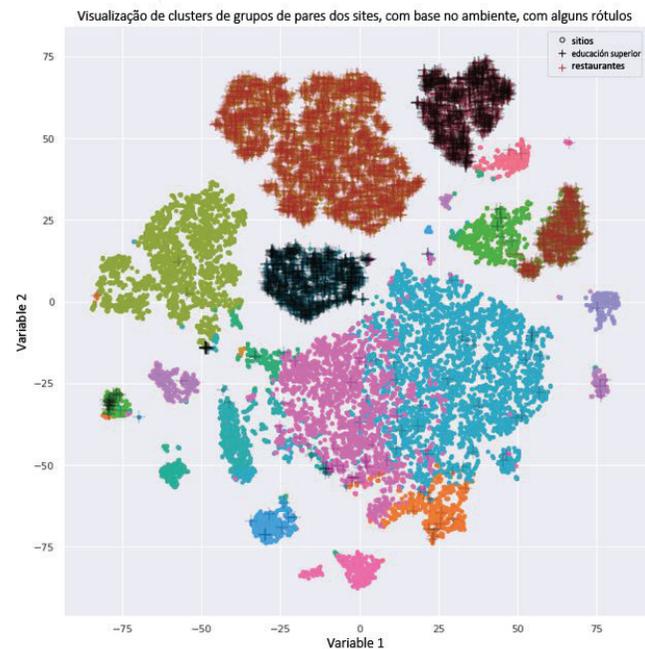
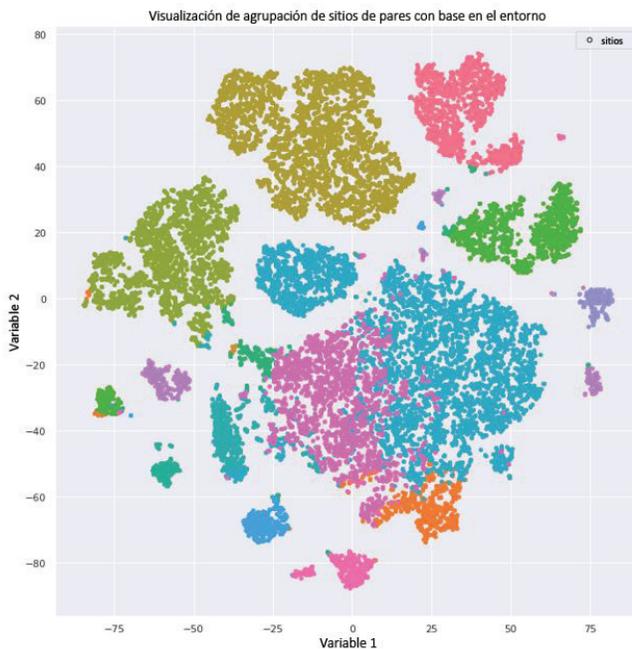
Ahora que ya describimos las características del entorno que pueden usarse para cuantificar el comportamiento y el rendimiento de diferentes sitios, explicaremos a continuación cómo usamos esas características de entorno para reunir sitios en grupos de pares.

Existen cada vez más dispositivos móviles activos y el tráfico de datos continúa creciendo sin límite. En la actualidad ya no es suficiente tener una red buena y confiable; la red tiene que ser optimizada para casos de uso específicos. Hablaremos con más detalles sobre la optimización en la próxima sección, y nos concentraremos ahora en un prerrequisito importante para ayudar a nuestra IA a mejorar el rendimiento de las redes de nuestros clientes: **las definiciones de grupos de pares**.

