MESTRADO EM ENGENHARIA DE TECNOLOGIAS E SISTEMAS WEB

Ecossistema Inteligente para Monitorização Proativa de Sinais Vitais

Adelino Masioli

Orientador: Professor Doutor Firmino Silva

DISSERTAÇÃO

VILA NOVA DE GAIA

Julho | 2026

INSTITUTO POLITÉCNICO DE GESTÃO E TECNOLOGIA

Ecossistema Inteligente para Monitorização Proativa de Sinais Vitais

Adelino Lázaro Ferreira Masioli

Aprovado em 15/10/2026

Composição do Júri

Presidente

Prof. Especialista José Joaquim Moreira

Arguente

Prof. Doutor António Abreu

Orientador

Prof. Doutor Firmino Oliveira da Silva

Vila Nova de Gaia

2026

Dissertação de Mestrado submetida para satisfação parcial dos requisitos do grau de Mestre em Engenharia de Tecnologias e Sistemas Web, realizada sob a orientação do Professor Doutor Firmino Oliveira da Silva e apresentada ao ISLA - Instituto Politécnico de Gestão e Tecnologia, para obtenção do grau de Mestre em Engenharia de Tecnologias e Sistemas Web, ao abrigo do Despacho nº 9371/2020.

Declaração de Originalidade

Eu, Adelino Masioli, declaro que a presente dissertação constitui o registo autêntico do trabalho de investigação original por mim desenvolvido. Não foi submetida, total ou parcialmente, a qualquer outro grau académico ou qualificação profissional. Todas as fontes de informação utilizadas, incluindo contribuições de terceiros, obras publicadas e ferramentas colaborativas, foram explicitamente reconhecidas em conformidade com os padrões de integridade académica.

Agradecimentos

Expresso a minha mais profunda gratidão ao Professor Firmino Silva, orientador desta dissertação, cujo acompanhamento rigoroso, crítica construtiva e disponibilidade permanente foram determinantes para a qualidade do trabalho aqui apresentado. O seu profundo conhecimento em sistemas de informação em saúde e em metodologias de investigação em ciências da computação orientou decisivamente as escolhas metodológicas e técnicas que estruturam este documento.

Agradeço igualmente à minha família pelo encorajamento contínuo e à instituição ISLA Gaia pelo ambiente académico e pelos recursos que tornaram viável esta investigação. Por fim, o meu reconhecimento estende-se à comunidade de código aberto dos ecossistemas Flutter, FastAPI e TimescaleDB.

Resumo

A presente dissertação descreve o design, o desenvolvimento e a validação experimental de um ecossistema digital para a monitorização proativa e contínua de sinais vitais, com o objetivo de contribuir para a deteção precoce de alterações fisiológicas e para o acompanhamento remoto de pacientes. O sistema integra três componentes principais: uma aplicação móvel multiplataforma desenvolvida em Flutter para a aquisição de dados pelo paciente, um backend escalável em Python/FastAPI, com armazenamento em PostgreSQL/TimescaleDB, e um dashboard clínico em React.js com Recharts para apoio à decisão. O objetivo central consiste em viabilizar a monitorização remota de pacientes (RPM), com uma sobrecarga operacional reduzida para os utilizadores.

A metodologia adotada foi a Design Science Research (DSR), que orientou o desenvolvimento incremental em quatro sprints: (1) pipeline básico de dados; (2) autenticação e controlo de acesso baseado em papéis; (3) motor de deteção de anomalias e alertas em tempo real; e (4) visualização clínica avançada. A validação experimental utilizou uma coorte sintética de 10 pacientes, durante 72 horas simuladas, e processou 90.770 leituras através da API do protótipo. Os resultados demonstraram a viabilidade técnica da arquitetura proposta no ambiente controlado: foram processadas 90.770 leituras sem perda ou duplicação, a latência média ponta a ponta foi de 1,55 segundos (p99 = 2,97 s) e os 120 episódios anómalos sustentados foram corretamente associados a alertas, sem falsos positivos ou falsos negativos no protocolo experimental. Uma experiência de ablação com persistência N=1 produziu 73 falsos alertas e reduziu a precisão para 62,2%, evidenciando o contributo do critério de persistência temporal. Estes resultados demonstram consistência técnica do ecossistema, mas não constituem validação de eficácia clínica. Como principal limitação, destaca-se o uso de dados sintéticos, sendo necessária validação futura em contexto clínico real.

Palavras-chave: saúde digital; monitorização remota de pacientes; sinais vitais; Design Science Research; dispositivos wearable; deteção de anomalias; FastAPI; TimescaleDB; Flutter.

Índice

1 Introdução **1**

1.1 Formulação do Problema e Justificação 2

1.2 Objetivos 3

1.2.1 Objetivo Geral 3

1.2.2 Objetivos Específicos 3

1.3 Questão de Investigação 4

1.4 Hipóteses de Investigação 4

1.5 Contributo Científico da Investigação 5

1.6 Estrutura do Documento 6

2 Revisão da Literatura **7**

2.1 Inteligência Artificial em Monitorização Remota de Pacientes 7

2.2 Dispositivos Wearable e Aquisição de Dados Fisiológicos 8

2.3 Arquiteturas de Sistemas de Saúde Digital 9

2.4 Deteção de Anomalias em Séries Temporais Clínicas 9

2.4.1 Explainable AI e Sistemas Especialistas em Saúde 11

2.5 Lacunas Identificadas e Posicionamento do Trabalho 12

2.6 Análise Comparativa dos Sistemas de RPM 12

2.7 Inteligência Artificial e Suporte à Decisão 14

2.8 Tendências Recentes e Evolução do Domínio 14

2.8.1 Interoperabilidade, FHIR e Ecossistemas de Saúde Digital 15

3 Metodologia **15**

3.1 Enquadramento DSR 16

3.2 Requisitos do Sistema 17

3.3 Requisitos 18

3.3.1 Requisitos Funcionais 18

3.3.2 Requisitos Não Funcionais 19

3.3.3 Matriz de Rastreabilidade dos Requisitos 20

3.4 Fases e Sprints de Desenvolvimento 21

3.5 Ambiente de Teste e Coorte Sintética 22

4 Desenvolvimento e Implementação **23**

4.1 Aplicação Móvel (Camada do Paciente) 24

4.1.1 Funcionalidades Implementadas 25

4.2 Backend (Camada de Processamento e Armazenamento) 26

4.2.1 Modelo de Dados e Armazenamento 26

4.2.2 Motor de Deteção de Anomalias 27

4.3 Dashboard Clínico (Camada de Visualização) 29

4.4 Diagrama de Sequência e Fluxo Ponta a Ponta 29

5 Resultados **30**

5.1 Latência de Propagação Ponta a Ponta 31

5.2 Integridade dos Dados 32

5.3 Precisão da Deteção de Anomalias 33
6 Discussão dos Resultados 34
6.1 Interpretação dos Resultados Obtidos 34
6.2 Comparação com a Literatura 35
6.3 Impacto dos Dados Sintéticos 36
6.4 Escalabilidade 36
6.5 Wearables Reais 37
6.6 Limitações Metodológicas e Validade dos Resultados 37
6.7 Síntese da Discussão 39
7 Conclusão e Trabalho Futuro 40
7.1 Trabalho Futuro 40
7.1.1 Integração de Modelos de IA Preditiva 40
7.1.2 Estudos de Usabilidade Clínica 40
7.1.3 Produção e Conformidade Regulatória 41
Referências Bibliográficas 42

Índice de Figuras

Figura 1 — Modelo de Três Ciclos da Design Science Research (adaptado de Hevner, 2007)

Figura 2 — Arquitetura ponta a ponta do ecossistema

Figura 3 — Interface da aplicação móvel desenvolvida

Figura 4 — Esquema relacional do modelo de dados

Figura 5 — Interface do dashboard clínico desenvolvido

Figura 6 — Diagrama de sequência do fluxo ponta a ponta

Figura 7 — Histograma de distribuição da latência ponta a ponta (n=300)

