ReGeo ISSN: 2177-3246

CONECTIVIDADE NÃO É INTELIGÊNCIA: A SAÚDE OPERACIONAL COMO PRÓXIMA EVOLUÇÃO DOS DISPOSITIVOS CONECTADOS

CONNECTIVITY IS NOT INTELLIGENCE: OPERATIONAL HEALTH AS THE NEXT EVOLUTION OF CONNECTED DEVICES

LA CONECTIVIDAD NO ES INTELIGENCIA: LA SALUD OPERACIONAL COMO LA PRÓXIMA EVOLUCIÓN DE LOS DISPOSITIVOS CONECTADOS

https://doi.org/10.56238/revgeov17n9-081

Data de submissão: 16/08/2026 **Data de publicação:** 16/09/2026

Airton J. Hess Jr.
Pós-graduado em Ciências da Computação
Instituição: SmartGreen Desenvolvimento de Tecnologias
E-mail: airton@hess.com.br

RESUMO

A primeira grande transformação proporcionada pela Internet das Coisas (IoT) foi tornar o mundo físico visível: sensores, dispositivos e plataformas passaram a produzir volumes crescentes de dados sobre equipamentos, cidades e infraestruturas. Entretanto, conectividade e telemetria não significam, necessariamente, compreensão. Um dispositivo pode permanecer on-line, responder a comandos e continuar transmitindo dados mesmo enquanto se degrada, perde eficiência ou se aproxima de uma falha. Objetivo: propor e formalizar o conceito de Saúde Operacional de dispositivos IoT, deslocando o paradigma do monitoramento por eventos (alarmes por limite) para um modelo contínuo de diagnóstico. Método: desenvolve-se, por abordagem analítico-conceitual apoiada em prova de conceito com dados sintéticos, uma cadeia de transformação — telemetria, normalização, ponderação por criticidade, índice, vetor multidimensional, memória temporal e tendência — validada em um cenário de telegestão de iluminação pública. Resultados: no cenário simulado, o Índice de Saúde de uma luminária cai de 94,0% para 62,4% em doze semanas, com aceleração da degradação (de −1,6 para −3,7 pontos percentuais por semana), sem que nenhuma variável isolada cruze seu limite crítico — evidenciando a janela do "quase errado" invisível ao monitoramento tradicional. Demonstra-se ainda que dois dispositivos com índice global idêntico (62%) podem exigir intervenções opostas, e que a agregação linear pode mascarar uma dimensão crítica. Em validação de campo sobre 15.717 dispositivos de um sistema real de telegestão, o método identificou 9,4% de equipamentos com assinatura de sobrecorrente, concentrados (98%) em um único modelo de luminária (taxa de 14,45%) e ausentes em quatro projetos-controle operados na mesma noite, demonstrando aplicação populacional em escala. Contribuição: o modelo converte telemetria em condição, condição em diagnóstico, diagnóstico em tendência e tendência em decisão, oferecendo base auditável para manutenção preditiva, autodiagnóstico em edge computing e governança do ciclo de vida de populações de dispositivos — com aplicação direta à infraestrutura urbana digital, como a iluminação pública inteligente.

Palavras-chave: Saúde Operacional. Internet das Coisas. Manutenção Preditiva. Índice de Saúde. Cidades Inteligentes. Telegestão de Iluminação Pública.

ABSTRACT
The first great transformation brought by the Internet of Things (IoT) was making the physical world visible: sensors, devices and platforms began to produce growing volumes of data about equipment, cities and infrastructure. However, connectivity and telemetry do not necessarily mean understanding. A device may remain online, respond to commands and keep transmitting data while it degrades, loses efficiency or approaches failure. This paper proposes and formalizes the concept of Operational Health of IoT devices, shifting the paradigm from event-based monitoring (threshold alarms) to a continuous diagnostic model. Through an analytical-conceptual approach supported by a synthetic-data proof of concept, a transformation chain is developed — telemetry, normalization, criticality weighting, index, multidimensional vector, temporal memory and trend — and validated in a public-lighting telemanagement scenario. In the simulation, the Health Index of a luminaire drops from 94.0% to 62.4% over twelve weeks, with accelerating degradation, while no individual variable crosses its critical threshold. In a field validation over 15,717 devices of a real telemanagement system, the method detected 9.4% of equipment with an overcurrent signature, concentrated in a single luminaire model (14.45%) and absent in four control projects operated on the same night, demonstrating population-scale application to urban digital infrastructure. The model turns telemetry into condition, condition into diagnosis, diagnosis into trend and trend into decision, providing an auditable basis for predictive maintenance, edge self-diagnosis and life-cycle governance of device populations.

Keywords: Operational Health. Internet of Things. Predictive Maintenance. Health Index. Smart Cities. Public Lighting Telemanagement.

RESUMEN
La primera gran transformación proporcionada por el Internet de las Cosas (IoT) fue hacer visible el mundo físico: sensores, dispositivos y plataformas comenzaron a producir volúmenes crecientes de datos sobre equipos, ciudades e infraestructuras. Sin embargo, la conectividad y la telemetría no significan, necesariamente, comprensión. Un dispositivo puede permanecer en línea, responder a comandos y continuar transmitiendo datos mientras se degrada, pierde eficiencia o se acerca a una falla. Este documento propone y formaliza el concepto de Salud Operacional de dispositivos IoT, desplazando el paradigma del monitoreo basado en eventos (alarmas por límite) a un modelo continuo de diagnóstico. A través de un enfoque analítico-conceptual apoyado en una prueba de concepto con datos sintéticos, se desarrolla una cadena de transformación — telemetría, normalización, ponderación por criticidad, índice, vector multidimensional, memoria temporal y tendencia — y se valida en un escenario de telegerencia de iluminación pública. En la simulación, el Índice de Salud de una luminaria cae de 94,0% a 62,4% en doce semanas, con degradación acelerada, mientras que ninguna variable individual cruza su umbral crítico. En una validación de campo sobre 15.717 dispositivos de un sistema real de telegerencia, el método detectó 9,4% de equipos con una firma de sobrecorriente, concentrados en un único modelo de luminaria (14,45%) y ausentes en cuatro proyectos de control operados en la misma noche, demostrando aplicación a escala poblacional en infraestructuras digitales urbanas. El modelo convierte la telemetría en condición, la condición en diagnóstico, el diagnóstico en tendencia y la tendencia en decisión, proporcionando una base auditable para mantenimiento predictivo, autodiagnóstico en computación de borde y gobernanza del ciclo de vida de poblaciones de dispositivos.