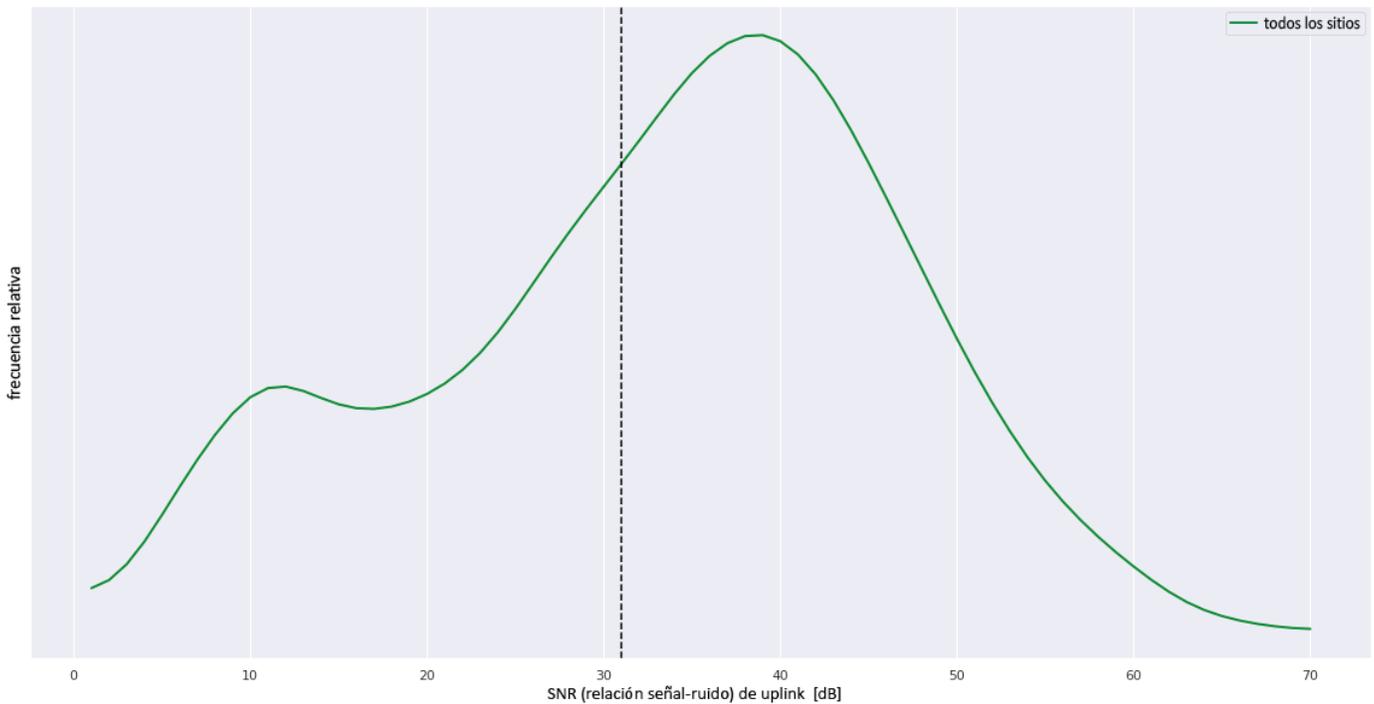
Los grupos de pares en el nivel más básico son grupos de sitios, redes, o hasta PA (puntos de acceso) a los cuales se compara una red dada. Por supuesto, es posible

comparar todas las redes entre sí, pero no es una buena idea. El entorno operativo de una pequeña cafetería es muy diferente del de una gran universidad o un hospital. Tiene más sentido comparar esos entornos por separado y, finalmente, permitir que la máquina de AIOps aprenda con ellos para hacer recomendaciones que mejoren el rendimiento con base en el desempeño y las condiciones operativas de los pares. Esta es una proyección 2D de una reunión de grupos de pares de AIOps para un subconjunto de nuestros sitios:

La imagen de la izquierda muestra una reunión automática de grupos, lo que significa que nuestros sitios realmente tienen entornos diferentes. En la imagen de la derecha, introdujimos verticalidad de mercado y clientes al adicionar cruces marrones y negras para identificar algunas facultades y restaurantes. Las cruces son independientes de la reunión de grupos de pares, por lo que el hecho de que las cruces se agrupen demuestran nuestra premisa de que diferentes tipos de sitio poseen entornos diferentes.