Índice de Tabelas

Tabela 1 — Comparação entre trabalhos relevantes de RPM e o ecossistema proposto

Tabela 2 — Requisitos funcionais do sistema

Tabela 3 — Requisitos não funcionais do sistema

Tabela 4 — Matriz de rastreabilidade dos requisitos

Tabela 5 — Mapeamento entre fases DSR e sprints de desenvolvimento

Tabela 6 — Perfis da coorte sintética de 10 pacientes

Tabela 7 — Thresholds de deteção de anomalias por sinal vital

Tabela 8 — Métricas de latência ponta a ponta

Tabela 9 — Métricas de desempenho do motor de deteção de anomalias

Lista de Acrónimos e Abreviaturas

AHA — American Heart Association

API — Application Programming Interface

AUC — Area Under the Curve

BLE — Bluetooth Low Energy

CAGR — Compound Annual Growth Rate

DSR — Design Science Research

ECG — Eletrocardiograma

ESC — European Society of Cardiology

FHIR — Fast Healthcare Interoperability Resources

FN — Falso Negativo

FP — Falso Positivo

HIPAA — Health Insurance Portability and Accountability Act

IA — Inteligência Artificial

IoT — Internet of Things

JWT — JSON Web Token

LAN — Local Area Network

LSTM — Long Short-Term Memory

MDR — Medical Device Regulation

RBAC — Role-Based Access Control

REST — Representational State Transfer

RF — Requisito Funcional

RGPD — Regulamento Geral sobre a Proteção de Dados

RNF — Requisito Não Funcional

RPM — Remote Patient Monitoring

SpO2 — Saturação Periférica de Oxigénio

SUS — System Usability Scale

TLS — Transport Layer Security

TN — Verdadeiro Negativo

TP — Verdadeiro Positivo

WHO — World Health Organization

XAI — Explainable Artificial Intelligence

1 Introdução

A crescente pressão sobre os sistemas de saúde, motivada pelo envelhecimento populacional e pela elevada prevalência de doenças crónicas não transmissíveis, reforça a necessidade de modelos de acompanhamento que complementem o contacto clínico presencial (WHO, 2021). Segundo a WHO (2023), as doenças não transmissíveis, consideradas em conjunto, representam aproximadamente 74% das mortes globais. Tecnologias de saúde conectada e telemonitorização podem apoiar novos modelos de acompanhamento fora do ambiente clínico tradicional (Kvedar et al., 2014). Embora dispositivos wearable permitam recolher diferentes sinais fisiológicos, o seu valor depende da qualidade, contextualização e integração dos dados em processos de acompanhamento. Este constitui o núcleo do problema abordado nesta dissertação: transformar fluxos de dados biométricos em informação tecnicamente estruturada e útil para suporte à decisão.

A disseminação de dispositivos wearable de consumo e de uso médico — como smartwatches, oxímetros de pulso e tiras peitorais — ampliou as possibilidades de recolha ambulatória e não invasiva de dados fisiológicos em contexto de vida diária. Contudo, como discutido por Piwek et al. (2016), a disponibilidade de dados provenientes de wearables não elimina limitações relacionadas com qualidade, interpretação, privacidade e integração dos dados no cuidado em saúde. De forma complementar, Klasnja e Pratt (2012) mostram que intervenções móveis em saúde devem ser concebidas em função de necessidades concretas de monitorização e suporte ao utilizador. Assim, o valor do RPM depende não apenas da aquisição de dados, mas da existência de mecanismos capazes de os integrar, processar e transformar em informação útil para acompanhamento.

A fragmentação tecnológica existente, a heterogeneidade dos formatos de dados e a inexistência de arquiteturas de referência abertas e validadas constituem as principais barreiras identificadas na literatura para a adoção clínica generalizada de soluções de RPM (Farahani et al., 2018; Seneviratne et al., 2017). O presente trabalho responde a estas lacunas através do design, desenvolvimento e validação experimental de um

sistema inteligente que integra wearables, aplicação móvel e algoritmos de deteção de anomalias, constituindo uma proposta de solução validada no contexto da investigação em saúde digital. O contributo científico não reside apenas na implementação técnica, mas na demonstração, ainda que em escala controlada, da eficácia e aplicabilidade de uma arquitetura modular e reprodutível para a monitorização proativa de sinais vitais — um domínio em rápido crescimento que carece de sistemas de referência abertos com validação quantitativa.

1.1 Formulação do Problema e Justificação

Não obstante a proliferação de dispositivos de monitorização, persiste um problema sistémico bem documentado: os pacientes falham frequentemente em registar consistentemente os seus dados fisiológicos, seja por esquecimento, falta de motivação ou pela fragmentação de ecossistemas proprietários incompatíveis entre si (Klasnja & Pratt, 2012). Esta adesão irregular impede a deteção precoce de anomalias clinicamente relevantes, como taquicardia noturna, hipotensão episódica ou dessaturação de oxigénio durante esforço.

A literatura sobre IoT aplicado à saúde evidencia a necessidade de integrar dispositivos, processamento distribuído, serviços e interfaces clínicas numa arquitetura coerente. Farahani et al. (2018), por exemplo, propõem uma arquitetura multicamada para ecossistemas IoT eHealth e destacam desafios de gestão de dados, escalabilidade, interoperabilidade, segurança e privacidade. Neste contexto, a presente investigação concentra-se não numa estimativa quantitativa da proporção de sistemas validados, mas na construção e avaliação experimental de um pipeline completo de RPM, desde a aquisição de sinais vitais até à geração e visualização de alertas.

A fadiga de alertas (alert fatigue) constitui uma limitação relevante em sistemas de apoio à decisão: a exposição repetida a alertas e o aumento da carga de trabalho podem reduzir a atenção dedicada a notificações individuais (Ancker et al., 2017). Neste contexto, mecanismos que evitem a geração de alertas a partir de oscilações isoladas são importantes para a qualidade operacional de um sistema de monitorização.

1.2 Objetivos

1.2.1 Objetivo Geral

Desenvolver e validar um ecossistema inteligente para monitorização remota de pacientes, capaz de recolher, analisar e interpretar sinais vitais em tempo útil através de regras transparentes, deteção de padrões fisiológicos anómalos e geração de alertas contextuais para apoio à decisão.

1.2.2 Objetivos Específicos

- Implementar um sistema de aquisição multi-fonte de sinais vitais, suportando entrada manual e integração simulada com dispositivos wearable via Bluetooth Low Energy (BLE).
- Desenvolver uma aplicação móvel multiplataforma (iOS/Android) para autogestão do paciente, com visualização histórica e notificações push.
- Conceber e implementar um backend seguro com API REST, armazenamento persistente em série temporal e gestão de autenticação com controlo de acesso baseado em papéis (RBAC).
- Implementar um motor de deteção de anomalias para quatro sinais vitais essenciais, com thresholds configuráveis por perfil de paciente e geração de alertas em tempo real.
- Desenvolver um dashboard clínico interativo com visualização temporal, gestão de alertas e exportação de relatórios clínicos.
- Validar o sistema ponta a ponta através de testes experimentais controlados, medindo latência, integridade de dados e precisão dos alertas.

1.3 Questão de Investigação

A questão de investigação que orienta o presente trabalho é a seguinte:

Em que medida um ecossistema inteligente baseado na integração de dispositivos wearable, análise automatizada de séries temporais fisiológicas e mecanismos de suporte à decisão clínica pode contribuir para a deteção precoce de situações de risco e para a monitorização proativa de pacientes em contexto remoto?

Esta questão principal é complementada por três subquestões de investigação: (i) Qual o desempenho do mecanismo de deteção de anomalias baseado em regras parametrizáveis quando aplicado a dados fisiológicos sintéticos em ambiente controlado? (ii) Em que medida a arquitetura proposta permite processar e propagar alertas em tempo compatível com os requisitos definidos para monitorização remota? (iii) Em que medida o pipeline automatizado de aquisição, processamento e armazenamento assegura a continuidade e a integridade dos dados gerados no ambiente experimental?

1.4 Hipóteses de Investigação

Em resposta à questão de investigação formulada, o presente trabalho propõe e testa as seguintes hipóteses, operacionalizáveis no contexto do protótipo desenvolvido:

H1 – O mecanismo de deteção de anomalias baseado em regras parametrizáveis permite identificar, no ambiente experimental controlado, as anomalias introduzidas na coorte sintética, com desempenho quantificável através de métricas de precisão, sensibilidade, especificidade e F1-Score.