Palabras clave: Salud Operacional. Internet de las Cosas. Mantenimiento Predictivo. Índice de Salud. Ciudades Inteligentes. Telegerencia de Iluminación Pública.

1 INTRODUÇÃO

Durante alguns anos, pareceu que a Internet das Coisas (IoT) havia resolvido o problema do controle de ativos distribuídos. Conectaram-se equipamentos, distribuíram-se sensores, construíram-se redes de comunicação e criaram-se plataformas, *dashboards*, alertas e centros capazes de acompanhar milhões de dispositivos simultaneamente (ATZORI; IERA; MORABITO, 2010; GUBBI *et al.*, 2013). A sensação era quase inevitável: agora há controle. O mundo físico, contudo, revelou uma realidade mais complexa. Um equipamento pode continuar funcionando e, ainda assim, estar se degradando; pode permanecer on-line enquanto perde eficiência; pode responder a comandos enquanto um componente interno se aproxima silenciosamente do fim de sua vida útil.

Esse comportamento decorre de algo que nenhum *dashboard* elimina: o tempo. Componentes envelhecem, materiais sofrem desgaste, temperaturas variam, ciclos se acumulam, redes elétricas oscilam e sensores sofrem deriva. Grande parte desse processo acontece *antes* que qualquer alarme seja disparado. É justamente no intervalo entre funcionar e falhar que reside uma oportunidade ainda pouco explorada.

O problema central deste trabalho não é a escassez de dados, nunca se teve tanta telemetria, mas a lacuna entre *medir* e *compreender*. Um sistema tradicional responde com facilidade à pergunta "o dispositivo está on-line?", mas deveria responder também "como está esse dispositivo?". Esta segunda pergunta exige compreender a condição elétrica, funcional, energética, térmica e temporal do ativo, e a literatura de *Prognostics and Health Management* (PHM) e manutenção baseada em condição (CBM) oferece fundamentos maturos para máquinas rotativas e sistemas industriais (JARDINE; LIN; BANJEVIC, 2006; LEE *et al.*, 2014), ainda pouco transpostos para populações massivas de dispositivos IoT de baixo custo operando em campo, como as luminárias que compõem a infraestrutura de iluminação pública de uma cidade inteligente, ativo urbano crítico cuja gestão eficiente é, também, questão de desenvolvimento regional e de governança pública.

Assim, formula-se a questão de pesquisa: *como transformar, de forma contínua, auditável e escalável, a telemetria de dispositivos IoT em uma medida interpretável de sua condição e de sua tendência de degradação?* O objetivo geral é propor e formalizar o conceito de Saúde Operacional, materializado em um Índice de Saúde, em um vetor multidimensional (o "Raio-X funcional" do dispositivo) e em indicadores de tendência. Os objetivos específicos são: (i) formalizar a cadeia de transformação de sinais físicos em saúde; (ii) discutir os efeitos da agregação linear e não linear; e (iii) demonstrar o modelo em uma prova de conceito de telegestão de iluminação pública. Os conceitos aqui apresentados integram a metodologia desenvolvida pelo autor na trilogia *O Genoma do IoT*, *O Raio-X do IoT* e *A Gênese do IoT*.

O artigo está organizado em sete seções. A seção 2 revisa a literatura de PHM, RUL, índice de saúde e *edge computing*. A seção 3 descreve o método. A seção 4 formaliza o modelo proposto. A seção 5 apresenta a prova de conceito e a validação em campo sobre uma base real de 15.717 dispositivos de iluminação pública inteligente. A seção 6 discute implicações e limitações, e a seção 7 conclui.

2 REFERENCIAL TEÓRICO

2.1 DO MONITORAMENTO POR EVENTOS AO PHM

A arquitetura tradicional de monitoramento é fortemente baseada em limites: quando uma variável ultrapassa um valor, gera-se um alarme. Essa lógica é útil e continuará necessária, mas identifica o problema apenas quando ele já se tornou evidente (MOBLEY, 2002). A manutenção baseada em condição (CBM) e o PHM propõem, em contraste, inferir o estado de saúde a partir do processamento de sinais para antecipar falhas (JARDINE; LIN; BANJEVIC, 2006; VACHTSEVANOS *et al.*, 2006). Um alarme se assemelha a um grito, informa que algo aconteceu; um diagnóstico procura compreender por que está acontecendo, há quanto tempo e o que provavelmente ocorrerá em seguida.

2.2 PROGNÓSTICO E VIDA ÚTIL REMANESCENTE

A estimativa da vida útil remanescente (*Remaining Useful Life*, RUL) sistematiza o horizonte até a falha por abordagens estatísticas e orientadas a dados (SI *et al.*, 2011; PENG; DONG; ZUO, 2010). Revisões sistemáticas associam o PHM à Indústria 4.0, apontando a convergência entre IoT, aprendizado de máquina e manutenção preditiva (ZONTA *et al.*, 2020). O presente trabalho posiciona-se a montante do RUL: antes de estimar quando o ativo falhará, propõe uma medida contínua e interpretável de *quão saudável* ele está e de *para onde* caminha.

2.3 ÍNDICE DE SAÚDE E GESTÃO DE ATIVOS

A ideia de condensar múltiplos indicadores em um único índice de saúde já é consolidada na gestão de ativos elétricos, notadamente em transformadores de potência, nos quais fatores ponderados de condição produzem um *Health Index* que orienta priorização e substituição (JAHROMI *et al.*, 2009). Normas internacionais oferecem o arcabouço: a ISO 13374 padroniza o processamento, a comunicação e a apresentação de dados de monitoramento de condição em blocos funcionais (aquisição, manipulação, detecção de estado, avaliação de saúde e prognóstico) (ISO, 2003), e a ISO 55000 estabelece princípios de gestão de ativos ao longo do ciclo de vida (ISO, 2014). A contribuição

deste artigo é transpor e generalizar o índice de saúde, historicamente aplicado a ativos individuais de alto valor, para populações massivas, heterogêneas e distribuídas de dispositivos IoT.