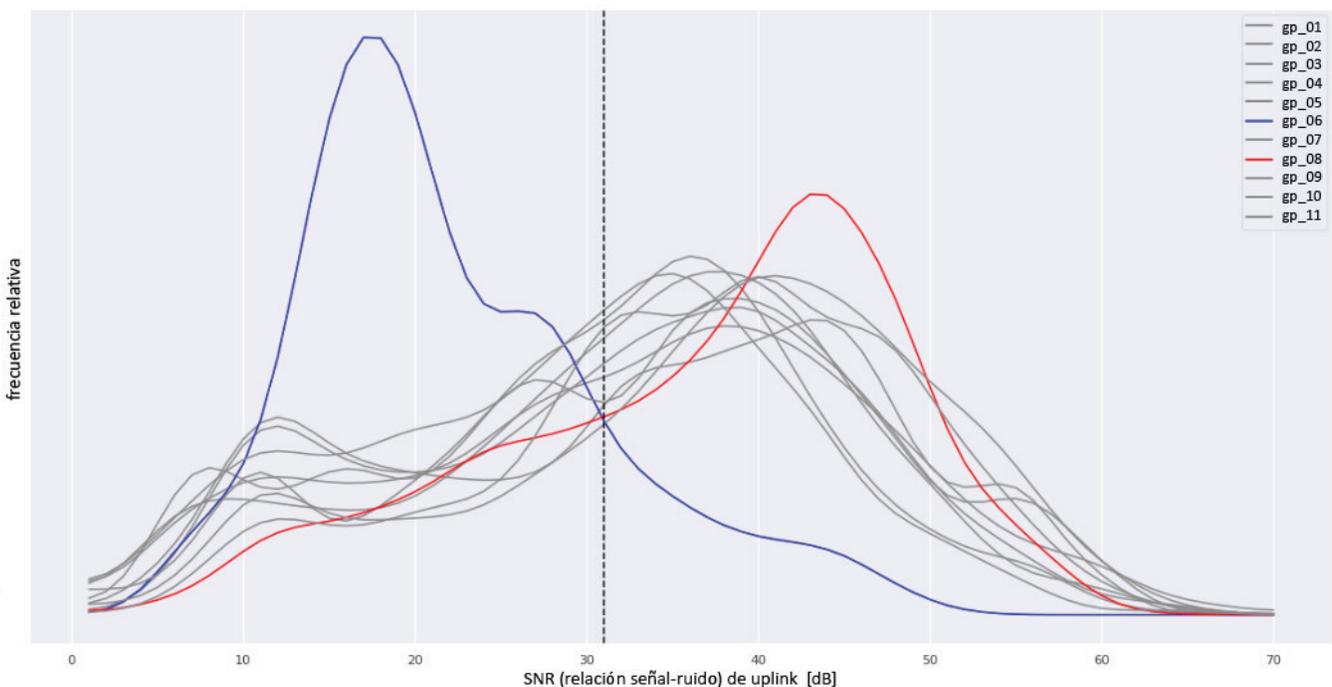


Es fantástico poder agrupar entornos similares, pero ¿cuál es el impacto más amplio? Regresemos al ejemplo de la SNR (relación señal a ruido) de uplink de la sección anterior:



Esta es la SNR de uplink promedio de las estaciones de clientes conectados a PA en sitios muy diferentes para un cliente específico. Como discutido anteriormente, hay múltiples modos, con algunas estaciones de clientes conectadas con SNR de uplink bajo y otras conectadas con SNR de uplink alto. Si uno de los sitios del cliente tiene un

SNR de uplink promedio de estación de cliente de 31 dB (la línea discontinua negra), ¿eso es bueno o malo? De hecho está justo en el medio de toda la distribución, y esos es todo lo que podemos decir de la distribución total. Sin embargo, se puede mejorar usando grupos de pares creados con nuestro flujo de trabajo de AIOps.