H2 – O pipeline automatizado de aquisição, transmissão, processamento e armazenamento permite processar as leituras geradas no ambiente experimental sem perda ou duplicação de registos, assegurando a integridade dos dados ao longo do fluxo ponta a ponta.

H3 – O mecanismo de geração e propagação de alertas em tempo real permite uma latência média ponta a ponta inferior a 5 segundos e um percentil 99 inferior a 10 segundos, em conformidade com os critérios definidos para o requisito RNF1.

As três hipóteses foram operacionalizadas e avaliadas no contexto da validação experimental descrita na Secção 5, com recurso à coorte sintética de dez pacientes e a 90.770 leituras geradas ao longo de 72 horas simuladas.

1.5 Contributo Científico da Investigação

O principal contributo científico desta investigação consiste na proposta e validação de um ecossistema inteligente para monitorização remota de pacientes, concebido para integrar aquisição contínua de sinais vitais, processamento inteligente de dados fisiológicos e suporte à decisão clínica em tempo real.

Ao contrário de soluções centradas apenas na recolha ou visualização de dados, o sistema proposto incorpora uma camada de processamento responsável por interpretar séries temporais provenientes de dispositivos wearable, identificar padrões fisiológicos potencialmente anómalos e produzir alertas explicáveis para acompanhamento por pacientes e profissionais de saúde.

Os contributos científicos específicos desta investigação são:

C1 – Proposta de uma arquitetura de referência para sistemas de Remote Patient Monitoring composta por cinco camadas interoperáveis: aquisição, processamento, inteligência, armazenamento e visualização.

C2 – Desenvolvimento de um modelo de análise inteligente baseado na combinação de regras clínicas parametrizáveis, persistência temporal e interpretação contextual dos sinais vitais.

C3 – Definição de um framework modular preparado para integração de modelos avançados de Inteligência Artificial, incluindo LSTM Autoencoders, Anomaly Transformers e Federated Learning.

C4 – Demonstração experimental da viabilidade técnica de um pipeline completo de monitorização inteligente utilizando dispositivos wearable, aplicação móvel, backend analítico e dashboard clínico.

C5 – Proposta de uma abordagem compatível com os princípios de Explainable Artificial Intelligence (XAI), assegurando transparência, rastreabilidade e auditabilidade das decisões produzidas pelo sistema.

A originalidade desta investigação não reside na criação isolada de uma aplicação móvel, de um dashboard clínico ou de mecanismos de deteção de anomalias — componentes já amplamente representados na literatura —, mas na integração coerente destes elementos numa arquitetura única, modular e reprodutível para cenários de Remote Patient Monitoring (RPM). Ao contrário da maioria dos trabalhos identificados no estado da arte, que se concentram em aspetos isolados (aquisição de dados, algoritmos de deteção, dispositivos wearable ou plataformas de visualização), o presente trabalho integra estes componentes num ecossistema completo e validado quantitativamente ponta a ponta.

Esta integração permite não apenas validar a viabilidade técnica da arquitetura, mas também estabelecer uma base de referência extensível para investigações futuras envolvendo Inteligência Artificial preditiva, interoperabilidade FHIR e sistemas de apoio à decisão clínica em tempo real. O contributo da investigação situa-se, assim, tanto ao nível da implementação tecnológica como, sobretudo, ao nível da definição de uma arquitetura de referência cientificamente fundamentada.

1.6 Estrutura do Documento

O restante documento organiza-se da seguinte forma: o Capítulo 2 apresenta a revisão crítica da literatura relevante, culminando na identificação das lacunas de investigação e no posicionamento do trabalho face ao estado da arte; o Capítulo 3 descreve a metodologia Design Science Research adotada, os requisitos do sistema e o ambiente experimental; o Capítulo 4 detalha o desenvolvimento e a implementação técnica do ecossistema (aplicação móvel, backend e dashboard clínico); o Capítulo 5 apresenta os resultados experimentais de latência, integridade de dados e deteção de anomalias; o Capítulo 6 discute criticamente estes resultados, incluindo as suas limitações

metodológicas; e o Capítulo 7 conclui a dissertação, sintetizando o contributo científico e propondo linhas de trabalho futuro.

2 Revisão da Literatura

A presente revisão incide sobre quatro domínios inter-relacionados: (i) a evolução dos sistemas de monitorização remota de pacientes; (ii) as arquiteturas de sistemas de saúde digital; (iii) as abordagens de deteção de anomalias em séries temporais clínicas; e (iv) os requisitos de desempenho e interoperabilidade. A seleção de literatura baseou-se em pesquisa nas bases PubMed, IEEE Xplore e ACM Digital Library, com filtros temporais de 2014 a 2024, privilegiando artigos de revistas indexadas Q1/Q2 e conferências de primeira linha (IEEE EMBC, ACM CHI, AMIA).

2.1 Inteligência Artificial em Monitorização Remota de Pacientes

Nos últimos anos, a aplicação de Inteligência Artificial (IA) à monitorização remota de pacientes emergiu como uma das áreas de maior crescimento dentro da saúde digital. A disponibilidade crescente de dispositivos wearable e sensores biométricos permitiu a geração contínua de grandes volumes de dados fisiológicos, criando condições favoráveis para a utilização de algoritmos inteligentes capazes de identificar padrões clínicos complexos e apoiar a tomada de decisão médica.

Segundo Topol (2019), a principal transformação proporcionada pela IA em saúde não reside apenas na automatização de tarefas, mas na capacidade de detetar relações subtis entre variáveis fisiológicas que frequentemente escapam à observação humana. Esta capacidade é particularmente relevante em sistemas de monitorização contínua, nos quais pequenas alterações ao longo do tempo podem representar sinais precoces de deterioração clínica.

Estudos com wearables e ECG ambulatório demonstram que sinais fisiológicos recolhidos fora do ambiente hospitalar podem apoiar a identificação de alterações cardíacas. Perez et al. (2019) avaliaram esta possibilidade em larga escala com

smartwatch, enquanto Hannun et al. (2019) demonstraram o potencial de redes neurais profundas para classificação de arritmias em ECG ambulatório.

Contudo, apesar dos resultados promissores, diversos autores alertam para desafios importantes relacionados com interpretabilidade, auditabilidade e confiança clínica. Barredo Arrieta et al. (2020) argumentam que sistemas de suporte à decisão médica devem privilegiar abordagens Explainable AI (XAI), capazes de justificar claramente as recomendações produzidas.

Neste contexto, observa-se uma tendência crescente para arquiteturas híbridas que combinam conhecimento clínico explícito, regras de inferência e algoritmos de aprendizagem automática. Esta abordagem procura equilibrar desempenho preditivo e transparência, características particularmente relevantes em ambientes clínicos regulados.

2.2 Dispositivos Wearable e Aquisição de Dados Fisiológicos

A literatura sobre dispositivos wearable para monitorização de saúde é extensa e em rápida evolução. Gao et al. (2018) analisam diferentes tecnologias de sensores aplicadas à monitorização de saúde. De forma complementar, Seneviratne et al. (2017) apresentam uma revisão abrangente de dispositivos wearable, incluindo categorias de dispositivos, comunicação, segurança, eficiência energética e desafios de investigação. Em conjunto, estes trabalhos evidenciam a diversidade tecnológica do domínio e a necessidade de considerar não apenas a aquisição dos sinais, mas também conectividade, segurança e integração dos dados.

Particularmente relevante é a capacidade demonstrada de dispositivos wearable na identificação de alterações do ritmo cardíaco. No Apple Heart Study, Perez et al. (2019) avaliaram 419.297 participantes e mostraram a viabilidade de uma aplicação de smartwatch para identificar pulsos irregulares compatíveis com fibrilhação auricular; entre as notificações que puderam ser comparadas simultaneamente com um patch de ECG, o valor preditivo positivo para a notificação foi de 0,84. Em contexto distinto, Hannun et al. (2019) demonstraram que uma rede neural profunda aplicada a ECG

ambulatório podia classificar arritmias com desempenho comparável ao de cardiologistas especialistas. Estes estudos sustentam o potencial de sensores e algoritmos para monitorização, sem implicar equivalência entre dispositivos de consumo e sistemas clínicos.