2.4 EDGE COMPUTING, GÊMEOS DIGITAIS E AUTODIAGNÓSTICO

A maior capacidade computacional embarcada e o *edge computing* permitem deslocar parte da inteligência para o próprio dispositivo, reduzindo latência e dependência da nuvem (SHI *et al.*, 2016). Em paralelo, gêmeos digitais têm sido acoplados ao PHM para representar e prever a condição de equipamentos complexos (TAO *et al.*, 2018). Esses movimentos sustentam a hipótese, adiante desenvolvida, de dispositivos capazes de calcular localmente a própria saúde e comunicar não apenas dados, mas conhecimento sobre si.

2.5 LACUNA DE PESQUISA

A literatura consolida PHM, RUL e índice de saúde sobretudo para máquinas industriais e ativos individuais de alto valor. Persiste, entretanto, uma lacuna: um modelo contínuo, auditável e escalável de saúde operacional para populações de dispositivos IoT de campo, como as luminárias de uma cidade sob telegestão,, que integre índice global, decomposição multidimensional, memória temporal e tendência, e que seja leve o bastante para execução em *edge*. É essa lacuna que o modelo a seguir busca preencher.

3 MÉTODO

Adota-se abordagem analítico-conceitual com prova de conceito (*proof of concept*), aproximando-se do paradigma da *Design Science Research*, cujo produto é um artefato, o Índice de Saúde Operacional, avaliado quanto à sua utilidade e coerência interna. O modelo é formalizado matematicamente (seção 4) e avaliado em dois níveis complementares (seção 5): uma *demonstração controlada*, sobre dados sintéticos que reproduzem padrões físicos plausíveis de degradação de uma luminária, e uma *validação de campo*, sobre uma base real de 15.717 dispositivos de um sistema de telegestão de iluminação pública.

A demonstração controlada, com dados sintéticos, permite exercitar os mecanismos que uma leitura real pontual não revela, trajetória temporal, tendência e comparação antes/depois, controlar as condições e garantir reprodutibilidade integral, pois todos os valores foram gerados e calculados computacionalmente. A validação de campo, por sua vez, confronta o modelo com a realidade operacional e com a escala populacional. Os dados de campo provêm de leituras instantâneas transmitidas na noite de 09 para 10 de junho de 2026; nomes de projeto e de fabricante foram

anonimizados e não se relatam valores comerciais ou identificadores pessoais, em conformidade com práticas de confidencialidade. A proposta metodológica pode ser resumida na cadeia de transformação:

TELEMETRIA → NORMALIZAÇÃO → PONDERAÇÃO → ÍNDICE → RAIO-X → TEMPO → DECISÃO

Cada etapa cumpre uma função específica, detalhada a seguir. O princípio orientador não é medir mais, e sim compreender melhor.

4 O MODELO DE SAÚDE OPERACIONAL

Define-se Saúde Operacional como *o grau de proximidade entre o comportamento real do dispositivo e sua condição técnica ideal, considerando sua história e evolução temporal*. Abandona-se a visão binária OK/FALHA em favor de uma escala contínua de 0% a 100%, na qual um dispositivo com saúde de 93% não é lido do mesmo modo que outro com 61%, e dois dispositivos com 61% podem representar riscos distintos conforme as dimensões afetadas e sua tendência.

4.1 NORMALIZAÇÃO DAS VARIÁVEIS

Variáveis físicas possuem unidades distintas (volts, amperes, watts, graus, indicadores de qualidade de enlace). Para combiná-las, cada variável *i* é convertida em uma saúde parcial $h_i \in [0, 1]$, em que 1 representa condição próxima do ideal e 0, condição severamente degradada. Para uma variável na qual valores maiores são piores (ex.: temperatura, consumo, instabilidade de corrente), com valor nominal *x_nom* e crítico *x_crit*:

$$h_i = clamp[\ (x_crit - x) / (x_crit - x_nom),\ 0,\ 1\ ] \quad (1)$$

Para uma variável na qual valores menores são piores (ex.: fator de potência, eficiência, taxa de entrega de pacotes):

$$h_i = clamp[\ (x - x_crit) / (x_nom - x_crit),\ 0,\ 1\ ] \quad (2)$$

em que $clamp(z, 0, 1) = min(1, max(0, z))$. Normalizar, porém, não é apenas reescalar números: é interpretar tecnicamente o que é normal, aceitável, degradado e crítico para cada variável. A Tabela 1 apresenta os limites adotados na prova de conceito.

Tabela 1. Limites técnicos de normalização adotados

Variável	Nominal	Crítico	Sentido
Consumo / potência ativa (W)	100	130	maior é pior
Fator de potência	0,98	0,85	menor é pior
Instabilidade de corrente – CV (%)	1,0	8,0	maior é pior
Temperatura operacional (°C)	45	85	maior é pior
Eficiência relativa (%)	100	70	menor é pior
Taxa de entrega de pacotes (%)	99	80	menor é pior

Fonte: Elaborado pelos autores, 2026

4.2 PONDERAÇÃO POR CRITICIDADE E ÍNDICE GLOBAL

Nem toda variável tem a mesma relevância: uma variação térmica não pesa como uma perda de comunicação, nem uma alteração de fator de potência como uma falha de atuação. As variáveis são agrupadas em dimensões *d* (Energia, Controle, Comunicação, Eficiência e Tempo), e a saúde de cada dimensão é a média das saúdes parciais de suas variáveis:

$$H_d = (1 / |V_d|) \cdot \Sigma_{i \in V_d} h_i \quad (3)$$

A cada dimensão atribui-se um peso de criticidade w_d, com $\Sigma\, w_d = 1$. O índice de saúde global resulta de uma soma ponderada, convertida à escala percentual:

$$H = \Sigma_d\, w_d \cdot H_d\,, \; H(\%) = 100 \cdot H \quad (4)$$

A simplicidade dessa formulação é uma vantagem: ela é compreensível, reproduzível e auditável, requisito essencial para uso em contratos e auditorias. A Tabela 2 apresenta os pesos adotados.