Aquí vemos que los sitios de nuestros clientes entran en varios grupos de pares diferentes para entornos. (Nota: este es solo un recorte de un espacio de alta dimensión, por lo que se espera que muchas distribuciones se vean similares). Dos de las distribuciones se destacan, los grupos de pares 6 y 8, en azul y rojo respectivamente. En términos generales, el grupo de pares 6 tiende a estar compuesto de PA más antiguos colocados al aire libre, mientras que el grupo de pares 8 consiste de modelos mixtos e implementaciones medianas. Nuestro mismo sitio de prueba de más arriba con SNR de uplink promedio de estación de cliente de 31 dB, estaría en el percentil 73 para el grupo de pares 6, pero solo en el percentil 21 para el grupo de pares 8. Por sí sola, la información permite que nuestros clientes perfeccionen sus sitios con problemas. Además, como veremos en la próxima sección, también podemos usar el rendimiento relativo de un sitio comparado con sus pares para recomendar cambios y optimizar el funcionamiento del sitio.

La adición de grupos de pares a nuestras soluciones de AIOps permite que comparemos sitios con precisión mucho mayor y es un bloque de construcción clave para nuestra capacidad de recomendar mejoras para un sitio o red con base en el rendimiento y la configuración de los pares. Usando Aruba Central, recopilamos continuamente terabytes de datos y miles de perfiles de sitios para que las recomendaciones sean optimizadas y proporcionen los resultados más positivos.

EN RESUMEN: LAS PERCEPCIONES DE IA PROPORCIONAN RECOMENDACIONES ACCIONABLES

Con una infraestructura de IA fuerte, acceso a los datos del entorno y el uso de grupos de pares, ilustraremos a continuación como combinamos esas técnicas para proporcionar información de IA concreta y confiable a nuestros clientes. Aruba AI Insights proporciona análisis, datos y recomendaciones necesarias para que el equipo de TI corrija errores con rapidez, evite problemas y optimice continuamente las redes cableadas, inalámbricas o WAN con una diversa gama de factores.

Para ilustrar el poder de AI Insights y cómo funciona, definiremos un concepto clave: eficiencia de tiempo de transmisión. **Eficiencia de tiempo de transmisión** es una medida de Aruba usada para clasificar el rendimiento de Wi-Fi para un punto de acceso (PA), un edificio, o todas las instalaciones del cliente. Si un punto de acceso proporciona enlaces de alto SNR con alta velocidad en bandas accesibles para la mayoría de los dispositivos de clientes presentes, entonces tiene una eficiencia de tiempo de transmisión alta.

Como ejemplo de eficiencia de tiempo de transmisión, veamos dos PA diferentes: "PA A" en rojo y "PA B" en azul, en la Figura 1 a continuación. Estos PA son del mismo modelo, tienen entornos similares y aproximadamente el mismo número de estaciones de clientes conectados todos los días. En un día determinado, podemos ver algunas medidas relacionadas con la eficiencia de tiempo de transmisión: el SNR (relación señal a ruido) de uplink del cliente y la velocidad de uplink del cliente.