2.3 Arquiteturas de Sistemas de Saúde Digital

A análise crítica das arquiteturas de sistemas de RPM propostas na literatura revela três padrões dominantes: arquiteturas monolíticas, arquiteturas em camadas e arquiteturas de microsserviços. A maioria dos trabalhos académicos adota arquiteturas em camadas (three-tier) que separam aquisição, processamento e visualização, em consonância com os princípios de separação de responsabilidades (separation of concerns) que orientam a engenharia de software moderna (Fowler, 2002).

Farahani et al. (2018) discutem arquiteturas IoT eHealth que distribuem aquisição, processamento e serviços entre dispositivos, recursos de edge/fog e cloud. O trabalho evidencia que requisitos como latência, escalabilidade, segurança, privacidade e gestão de dados devem ser considerados conjuntamente na definição arquitetural. Estes princípios contribuíram para a separação modular adotada no presente trabalho, mas o limite de latência utilizado no RNF1 é um critério de aceitação definido para este artefacto e não um valor universal derivado daquela referência.

A utilização de uma extensão orientada a séries temporais é coerente com os requisitos de armazenamento e consulta de medições ordenadas temporalmente. Trabalhos como Pelkonen et al. (2015) demonstram a relevância de estruturas especializadas para armazenamento e consulta eficiente de séries temporais em grande escala. Nesta dissertação, contudo, não foi realizado um benchmark comparativo entre TimescaleDB e bases de dados relacionais de uso geral.

2.4 Deteção de Anomalias em Séries Temporais Clínicas

A deteção de anomalias em séries temporais fisiológicas pode ser abordada por três paradigmas principais: (i) sistemas baseados em regras (rule-based), (ii) métodos estatísticos clássicos, e (iii) modelos de aprendizado automático. Cada abordagem

apresenta compromissos distintos entre interpretabilidade, sensibilidade, especificidade e custo computacional.

Os sistemas baseados em regras, como o implementado no presente trabalho, oferecem transparência total, comportamento determinístico e validação clínica direta por especialistas. A literatura documenta amplamente a sua eficácia em contextos de monitorização de sinais vitais: Bellazzi & Zupan (2008), em revisão publicada no Journal of the American Medical Informatics Association, demonstraram que sistemas de inferência baseados em regras alcançam precisões comparáveis a modelos de aprendizado automático para anomalias bem caracterizadas e clinicamente definidas.

Abordagens baseadas em aprendizagem profunda, como redes LSTM para deteção de anomalias (Malhotra et al., 2015) e o Anomaly Transformer (Xu et al., 2021), mostram que modelos treinados sobre padrões temporais podem identificar comportamentos anómalos sem depender exclusivamente de thresholds fixos. Em contrapartida, a sua adoção acrescenta complexidade de treino, validação e interpretação dos resultados. Em saúde, Rajkomar et al. (2019) salientam a necessidade de avaliação rigorosa, integração adequada no fluxo clínico e atenção às limitações dos modelos de aprendizagem automática.

A abordagem de persistência de leituras consecutivas implementada no motor de deteção procura evitar que uma violação isolada de threshold seja imediatamente convertida em alerta. Esta opção é coerente com a preocupação, presente na literatura de monitorização contínua, de contextualizar dados fisiológicos e reduzir alarmes espúrios (Clifton et al., 2014). No presente trabalho, porém, o efeito da persistência não é inferido a partir de uma percentagem externa: é avaliado diretamente através do teste de ablação que compara o motor configurado com persistência com a condição N=1.

A relevância da inteligência artificial na transformação da medicina foi sistematicamente argumentada por Topol (2019) em Deep Medicine, onde o autor demonstra que os modelos de IA, quando aplicados a dados fisiológicos contínuos, podem superar diagnósticos clínicos em domínios específicos como leitura de imagem ou classificação de arritmias. Contudo, Topol (2019) alerta igualmente para os riscos de uma adoção acrítica: a eficácia destes modelos depende da qualidade e representação dos dados de

treino, e a sua utilidade clínica exige integração no fluxo de trabalho do profissional, não a sua substituição. Esta perspetiva sustenta a opção metodológica do presente trabalho: num primeiro estágio, privilegiar um motor de deteção baseado em regras interpretáveis e clínicamente validáveis, deixando a incorporação de modelos preditivos mais complexos para uma fase de maturidade posterior do sistema, quando existirem dados reais suficientes para treino e validação robusta.

2.4.1 Explainable AI e Sistemas Especialistas em Saúde

A utilização de Inteligência Artificial em contexto clínico exige requisitos adicionais de transparência e rastreabilidade que não estão presentes em muitos domínios industriais. Ao contrário de sistemas convencionais de Machine Learning, em que a precisão é frequentemente o principal indicador de qualidade, aplicações médicas exigem igualmente a capacidade de justificar decisões e recomendações.

Segundo Barredo Arrieta et al. (2020), a Explainable Artificial Intelligence (XAI) constitui atualmente uma das áreas mais relevantes da investigação em IA aplicada à saúde. A possibilidade de compreender os fatores que conduziram à geração de um alerta ou recomendação é fundamental para garantir confiança por parte dos profissionais de saúde.

Neste contexto, sistemas especialistas e motores de inferência baseados em conhecimento continuam a desempenhar um papel relevante. Bellazzi e Zupan (2008) demonstraram que abordagens baseadas em regras clínicas podem alcançar desempenhos comparáveis aos modelos de aprendizagem automática em diversos cenários de monitorização fisiológica, apresentando simultaneamente maior transparência e facilidade de validação clínica.

A literatura recente sugere que a evolução natural dos sistemas de monitorização inteligente passa pela combinação de mecanismos explicáveis com modelos preditivos mais avançados. Tal estratégia permite preservar a auditabilidade do sistema enquanto

beneficia das capacidades preditivas proporcionadas pelas técnicas modernas de Machine Learning.

2.5 Lacunas Identificadas e Posicionamento do Trabalho

A análise crítica da literatura permite delimitar três lacunas relevantes para o presente trabalho. A primeira refere-se à integração arquitetural: ecossistemas IoT eHealth exigem articulação entre dispositivos, processamento, serviços e interfaces, ao mesmo tempo que enfrentam desafios de interoperabilidade, gestão de dados, escalabilidade, segurança e privacidade (Farahani et al., 2018). A segunda prende-se com a necessidade de avaliar quantitativamente o comportamento do pipeline ponta a ponta, incluindo latência, integridade dos dados e desempenho do mecanismo de deteção, dimensões que nesta investigação são tratadas experimentalmente. A terceira diz respeito à interpretabilidade dos mecanismos de apoio à decisão: modelos de aprendizagem automática podem introduzir dificuldades de explicação e confiança em contexto clínico (Rajkomar et al., 2019; Topol, 2019). O presente trabalho posiciona-se perante estas lacunas através de uma arquitetura integrada e reprodutível, acompanhada por validação quantitativa em ambiente experimental controlado e por um motor de deteção baseado em regras transparentes e parametrizáveis. Esta validação não pretende demonstrar eficácia clínica, mas avaliar o comportamento técnico do artefacto nas condições experimentais definidas.

2.6 Análise Comparativa dos Sistemas de RPM

Com o objetivo de posicionar cientificamente o presente trabalho face ao estado da arte, foi realizada uma análise comparativa de sistemas representativos de monitorização remota de pacientes publicados na literatura. A comparação considera dimensões consideradas críticas para sistemas modernos de RPM, incluindo integração com dispositivos wearable, utilização de Inteligência Artificial, suporte à monitorização em tempo real, capacidade de explicação das decisões produzidas e metodologias de validação adotadas.

Tabela 1. Comparação entre trabalhos relevantes de RPM e o ecossistema proposto.

Trabalho	Wearable	IA / Análise Inteligente	Dashboard Clínico	Tempo Real	XAI	Validação
Seto et al. (2012)	✓	✗	Parcial	✗	✗	Estudo clínico
Clifton et al. (2014)	✓	Modelação preditiva	✗	✓	✗	Avaliação preditiva
Perez et al. (2019)	✓	Algoritmo de notificação de pulso irregular	✗	✓	✗	PPV da notificação = 0,84
Hannun et al. (2019)	✓	Deep Learning	✗	✓	✗	Comparação com cardiologistas
Barredo Arrieta et al. (2020)	✗	Explainable AI	✗	✗	✓	Revisão de XAI
Piwek et al. (2016)	✓	Revisão de wearables de consumo	✗	N/A	✗	Revisão crítica
Farahani et al. (2018)	✓	Arquitetura IoT eHealth	✓	✓	✗	Revisão arquitetural
Presente Trabalho	✓	Regras explicáveis + análise temporal	✓	Polling de 3s no ensaio	Regras explicáveis	F1 Score, Latência e Integridade

A análise comparativa evidencia que a maioria dos trabalhos identificados concentra-se em apenas uma parte do ecossistema de monitorização remota, privilegiando algoritmos de deteção, dispositivos wearable ou estudos clínicos específicos. São raros os trabalhos que integram simultaneamente aquisição automática de dados, processamento inteligente, geração de alertas, visualização clínica em tempo real e mecanismos de explicabilidade.