Tabela 2. Dimensões e pesos de criticidade

Dimensão	**Peso (w_d)**	**Interpretação**
Energia	0,30	condição elétrica/térmica
Controle	0,20	atuação e comando
Eficiência	0,20	entrega por unidade consumida
Comunicação	0,15	qualidade do enlace
Tempo	0,15	desgaste acumulado

Fonte: Elaborado pelos autores, 2026

4.3 AGREGAÇÃO NÃO LINEAR E O RISCO DE COMPENSAÇÃO

A soma ponderada tem uma limitação estrutural: uma dimensão saudável pode compensar artificialmente uma dimensão crítica. Em aplicações mais sensíveis, emprega-se uma agregação não linear, por exemplo, a média geométrica ponderada, que penaliza fortemente qualquer dimensão próxima de zero:

$$H_g = \Pi_d (H_d)^{w_d} \quad (5)$$

A escolha entre (4) e (5) é, ela própria, uma decisão de projeto de diagnóstico, cujos efeitos são quantificados na seção 5.3.

4.4 O VETOR MULTIDIMENSIONAL: O RAIO-X FUNCIONAL

Um número isolado resume, mas não diagnostica. Propõe-se representar a condição do equipamento por um vetor multidimensional de saúde:

$$\boldsymbol{H} = [\, H_{Energia} , H_{Controle} , H_{Comunicação} , H_{Eficiência} , H_{Tempo} \,] \quad (6)$$

O índice global resume; o vetor diagnostica. Representado graficamente, por exemplo, em visualização radial, o vetor revela *onde* está a degradação. Denomina-se essa representação o Raio-X funcional do dispositivo: a forma passa a informar a natureza do problema.

4.5 MEMÓRIA TEMPORAL

Um equipamento não é apenas o que mede agora; é também o que viveu. Dois dispositivos com leituras instantâneas semelhantes podem ter condições distintas se um acumulou 1.000 horas de operação e outro, 50.000, o mesmo valendo para o número de ciclos de acionamento. Por isso, a

dimensão Tempo incorpora memória, agregando tempo acumulado de operação, horas em carga, número de ciclos, histórico térmico e desvios acumulados em relação ao comportamento ideal:

H_Tempo(t) = f(horas acumuladas, ciclos, histórico térmico, ocorrências)

O fator temporal transforma uma fotografia em uma história, e é a história que permite identificar a degradação.

4.6 TENDÊNCIA E ACELERAÇÃO

Conhecer a saúde atual já é um avanço; o salto ocorre ao observar sua trajetória. Um dispositivo com 72% estável há meses difere radicalmente de outro que caiu de 91% para 72% em semanas. Além do valor *H*, observa-se sua variação (a inclinação), estimada por diferença finita ou regressão linear em uma janela de *k* períodos:

$$dH/dt \approx (H_t - H_{t-k}) / k \quad (7)$$

Inclinação persistentemente negativa evidencia degradação. Quando a própria velocidade de queda aumenta, há aceleração da degradação, sinal ainda mais relevante:

$$d^2H/dt^2 < 0 \Rightarrow \text{aceleração da degradação} \quad (8)$$

É nesse ponto que o diagnóstico se aproxima da predição: o sistema deixa de responder apenas “como está?” e passa a responder “para onde está indo?”.

5 APLICAÇÃO E VALIDAÇÃO

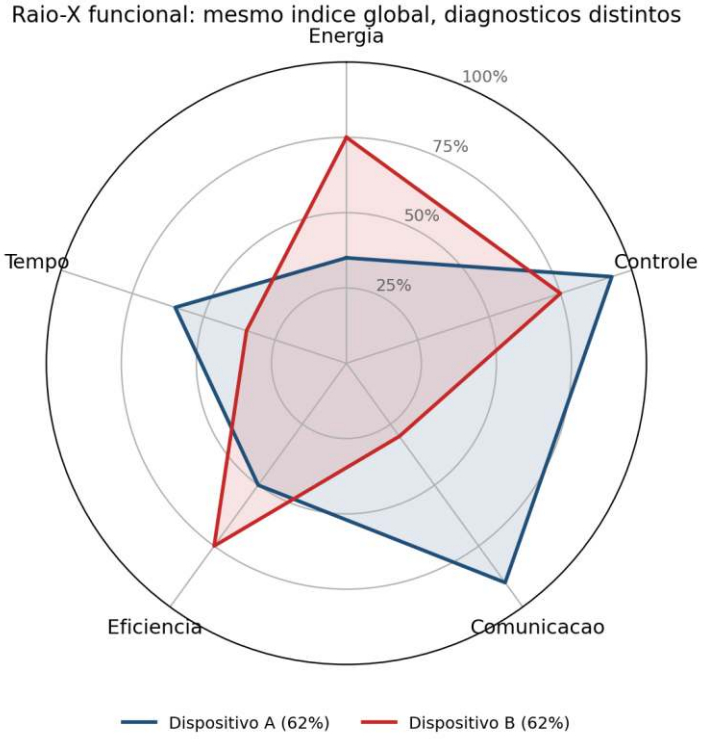
O modelo é avaliado em dois níveis. Primeiro, uma demonstração controlada (subseções 5.1 a 5.4) exercita seus mecanismos sobre dados sintéticos, adotando os limites da Tabela 1 e os pesos da Tabela 2. Em seguida, uma validação de campo (subseções 5.5 a 5.7) aplica a lógica de diagnóstico a uma base real de telegestão de iluminação pública, em escala populacional.

5.1 MESMO ÍNDICE GLOBAL, DIAGNÓSTICOS DISTINTOS

Considerem-se dois dispositivos com índice global praticamente idêntico, cerca de 62%. O Dispositivo A apresenta degradação elétrica e de eficiência (Energia 35%, Eficiência 50%), com boa comunicação e controle; o Dispositivo B tem eletrônica saudável, mas crise de comunicação e envelhecimento avançado (Comunicação 30%, Tempo 35%). Os índices globais coincidem; os

problemas, e as intervenções necessárias, são opostos. A Figura 1 evidencia, pela forma do Raio-X, o que o número isolado oculta.