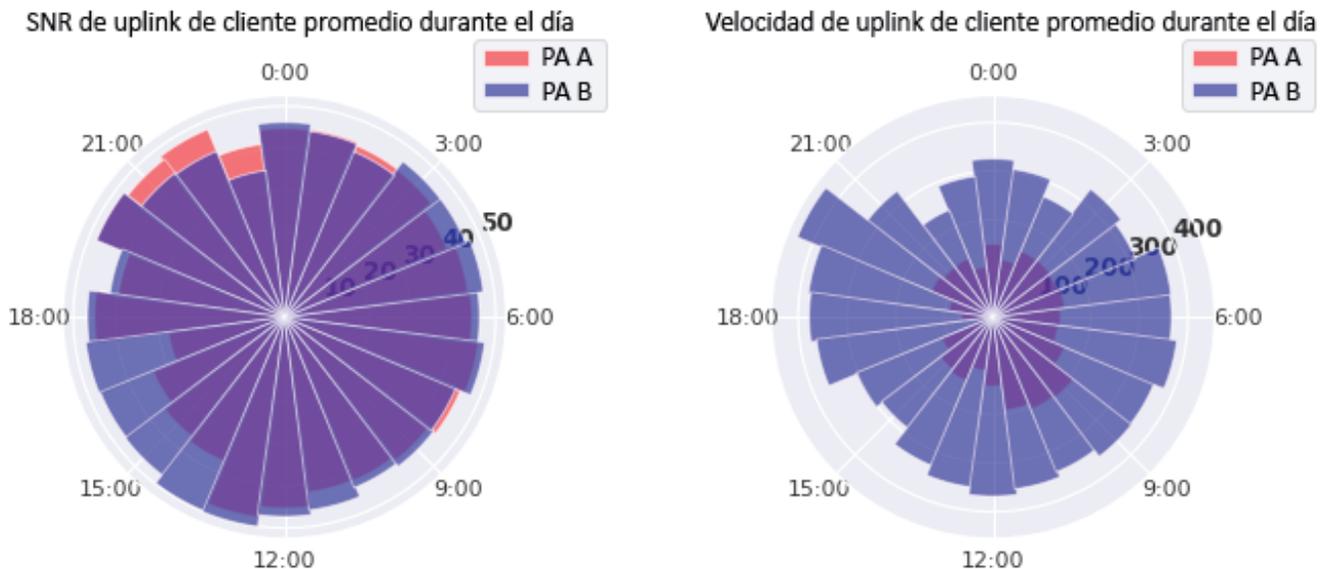


Figura 1 (Izquierda) SNR de uplink promedio por cliente de todos los clientes conectados en cada hora de un día. (Derecha) Velocidad de uplink promedio por cliente de todos los clientes conectados en cada hora de un día.



Los dos PA tienen una SNR muy similar, de 30 a 40 dB durante la mayor parte del día. Hay algunos períodos en que el PA B tiene un rendimiento mucho mejor que el PA A, pero la diferencia a lo largo del día no es significativa. Sin embargo, hay una diferencia significativa en las velocidades de uplink obtenidas por los PA A y B: el PA B tuvo velocidades promedio de 2 a 3 veces superiores. El motivo podría ser un problema de hardware, y tenemos mecanismos para verificarlo, pero en este caso, la única diferencia real entre esos dos PA son los **ajustes de configuración**. Pasemos ahora a discutir el rendimiento en un edificio.

Configurar el Wi-Fi de un edificio requiere mucho conocimiento y trabajo especializado. Debe estimarse el número promedio de estaciones de clientes y la demanda pico. Es necesario instalar una cantidad de PA suficiente para que no queden áreas sin cobertura, pero no demasiados para que no ocurra interferencia (y para que no aumenten los costos del proyecto). Existen muchos otros factores que deben considerarse, pero la implementación inicial es solo una pequeña parte del escenario total de la red. Los cambios de comportamiento y de demanda del cliente pueden afectar hasta a las redes mejor proyectadas. Agregue una de nuestras soluciones AIops: **recomendaciones de configuración**.

Existe una docena de diferentes perillas que se pueden ajustar para optimizar el rendimiento de la red inalámbrica, incluyendo la potencia de transmisión y el número de canales. Ya no necesitamos adivinar para optimizar la red aprovechando la IA y nuestro amplio conjunto de datos con información sobre rendimiento de Wi-Fi, recopilado durante años para recomendar los ajustes de configuración óptimos.

Calculamos la eficiencia del tiempo de transmisión de las redes de todos nuestros clientes y las guardamos junto con las características de los entornos y los ajustes de configuración para cada edificio. Luego, para cada edificio candidato, buscamos todos los edificios similares por entorno, y usamos IA para considerar la posible mejora de rendimiento al cambiar cada conjunto de configuraciones por los de los principales pares. Si encontramos mejoras significativas y nuestro modelo de IA confía en los resultados, entonces le recomendamos los nuevos ajustes a nuestro cliente. La figura 2 muestra los resultados de ese proceso.