Os trabalhos mais recentes tendem a concentrar-se em componentes específicos do ecossistema de RPM — algoritmos de IA, interoperabilidade ou validação clínica isolada —, permanecendo escassas as arquiteturas abertas que integrem simultaneamente aquisição, análise inteligente, alertas em tempo real, visualização clínica e explicabilidade. É precisamente nesta integração que o presente trabalho se diferencia, posicionando-se como contribuição complementar à literatura, com ênfase simultânea em desempenho operacional, interpretabilidade e potencial de evolução para modelos mais avançados de IA.

2.7 Inteligência Artificial e Suporte à Decisão

A camada de análise do ecossistema não se limita à recolha e apresentação de sinais vitais: aplica regras transparentes e persistência temporal para identificar padrões potencialmente anómalos e produzir alertas contextuais para apoio à decisão. A versão atual não utiliza modelos de aprendizagem automática treinados sobre dados clínicos; o comportamento do motor é determinístico, parametrizável e auditável. Os modelos de aprendizagem automática discutidos na Secção 2.4 representam uma possível evolução futura da arquitetura, a avaliar separadamente quanto a desempenho, interpretabilidade e segurança.

2.8 Tendências Recentes e Evolução do Domínio

Literatura recente enquadra a oportunidade do trabalho:

Piwek et al. (2016) discutem o potencial dos wearables de consumo para saúde e também limitações relacionadas com precisão, privacidade e integração, reforçando a necessidade de avaliação crítica destes dispositivos em ecossistemas de monitorização.

A expansão da telemonitorização após a pandemia reforçou a relevância de investigar arquiteturas de RPM integradas, interoperáveis e passíveis de avaliação técnica.

Mandl et al. (2024) destacam que a integração de soluções digitais e de IA em saúde depende de um ecossistema de dados interoperável e de padrões que favoreçam o fluxo de informação entre sistemas.

Modelos de linguagem de grande escala constituem uma linha futura de investigação para sumarização e interação com informação clínica, mas a sua incorporação no ecossistema exigiria avaliação específica de segurança, factualidade e utilidade clínica.

2.8.1 Interoperabilidade, FHIR e Ecossistemas de Saúde Digital

A interoperabilidade representa um dos principais desafios para a adoção generalizada de soluções de monitorização remota de pacientes. A coexistência de múltiplos fabricantes de dispositivos wearable, sistemas hospitalares e plataformas de telemedicina cria dificuldades significativas na integração e partilha de informação clínica.

Mandl et al. (2024) salientam que a integração de soluções digitais e de IA em saúde depende de infraestruturas interoperáveis e de padrões que permitam o fluxo de dados entre sistemas. Neste contexto, o Fast Healthcare Interoperability Resources (FHIR) constitui um padrão relevante para representar e trocar recursos clínicos de forma estruturada. A arquitetura proposta nesta dissertação não implementa FHIR no protótipo experimental, mas foi concebida de forma modular para permitir essa extensão em trabalho futuro.

Paralelamente, a evolução dos dispositivos wearable está a conduzir à criação de ecossistemas de saúde digital cada vez mais distribuídos, nos quais dados provenientes de múltiplas fontes podem ser agregados e analisados. Neste contexto, o desafio não se limita à recolha: inclui interoperabilidade, qualidade dos dados, processamento e transformação das medições em informação útil para acompanhamento.

Esta tendência reforça a necessidade de arquiteturas modulares, escaláveis e preparadas para integração futura de modelos avançados de Inteligência Artificial, capazes de analisar grandes volumes de séries temporais fisiológicas de forma contínua.

3 Metodologia

O presente trabalho adota a Design Science Research (DSR) como paradigma de investigação orientado à construção e avaliação de artefactos destinados a resolver problemas relevantes em sistemas de informação, em consonância com o enquadramento de Hevner et al. (2004). Para operacionalizar o processo de investigação, utiliza-se a Design Science Research Methodology (DSRM) de Peffers et al. (2007), estruturada em seis atividades: (1) identificação do problema e motivação — análise das limitações e desafios dos ecossistemas de RPM; (2) definição dos objetivos da solução — especificação dos requisitos funcionais, não funcionais e da arquitetura de alto nível; (3) design e desenvolvimento — construção incremental do sistema em quatro sprints iterativos; (4) demonstração — execução do protótipo em ambiente controlado com uma coorte sintética; (5) avaliação — medição experimental de latência, integridade de dados e desempenho da deteção, confrontando os resultados com as hipóteses de investigação; e (6) comunicação — documentação da arquitetura, do processo experimental e dos resultados na presente dissertação. Esta separação distingue o enquadramento conceptual da DSR do modelo processual utilizado para conduzir e comunicar a investigação.

3.1 Enquadramento DSR

Complementarmente, Hevner (2007) descreve a DSR através de três ciclos inter-relacionados: Relevância, Rigor e Design. O Ciclo de Relevância estabelece a ligação entre o ambiente do problema e a investigação; o Ciclo de Rigor conecta a investigação à base de conhecimento, teorias e métodos existentes; e o Ciclo de Design sustenta a iteração entre construção e avaliação do artefacto. No presente trabalho, o problema e os requisitos de RPM alimentam o Ciclo de Relevância; a literatura científica e os

fundamentos de engenharia suportam o Ciclo de Rigor; e o desenvolvimento incremental e a avaliação experimental do ecossistema concretizam o Ciclo de Design.

A Figura 1 representa o modelo de três ciclos proposto por Hevner (2007). O Ciclo de Relevância conecta o contexto do problema à investigação; o Ciclo de Rigor relaciona a investigação com a base de conhecimento; e o Ciclo de Design orienta a iteração entre construção e avaliação do artefacto.

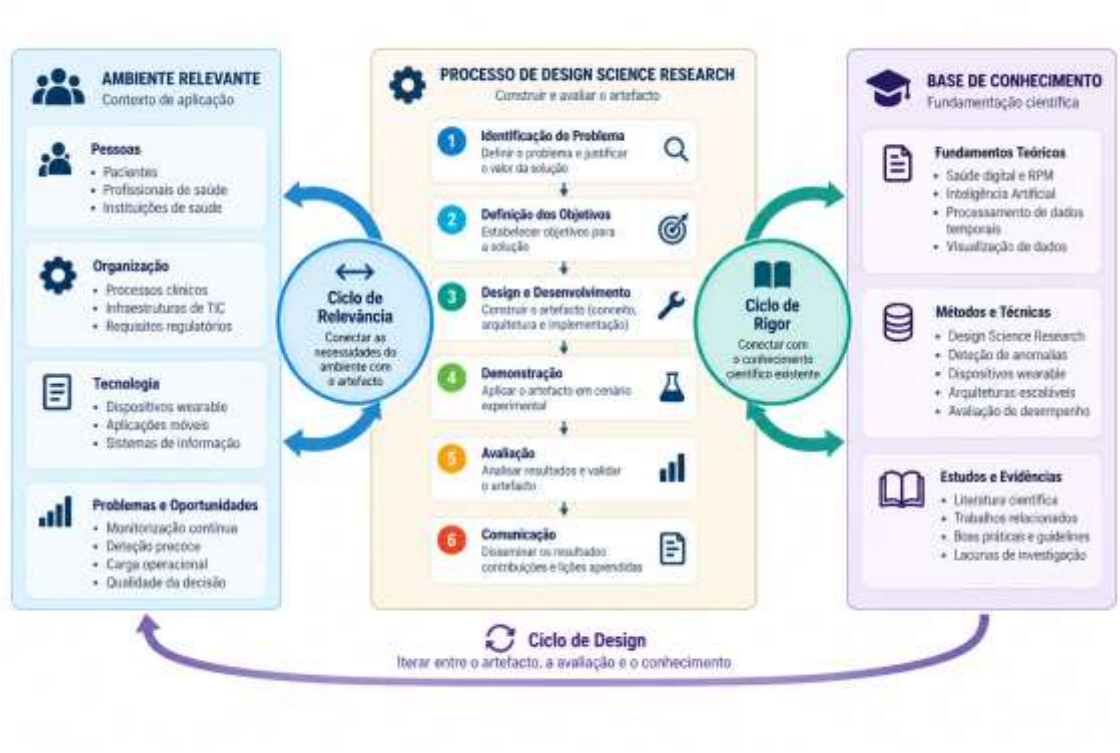


Figura 1. Modelo de Três Ciclos da Design Science Research, adaptado de Hevner (2007). (Autoria própria, com apoio de ferramenta de IA para a renderização gráfica.)