Figura 1. Raio-X funcional de dois dispositivos com índice global idêntico



Fonte: Elaborado pelos autores, 2026

5.2 TRAJETÓRIA TEMPORAL DE UMA LUMINÁRIA

Simula-se uma luminária inteligente ao longo de doze semanas. Ela permanece acesa, responde a comandos e está on-line, pelo modelo tradicional, receberia classificação normal. Seu histórico, contudo, revela uma assinatura de degradação: o consumo aumenta, o fator de potência cai, a corrente se torna mais instável, a temperatura sobe e a eficiência diminui. A Tabela 3 apresenta a evolução; a Figura 2, a trajetória do índice.

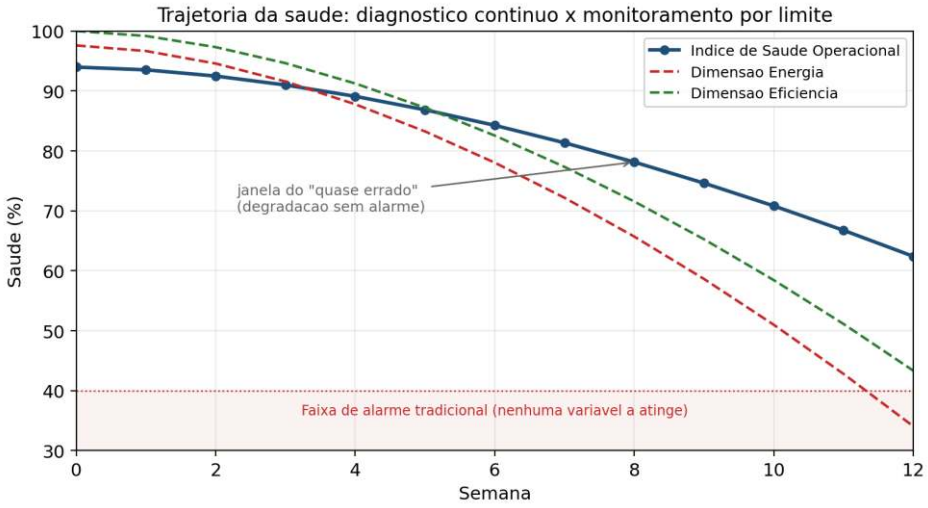
Tabela 3. Evolução semanal da telemetria e da saúde da luminária

Sem.	Consumo (W)	FP	CV (%)	Temp (°C)	Efic. (%)	Saúde (%)
0	100,0	0,980	1,5	46,0	100,0	94,0
2	100,9	0,976	1,7	47,2	99,2	92,5
4	102,8	0,968	2,3	50,0	97,4	89,1
6	105,5	0,957	3,0	54,0	94,8	84,3
8	109,0	0,942	4,0	59,1	91,5	78,1
10	113,2	0,925	5,2	65,1	87,5	70,8
12	118,0	0,905	6,5	72,0	83,0	62,4

Nenhuma variável cruza seu limite crítico (Tabela 1) no período.
Fonte: Elaborado pelos autores, 2026

O índice cai de 94,0% para 62,4%, mais de 31 pontos percentuais, sem que *nenhuma* variável cruze seu limite crítico (consumo 118 < 130 W; FP 0,905 > 0,85; CV 6,5 < 8%; temperatura 72 < 85 °C; eficiência 83 > 70%). Um sistema por limite não teria emitido alarme. A inclinação média é de −2,67 pontos percentuais por semana, e a degradação acelera: passa de −1,64 na primeira metade para −3,65 pp/semana na segunda (aceleração de −2,01 pp/semana²). A Figura 2 destaca a janela do "quase errado", a região anterior ao alarme, na qual a manutenção ainda pode ser planejada, o custo reduzido e a falha evitada. A luminária não falhou: ela está adoecendo.

Figura 2. Trajetória da saúde: diagnóstico contínuo versus monitoramento por limite



Fonte: Elaborado pelos autores, 2026

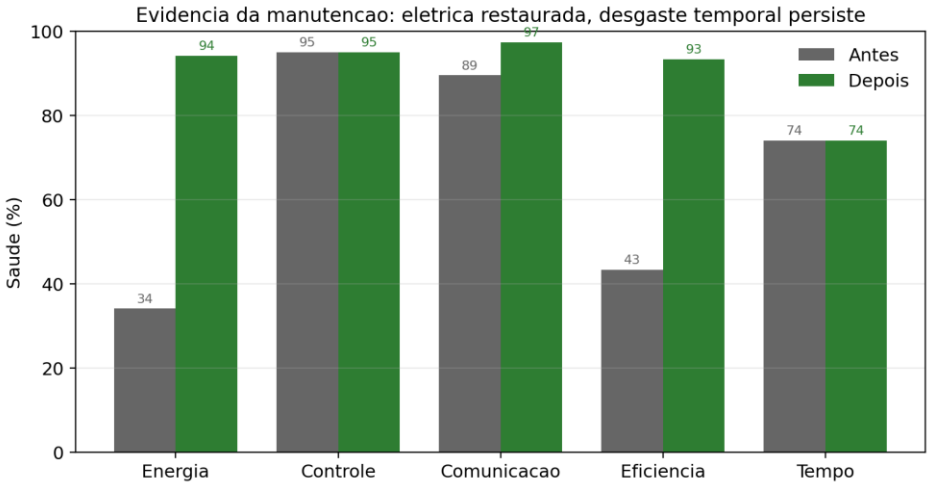
5.3 SENSIBILIDADE DA AGREGAÇÃO

Compare-se um dispositivo X com uma única dimensão em colapso (Comunicação 10%) e as demais em 90%, a um dispositivo Y uniformemente mediano (todas as dimensões em 65%). Pela agregação linear (4), X obtém 78,0% e Y, 65,0%, o linear sugere que X está mais saudável, mascarando a dimensão crítica. Pela agregação geométrica (5), X cai para 64,7% enquanto Y permanece em 65,0%: a falha estrutural deixa de ser compensada. O resultado confirma que a escolha da função de agregação é uma decisão de projeto com consequências operacionais diretas, e que aplicações críticas favorecem formulações não lineares.