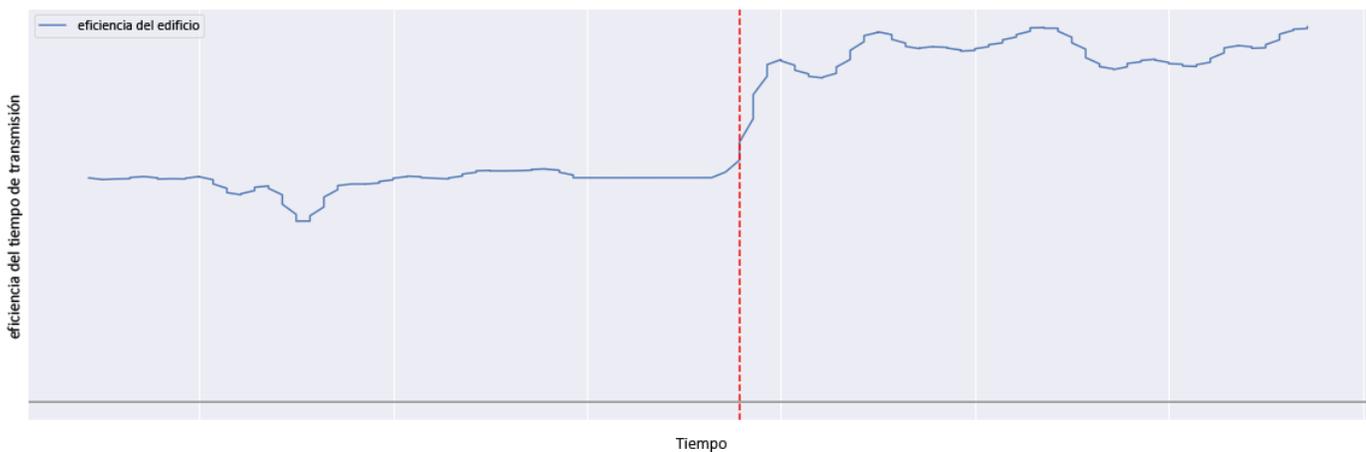


Figura 2. Gráfico de eficiencia de tiempo de transmisión X tiempo La línea gris es el origen. La línea roja es el momento en que se aplicaron los cambios de configuración recomendados.



La eficiencia del tiempo de transmisión en un edificio se muestra en función del tiempo. La información de IA enfocada en esa área encontró una configuración candidata para mejorar el rendimiento de la red para ese edificio con las decenas de miles de conjuntos de datos de entornos de clientes, y recomendamos ese cambio al cliente. El cambio se implementó en el tiempo indicado por la línea discontinua roja, y el cambio de rendimiento fue inmediato. En este caso, la mejora fue del 50 %. Y lo mejor es que, a medida que vamos mejorando las redes con nuestros clientes, la IA obtiene más opciones, y el edificio puede ser optimizado nuevamente en el futuro con los nuevos datos. Además, si la utilización real del edificio cambia, nuestro algoritmo lo detecta y recomienda los cambios apropiados. El próximo paso es facilitar esto aún más para nuestros clientes, al aplicar automáticamente la información de IA.

Para finalizar, veamos de nuevo los PA de la figura 1. En verdad, no son dos PA diferentes, sino el mismo PA observado en un dado día de la semana (PA A) y una semana después del cambio de configuración (PA B) recomendado por nuestro algoritmo, mostrado en la figura 2. Al usar la solución AIOps, nuestro cliente pudo mejorar las velocidades proporcionadas por un factor de 3, también mejorando un poco la calidad de la señal (SNR) de las conexiones, efectos estos capturados por nuestras medidas de la eficiencia del tiempo de transmisión del edificio.

RESUMEN: AI + AUTOMATIZACIÓN = AIOps CONFIABLE

La inteligencia artificial del Procesamiento de lenguaje natural para acceso rápido a la información de aprendizaje automático con o sin supervisión para diagnóstico, corrección y optimización de redes puede ser un aliado clave para el equipo de TI. No necesita ser un científico de datos para aprovechar su poder, pero es importante comprender lo que separa a una IA confiable de una que no cumple lo que promete.

Aruba proporciona cinco elementos cruciales para el éxito de la IA: acceso al volumen y variedad de datos necesarios para entrenar a los modelos, conocimiento de dominio para saber qué problemas hay que corregir, conocimiento de ciencia de datos para aplicar la tecnología adecuada a cada problema, años de validación de clientes de IA operando en entornos vivos, y la capacidad de adaptarse al tamaño de cualquier organización.