Seis atividades da DSRM e artefactos produzidos: (1) Identificação do Problema e Motivação — diagnóstico dos desafios de RPM; (2) Definição dos Objetivos da Solução — requisitos da Secção 3.2; (3) Design e Desenvolvimento — quatro sprints; (4) Demonstração — execução com coorte sintética; (5) Avaliação — métricas ponta a ponta; (6) Comunicação — documentação reprodutível da investigação.

3.2 Requisitos do Sistema

Os requisitos foram definidos a partir da análise do problema de investigação, da revisão da literatura e das necessidades identificadas em sistemas de monitorização remota de pacientes. Estes requisitos orientaram o design e o desenvolvimento do artefacto proposto.

3.3 Requisitos

3.3.1 Requisitos Funcionais

Tabela 2. Requisitos funcionais definidos para o ecossistema proposto.

Id	Requisito	Justificação
RF1	Aquisição automática de sinais vitais via wearable	Reduzir dependência do registo manual
RF2	Registo manual complementar	Permitir inserção de pressão arterial, peso e observações
RF3	Processamento inteligente dos dados	Identificar padrões de risco
RF4	Geração automática de alertas	Permitir intervenção precoce
RF5	Dashboard clínico	Facilitar acompanhamento

RF6	Exportação de relatórios	Apoiar consultas médicas
RF7	Gestão de utilizadores	Garantir controlo de acesso
RF8	Histórico temporal	Análise evolutiva dos sinais vitais
RF9	Suporte à análise inteligente dos sinais vitais	Identificar padrões de risco e produzir alertas explicáveis

3.3.2 Requisitos Não Funcionais

Tabela 3. Requisitos não funcionais definidos para o ecossistema proposto.

Id	Requisito	Justificação
RNF1	Latência inferior a 5 segundos	Suporte a monitorização em tempo real
RNF2	Escalabilidade	Suportar crescimento do número de pacientes
RNF3	Segurança	Garantir confidencialidade dos dados
RNF4	Auditabilidade	Rastrear eventos e alertas
RNF5	Disponibilidade	Operação contínua
RNF6	Interoperabilidade	Integração futura com FHIR e novos wearables
RNF7	Modularidade para IA	Evolução para modelos preditivos

Os requisitos não funcionais foram operacionalizados com critérios de aceitação quantitativos, de modo a permitir a sua verificação objetiva na fase de avaliação: RNF1 (latência) foi definido como média inferior a 5 s ponta a ponta, com p99 inferior a 10 s; RNF2 (escalabilidade) assume como meta de desenho o suporte a pelo menos 500 pacientes simultâneos, critério ainda não validado empiricamente (cf. Secção 6.4); RNF3 (segurança) exige autenticação JWT, cifragem TLS em trânsito e controlo de acesso RBAC; RNF4 (auditabilidade) exige registo persistente de todos os alertas gerados, com timestamp e identificação da regra ativada; e RNF5 (disponibilidade) assume como meta um objetivo de operação contínua de 99,5%, não medido no ambiente experimental controlado utilizado.

3.3.3 Matriz de Rastreabilidade dos Requisitos

Com o objetivo de garantir a coerência entre os requisitos definidos, os componentes desenvolvidos e os mecanismos de validação adotados, foi elaborada uma matriz de rastreabilidade. Esta matriz estabelece a correspondência entre os requisitos funcionais identificados na fase de especificação, os artefactos implementados ao longo do desenvolvimento e os elementos utilizados para a sua validação experimental.

A utilização de uma matriz de rastreabilidade é uma prática recomendada em projetos de engenharia de software, uma vez que permite demonstrar que todos os requisitos identificados foram efetivamente implementados e posteriormente avaliados durante a fase de validação do sistema.

Tabela 4. Matriz de rastreabilidade entre requisitos, implementação e evidências de validação.

Requisito	Implementação	Evidência de Validação
RF1 – Aquisição automática de	Aplicação móvel Flutter + integração BLE simulada	Testes de ingestão contínua de dados e processamento de 90.770 leituras na coorte sintética

sinais vitais via wearable		
RF2 – Registo manual complementar	Formulários de inserção manual de sinais vitais	Registo e persistência correta das leituras submetidas
RF3 – Processamento inteligente dos dados	Motor de inferência clínica e análise temporal	Avaliação da precisão na deteção de anomalias (F1 Score)
RF4 – Geração automática de alertas	Sistema de alertas em tempo real baseado em regras clínicas	Medição da latência média ponta a ponta e validação dos alertas gerados
RF5 – Dashboard clínico	Dashboard React com visualização temporal e gestão de alertas	Visualização em tempo real dos eventos e histórico clínico
RF6 – Exportação de relatórios	Módulo de exportação de dados e relatórios	Testes de geração e disponibilização de relatórios clínicos
RF7 – Gestão de utilizadores	Sistema de autenticação JWT e controlo de acesso RBAC	Validação dos perfis de utilizador e permissões de acesso
RF8 – Histórico temporal dos sinais vitais	PostgreSQL + TimescaleDB	Consulta e recuperação de séries temporais armazenadas
RF9 – Suporte à análise inteligente dos sinais vitais	Camada de inteligência baseada em regras parametrizáveis, persistência temporal e inferência contextual	Identificação de padrões de risco e geração de alertas explicáveis

A matriz apresentada demonstra que todos os requisitos funcionais definidos na fase de especificação foram implementados e posteriormente avaliados durante a validação experimental do ecossistema. Esta correspondência reforça a rastreabilidade do processo de desenvolvimento e contribui para a reprodutibilidade científica do artefacto proposto, em conformidade com os princípios da Design Science Research.

3.4 Fases e Sprints de Desenvolvimento

O processo de desenvolvimento seguiu seis fases DSR, implementadas através de quatro sprints de desenvolvimento:

Tabela 5. Mapeamento entre fases DSR e sprints de desenvolvimento.

Fase DSR	Sprint	Entregável Principal	Duração
1. Identificação do Problema	Pré-Sprint	Análise de requisitos e revisão da literatura	2 semanas
2. Objetivos da Solução	Pré-Sprint	Arquitetura de alto nível e stack tecnológica	1 semana
3. Design & Desenvolvimento	Sprint 1	Pipeline básico de dados e modelo de BD	3 semanas
3. Design & Desenvolvimento	Sprint 2	Autenticação, RBAC e API REST completa	3 semanas

3. Design & Desenvolvimento	Sprint 3	Motor de anomalias e alertas Redis	3 semanas
3. Design & Desenvolvimento	Sprint 4	Dashboard clínico e exportação	3 semanas
4. Demonstração	Pós-Sprint	Deploy em ambiente controlado	1 semana
5. Avaliação	Pós-Sprint	Testes experimentais e métricas	2 semanas
6. Comunicação	–	Presente dissertação	–

3.5 Ambiente de Teste e Coorte Sintética

A validação experimental foi conduzida num ambiente controlado composto por uma máquina virtual Ubuntu Server 22.04 LTS (4 vCPU, 8 GB RAM, SSD NVMe), representando o servidor de produção, e por um dispositivo físico Android (Samsung Galaxy A54) a executar a aplicação móvel desenvolvida. A coorte sintética de dez pacientes foi gerada com base em distribuições estatísticas derivadas da literatura fisiológica, representando perfis demográficos e clínicos heterogéneos.

Tabela 6. Perfis da coorte sintética de 10 pacientes utilizados na validação.