5.4 EVIDÊNCIA DA MANUTENÇÃO: ANTES E DEPOIS

O modelo permite, ainda, medir tecnicamente o resultado de uma intervenção. Em operações convencionais, muitas ordens terminam com a conclusão "serviço realizado", o que não equivale a "problema resolvido". Com o Raio-X, registra-se a condição imediatamente anterior e posterior à intervenção. Na semana 12, após a substituição do *driver* da luminária, o índice global sobe de 62,4% para 91,6%. O diagnóstico, porém, está nas dimensões (Figura 3): a saúde elétrica salta de 34% para 94% e a eficiência, de 43% para 93%, mas a dimensão Tempo permanece em 74%. Ou seja, a intervenção corrigiu a condição elétrica, mas o envelhecimento acumulado persiste. A manutenção passa a produzir evidência, o que pode transformar contratos, SLAs, auditorias e relações entre fabricantes, operadores e clientes.

Figura 3. Saúde por dimensão antes e depois da intervenção



Validação de campo (base real de telegestão)
Fonte: Elaborado pelos autores, 2026

5.5 O CASO XRA

Para confrontar o modelo com a realidade operacional, aplicou-se a lógica de diagnóstico sobre uma base real, o projeto XRA (denominação fictícia por confidencialidade), a partir das leituras instantâneas de corrente, tensão, potência e fator de potência transmitidas na noite de 09 para 10 de junho de 2026 (19h às 05h). No período, 15.717 dispositivos únicos transmitiram. Adotaram-se como limiares corrente de pico superior a 1.000 mA e leitura normal inferior a 700 mA, com mínimo de cinco ocorrências para sinalização. No vocabulário do modelo, a sobrecorrente persistente corresponde ao colapso da dimensão Energia ($H_Energia \rightarrow 0$), e a proporção de leituras em pico define a criticidade do equipamento.

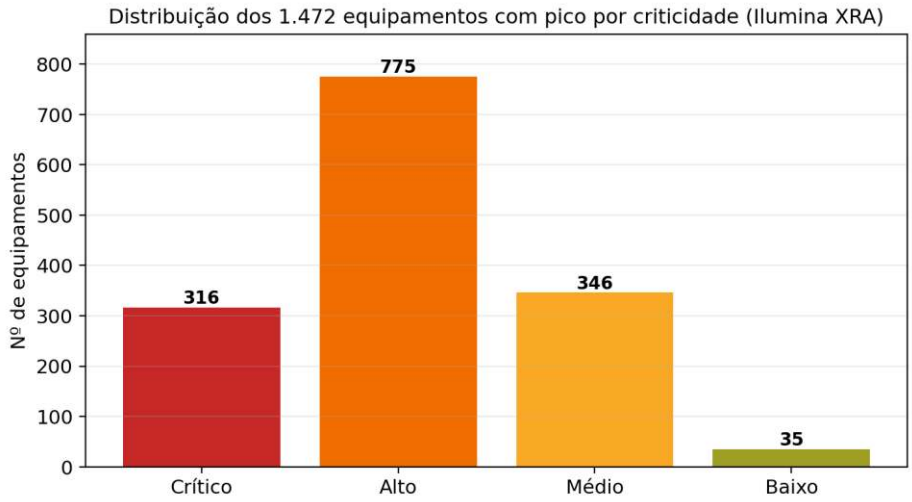
Do total, 1.472 equipamentos (9,4%) apresentaram assinatura de sobrecorrente, distribuídos em quatro níveis de criticidade (Tabela 4, Figura 4). Os 316 casos críticos operaram em sobrecorrente durante toda a noite, sem qualquer leitura na faixa normal, dispositivos que, pelo monitoramento tradicional, permaneciam “on-line” e “acesos”, mas que o diagnóstico revela em condição severa.

Tabela 4. Distribuição dos equipamentos com pico por criticidade (XRA)

Criticidade	**Qtd.**	**Critério**
Crítico	316	> 50% das leituras em pico e zero normais
Alto	775	> 50% das leituras em pico
Médio	346	> 20% das leituras em pico
Baixo	35	≥ 5 ocorrências de pico
Total	1.472	9,4% dos MACs únicos do período

Fonte: elaborado pelo autor (2026), a partir do relatório técnico REL-Raiox-001.

Figura 4. Distribuição dos equipamentos com pico por criticidade



Fonte: Elaborado pelos autores, 2026

5.6 ASSINATURA DE DEGRADAÇÃO POR MODELO E LOTE

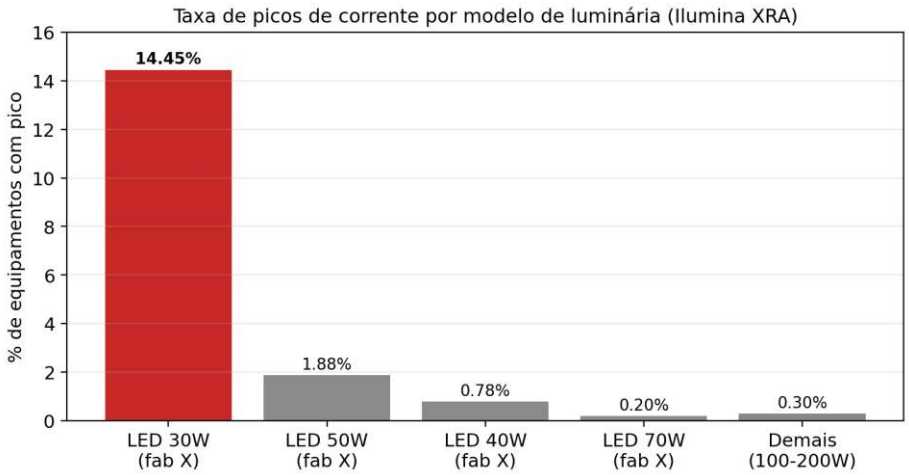
O cruzamento dos endereços físicos (MAC) com o cadastro de luminárias revelou forte concentração: a Luminária LED 30 W do fabricante X apresentou taxa de pico de 14,45% (1.442 de 9.977 unidades), contra menos de 2% em todos os demais modelos (Tabela 5, Figura 5). Praticamente a totalidade dos 316 críticos pertence a esse modelo. As correntes de pico situaram-se tipicamente entre 2.000 e 3.500 mA, muito acima do esperado para uma carga de 30 W,, com máximos de 5.000 mA e dois casos extremos acima de 30.000 mA, indicativos de falha severa de *driver*. Emerge, assim, uma assinatura de "doença" associada a um modelo/lote de fabricação, precisamente o tipo de padrão que o modelo se propõe a reconhecer, e cuja hipótese de causa raiz é a falha sistêmica no circuito de proteção de corrente de uma série específica.

Tabela 5. Taxa de picos de corrente por modelo de luminária

Modelo de luminária	**Instaladas**	**Com pico**	**% afetados**
LED 30 W (fab. X)	9.977	1.442	14,45%
LED 50 W (fab. X)	266	5	1,88%
LED 40 W (fab. X)	1.670	13	0,78%
LED 70 W (fab. X)	1.522	3	0,20%
Demais (100–200 W, fab. Y)	≈ 3.438	9	< 0,3%

Fonte: elaborado pelo autor (2026), a partir do relatório técnico REL-Raiox-001.

Figura 5. Taxa de picos por modelo de luminária



Fonte: Elaborado pelos autores, 2026

5.7 EPIDEMIOLOGIA ENTRE POPULAÇÕES DE DISPOSITIVOS

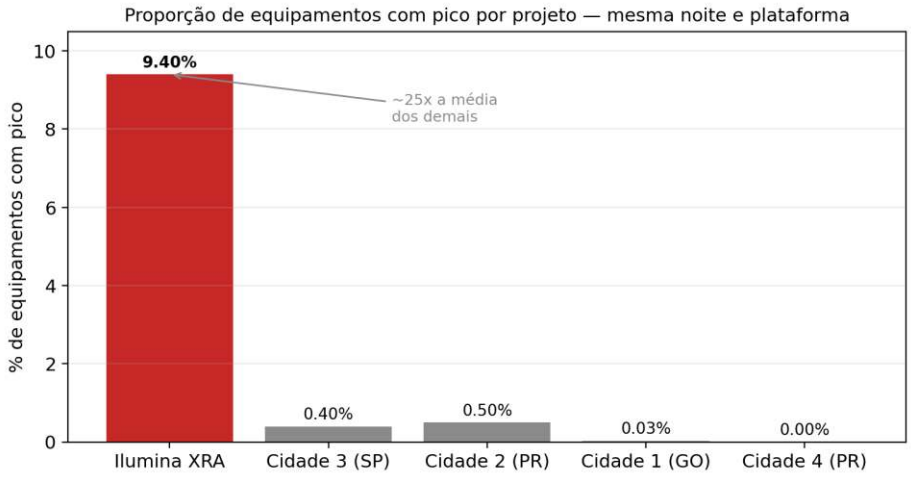
Para isolar a causa e descartar hipóteses de infraestrutura (plataforma, *gateways*, rede elétrica), a mesma análise foi aplicada a quatro outros projetos operados na mesma noite, plataforma e protocolo (Tabela 6, Figura 6). Enquanto o XRA registrou 9,4%, os demais ficaram entre 0,0% e 0,5% (média aproximada de 0,2%), proporção cerca de 25 vezes menor,, e um projeto-controle com 1.169 dispositivos ativos registrou zero picos, evidenciando que a plataforma de coleta opera corretamente. O diagnóstico deixa de ser individual e passa a operar como uma epidemiologia de populações: compara-se a saúde entre frotas, isola-se a causa raiz (o modelo/lote de um fornecedor) e orienta-se a ação corretiva, acionamento formal do fabricante, inspeção prioritária dos 316 críticos e substituição preventiva, protegendo o investimento e a vida útil do parque.

Tabela 6. Comparativo de picos de corrente entre os cinco projetos (mesma noite)

Projeto	**Eq. únicos**	**Com pico**	**% pico**	**Críticos**
XRA	15.717	1.472	9,4%	316
Cidade 1 (GO)	53.615	17	0,03%	11
Cidade 2 (PR)	2.809	15	0,5%	15
Cidade 3 (SP)	12.933	58	0,4%	47
Cidade 4 (PR)	1.169	0	0,0%	0

Fonte: elaborado pelo autor (2026), a partir do relatório técnico REL-Raiox-001.

Figura 6. Proporção de equipamentos com pico por projeto



Fonte: Elaborado pelos autores, 2026

A convergência entre a demonstração controlada e a validação de campo sustenta a hipótese central: a saúde operacional, quando formalizada, é simultaneamente interpretável no dispositivo e acionável na população, do diagnóstico individual à gestão epidemiológica de uma infraestrutura urbana inteira.

6 DISCUSSÃO

6.1 DA TELEMETRIA À GOVERNANÇA DO CICLO DE VIDA

Ao converter telemetria em condição, o modelo desloca a manutenção do calendário fixo para a condição real: equipes são enviadas primeiro aos equipamentos que de fato exigem intervenção, reduzem-se visitas improdutivas, antecipam-se falhas e identificam-se ineficiências energéticas antes que se tornem perdas relevantes. Fabricantes podem ser comparados pela trajetória real de seus equipamentos, garantias podem ser analisadas com base em comportamento e contratos podem incorporar indicadores de saúde, e não apenas de disponibilidade, alinhando a operação aos princípios de gestão de ativos da ISO 55000 (ISO, 2014).

6.2 EPIDEMIOLOGIA DE POPULAÇÕES DE DISPOSITIVOS

Quando cada equipamento possui índice e Raio-X próprios, torna-se possível calcular a saúde de populações inteiras: a saúde média de uma região, qual lote envelhece mais rápido, qual fornecedor é mais estável, qual modelo se degrada mais após três anos, qual área concentra falhas elétricas anômalas ou qual grupo demandará manutenção nos próximos meses. O conceito deixa de ser diagnóstico individual e passa a funcionar como uma epidemiologia das máquinas, administram-se não apenas equipamentos, mas populações de dispositivos. A validação de campo (seção 5.7) ilustra

concretamente esse potencial: foi essa leitura populacional que permitiu isolar, entre 15.717 dispositivos e cinco projetos, a associação entre a sobrecorrente e um único modelo/lote de luminária, um resultado inacessível ao exame de um equipamento por vez.