ID Paciente	Idade	Género	Condição Principal	SpO2 — valor de referência	FC — valor de referência
P001	28	M	Saudável	98-99%	62-72 bpm
P002	45	F	Hipertensão Grau 1	97-98%	68-78 bpm
P003	62	M	Diabetes Tipo 2	96-98%	70-82 bpm
P004	71	F	DPOC Leve	93-96%	72-85 bpm

P005	38	M	Saudável	98-99%	58-68 bpm
P006	55	F	Insuf. Cardíaca CF II	95-97%	75-90 bpm
P007	49	M	Hipertensão + Diabetes	96-98%	72-82 bpm
P008	33	F	Saudável	98-99%	60-70 bpm
P009	78	M	DPOC Moderado	91-94%	78-92 bpm
P010	66	F	Hipertensão Grau 2	96-98%	74-86 bpm

4 Desenvolvimento e Implementação

O ecossistema desenvolvido compreende três componentes primários com escolhas tecnológicas cuidadosamente justificadas pela literatura e pelos requisitos funcionais identificados. A Figura 2 apresenta a arquitetura ponta a ponta do sistema, evidenciando os fluxos de dados entre componentes e os protocolos de comunicação utilizados.



Figura 2. Arquitetura ponta a ponta do ecossistema. (Autoria própria, com apoio de IA para a renderização gráfica.)

4.1 Aplicação Móvel (Camada do Paciente)

A aplicação móvel foi desenvolvida em Flutter, adotando uma única base de código para suportar uma experiência multiplataforma. A escolha tecnológica procurou manter a camada móvel desacoplada do backend através de APIs bem definidas e concentrar nesta aplicação as funções de autenticação, aquisição de sinais vitais, integração BLE simulada, consulta do histórico e receção de alertas. Nesta dissertação, a adequação da escolha é avaliada sobretudo pela integração funcional da aplicação no ecossistema e não por uma comparação experimental de custos ou desempenho entre frameworks móveis.

A gestão de estado da aplicação utiliza o Context API do React combinado com o hook useReducer, padrão que elimina a necessidade de bibliotecas de gestão de estado externas (Redux) para aplicações de complexidade média, reduzindo a bundle size e a complexidade de debugging. A comunicação com o backend é realizada exclusivamente

via HTTPS com tokens JWT no cabeçalho Authorization, renovados automaticamente 5 minutos antes da expiração.

4.1.1 Funcionalidades Implementadas

1. Autenticação segura com JWT (access token 30 min + refresh token 7 dias), com armazenamento local seguro das credenciais de sessão na aplicação Flutter.
2. Entrada manual de quatro sinais vitais: frequência cardíaca, pressão arterial sistólica e diastólica, SpO2 e temperatura. Validação client-side de intervalos fisiológicos antes da transmissão.
3. Simulação de dispositivo wearable BLE: geração de leituras automáticas com variabilidade gaussiana em torno de valores basais configuráveis, representando um ponto de extensão para hardware real.
4. Visualização histórica com gráficos de linha interativos (biblioteca Victory Native), com zoom temporal configurável (1h, 24h, 7d, 30d) por sinal vital.
5. Receção e apresentação de notificações para alertas clínicos gerados pelo backend, com persistência local e estado de leitura na aplicação Flutter.

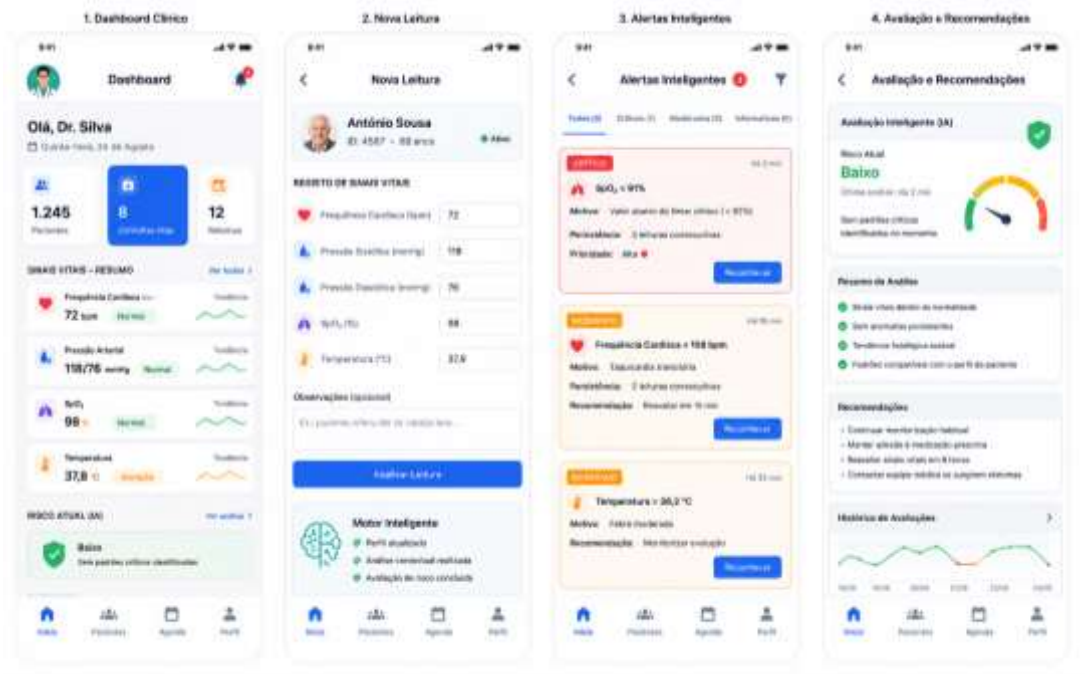


Figura 3. Interface da aplicação móvel desenvolvida. (Autoria própria — captura de ecrã da aplicação.)

4.2 Backend (Camada de Processamento e Armazenamento)

O backend constitui o núcleo de processamento do ecossistema. Foi desenvolvido em Python 3.11 com FastAPI, framework baseado no padrão ASGI e adequado à implementação de APIs assíncronas, com validação de dados e geração automática de documentação OpenAPI. A escolha foi orientada pela adequação funcional do framework à arquitetura proposta; a dissertação não pretende estabelecer um ranking comparativo de desempenho entre frameworks web.

4.2.1 Modelo de Dados e Armazenamento

Na arquitetura-alvo, o armazenamento utiliza PostgreSQL 15 com a extensão TimescaleDB 2.11, que acrescenta mecanismos orientados a séries temporais, como hypertables e particionamento temporal. A escolha é coerente com o desenho do sistema, no qual os sinais vitais são medições indexadas no tempo, e com a literatura sobre gestão de séries temporais em PostgreSQL (Freedman et al., 2019). O presente trabalho não realizou uma comparação experimental de compressão ou desempenho entre TimescaleDB e PostgreSQL convencional; no protocolo reprodutível de validação foi utilizada uma base SQLite temporária para isolar o ensaio.

A Figura 4 apresenta o esquema relacional simplificado do modelo de dados, com as cinco entidades principais e as suas relações.