6.3 INTELIGÊNCIA ARTIFICIAL E ASSINATURAS DE DEGRADAÇÃO

Com índices, vetores, histórico e tendências, abre-se espaço para que a aprendizagem de máquina reconheça famílias de degradação: um determinado desenho multidimensional pode associar-se à deterioração da fonte; outro pode preceder a falha de comunicação. O sistema passa a reconhecer não apenas valores, mas assinaturas de "doença". Isso desloca a IA do terreno abstrato para um espaço tecnicamente interpretável: em vez de declarar "há uma anomalia", o sistema pode explicar que "a combinação entre aumento térmico, queda de eficiência e instabilidade de corrente apresenta alta similaridade com o padrão histórico de degradação do *driver*", aproximando-se dos requisitos de interpretabilidade caros ao PHM (LEE *et al.*, 2014).

6.4 AUTODIAGNÓSTICO EM EDGE COMPUTING

A evolução natural ocorre quando parte do processo deixa de depender exclusivamente da nuvem. Com *edge computing* (SHI *et al.*, 2016), o dispositivo pode executar localmente a normalização, o cálculo do índice e o reconhecimento de tendência, transmitindo não "corrente = 2,37 A", mas "saúde global 71%, dimensão elétrica em degradação, tendência negativa persistente, inspeção recomendada". O dispositivo deixa de ser fonte de dados para tornar-se fonte de conhecimento sobre si mesmo, o que se articula, no limite, à noção de gêmeo digital acoplado ao prognóstico (TAO *et al.*, 2018).

6.5 LIMITAÇÕES E AMEAÇAS À VALIDADE

Três limitações devem ser explicitadas. Primeiro, quanto à validação: a demonstração dos mecanismos temporais (trajetória, tendência e antes/depois) apoia-se em dados sintéticos, e a validação de campo, embora em escala populacional real, corresponde a um recorte de uma única noite, uma fotografia, não uma série longitudinal, restrita à dimensão elétrica; a consolidação plena do modelo exige acompanhar a trajetória multidimensional de dispositivos reais ao longo de semanas, etapa prevista para trabalhos futuros. Segundo, os limites de normalização (Tabela 1) e os pesos de criticidade (Tabela 2) são calibrações de engenharia dependentes de tecnologia, fabricante e ambiente; sua definição criteriosa é condição para a validade do diagnóstico, e métodos sistemáticos de calibração, inclusive orientados a dados, constituem agenda de pesquisa. Terceiro, o modelo mede

condição e tendência, mas não fornece, por si, uma estimativa formal de RUL; sua integração a modelos estatísticos de vida remanescente (SI *et al.*, 2011) é caminho promissor. Reconhecidas essas fronteiras, a contribuição central permanece: uma camada de saúde contínua, auditável e escalável entre a telemetria bruta e a decisão de manutenção.

7 CONSIDERAÇÕES FINAIS

A Internet das Coisas cumpriu uma missão extraordinária: fez o mundo físico conectar-se e falar. O próximo passo é ensinar as máquinas, e os sistemas que as administram, a compreender o significado daquilo que dizem. A Saúde Operacional propõe essa evolução, transformando telemetria em condição, condição em diagnóstico, diagnóstico em tendência, tendência em decisão e decisão em evidência.

A prova de conceito demonstrou que um índice contínuo, decomposto em um vetor multidimensional e observado ao longo do tempo, revela degradações invisíveis ao monitoramento por limite, distingue dispositivos que um índice isolado confundiria e converte a manutenção em evidência mensurável. A validação sobre uma base real de 15.717 dispositivos levou o modelo do plano conceitual ao operacional: a leitura populacional isolou a causa raiz de uma degradação, um lote específico de luminárias, e converteu telemetria em decisão corretiva, protegendo uma infraestrutura urbana. A primeira geração do IoT conectou; a segunda monitorou; a próxima precisará compreender. Talvez o futuro do IoT não pertença aos dispositivos que produzam mais dados, mas aos que consigam compreender melhor a própria condição, capazes de dizer, com inteligência e honestidade: “eu sei como estou”. As fronteiras aqui apontadas, validação em campo, calibração orientada a dados, integração ao RUL e execução em *edge*, delineiam a agenda de pesquisa dos próximos trabalhos do autor.

REFERÊNCIAS

ATZORI, L.; IERA, A.; MORABITO, G. *The Internet of Things: a survey.* Computer Networks, v. 54, n. 15, p. 2787-2805, 2010.

GUBBI, J. *et al.* Internet of Things (IoT): a vision, architectural elements, and future directions. *Future Generation Computer Systems,* v. 29, n. 7, p. 1645-1660, 2013.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. *ISO 13374-1: condition monitoring and diagnostics of machines, data processing, communication and presentation, Part 1: general guidelines.* Geneva: ISO, 2003.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. *ISO 55000: asset management, overview, principles and terminology.* Geneva: ISO, 2014.

JAHROMI, A. *et al.* An approach to power transformer asset management using health index. *IEEE Electrical Insulation Magazine,* v. 25, n. 2, p. 20-34, 2009.

JARDINE, A. K. S.; LIN, D.; BANJEVIC, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing,* v. 20, n. 7, p. 1483-1510, 2006.

LEE, J. *et al.* Prognostics and health management design for rotary machinery systems, reviews, methodology and applications. *Mechanical Systems and Signal Processing,* v. 42, n. 1-2, p. 314-334, 2014.

MOBLEY, R. K. *An introduction to predictive maintenance.* 2. ed. Amsterdam: Butterworth-Heinemann, 2002.

PENG, Y.; DONG, M.; ZUO, M. J. Current status of machine prognostics in condition-based maintenance: a review. *The International Journal of Advanced Manufacturing Technology,* v. 50, n. 1-4, p. 297-313, 2010.

SHI, W. *et al.* Edge computing: vision and challenges. *IEEE Internet of Things Journal,* v. 3, n. 5, p. 637-646, 2016.

SI, X.-S. *et al.* Remaining useful life estimation, a review on the statistical data driven approaches. *European Journal of Operational Research,* v. 213, n. 1, p. 1-14, 2011.

TAO, F. *et al.* Digital twin driven prognostics and health management for complex equipment. *CIRP Annals,* v. 67, n. 1, p. 169-172, 2018.

VACHTSEVANOS, G. *et al. Intelligent fault diagnosis and prognosis for engineering systems.* Hoboken: John Wiley & Sons, 2006.

ZONTA, T. *et al.* Predictive maintenance in the Industry 4.0: a systematic literature review. *Computers & Industrial Engineering,* v. 150, art. 106889, 2020.