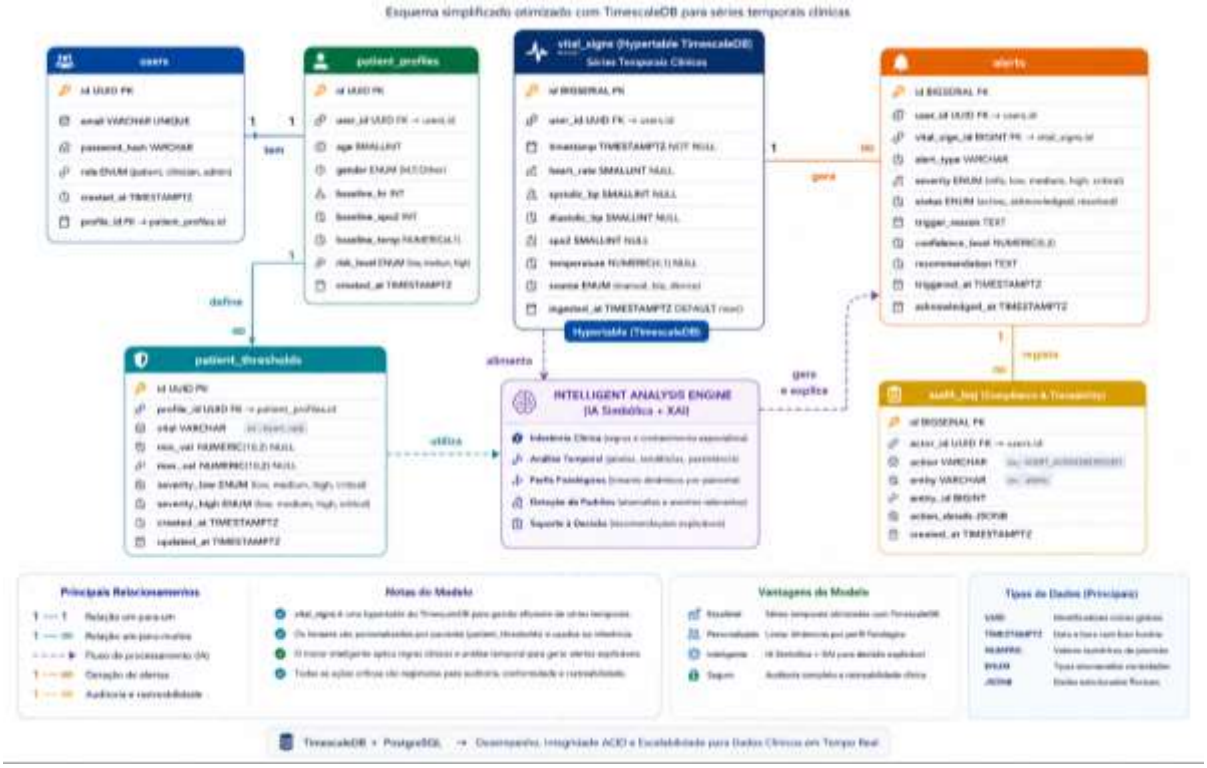


Figura 4. Esquema relacional do modelo de dados. (Autoria própria, com apoio de IA para a renderização gráfica.)

4.2.2 Motor de Deteção de Anomalias

O motor de deteção é implementado como um serviço assíncrono Python que é invocado após cada persistência bem-sucedida de uma leitura de sinal vital. O algoritmo avalia três condições em ordem sequencial:

- Verificação de threshold imediato: a leitura atual viola o intervalo [min_val, max_val] definido na tabela patient_thresholds para o paciente e sinal vital em questão.

- Verificação de persistência: as últimas N leituras consecutivas (N configurável, padrão N=3) também violaram o mesmo threshold, confirmando que não se trata de artefacto transitório.

- Verificação de duplicação: não existe um alerta ativo não resolvido do mesmo tipo para o mesmo paciente nas últimas 15 minutos, prevenindo spam de alertas.

Apenas quando as três condições são verificadas simultaneamente é gerado um alerta, publicado no canal Redis alert:{user_id} e persistido na tabela alerts com estado "novo". A Tabela 7 apresenta os thresholds padrão configurados para o protótipo. Estes valores constituem parâmetros técnicos do cenário experimental e não devem ser interpretados como limites clínicos universais ou recomendações diagnósticas. O motor foi desenhado como serviço independente com API bem definida — o princípio de design-by-replacement permite substituí-lo por um LSTM Autoencoder ou Anomaly Transformer sem alterar as camadas adjacentes de aplicação móvel, BD ou dashboard.

Tabela 7. Thresholds de deteção de anomalias por sinal vital (valores padrão, configuráveis por perfil de paciente).

Sinal Vital	Critério inferior	Critério superior	Persistência N	Enquadramento
Frequência Cardíaca	< 50 bpm	≥ 100 bpm	3 leituras	Parâmetro experimental
Pressão Arterial Sistólica	< 90 mmHg	≥ 140 mmHg	3 leituras	Parâmetro experimental
Pressão Arterial Diastólica	< 60 mmHg	≥ 90 mmHg	3 leituras	Parâmetro experimental
SpO2	< 94%	N/A	2 leituras	Parâmetro experimental
Temperatura Corporal	< 36,0 °C	≥ 38,0 °C	2 leituras	Parâmetro experimental

4.3 Dashboard Clínico (Camada de Visualização)

O dashboard clínico foi desenvolvido em React.js 18 com a biblioteca Recharts 2.8 para visualizações e TailwindCSS para estilos. Na arquitetura-alvo, a comunicação com o backend prevê REST API para dados históricos e um canal assíncrono para atualização de alertas. No protocolo experimental reprodutível utilizado nesta dissertação, contudo, a visibilidade dos alertas no dashboard foi emulada por polling com intervalo de 3 segundos. Consequentemente, os valores de latência apresentados na Secção 5 referem-se a este mecanismo experimental e não constituem uma medição de desempenho de WebSocket.

A interface organiza-se em quatro módulos principais: (i) Painel Geral com indicadores de estado agregados; (ii) Vista de Paciente com timelines temporais detalhadas; (iii) Centro de Alertas com gestão de estados e rastreabilidade; e (iv) Módulo de Relatórios com exportação CSV e PDF.

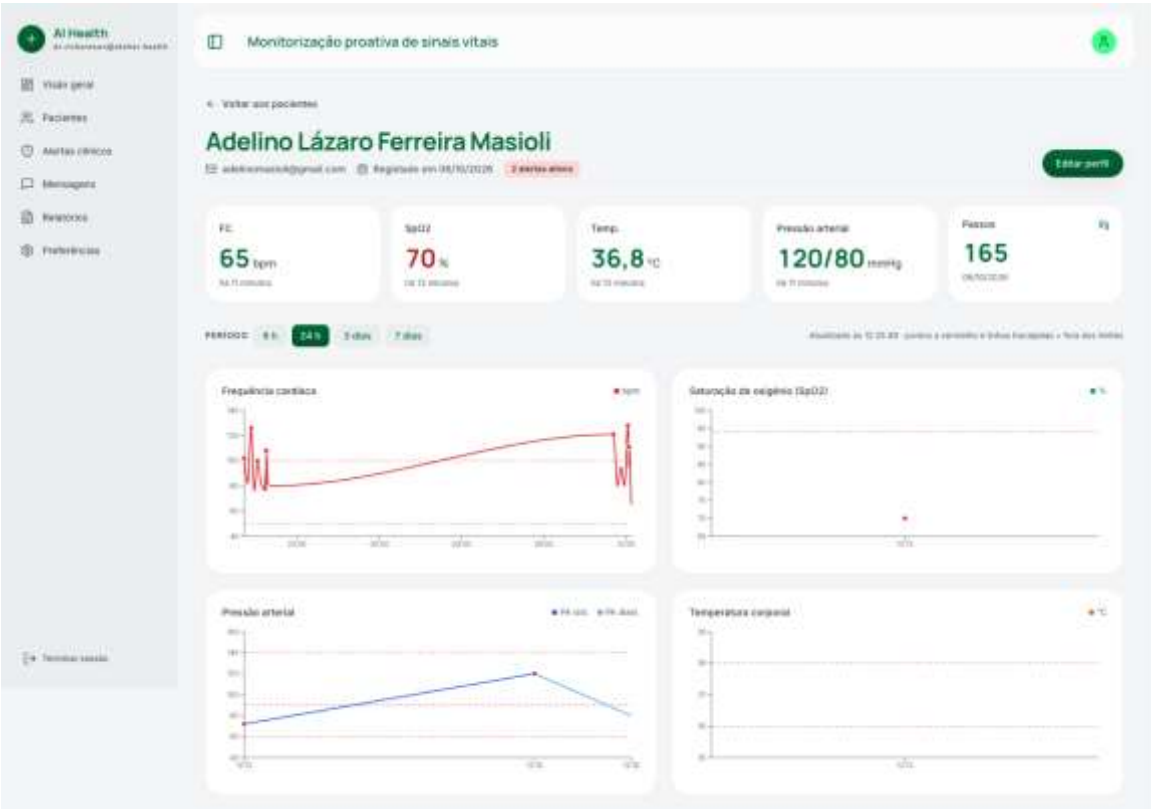


Figura 5. Interface do dashboard clínico desenvolvido. (Autoria própria — captura de ecrã da aplicação.)

4.4 Diagrama de Sequência e Fluxo Ponta a Ponta

A Figura 6 apresenta o diagrama de sequência do fluxo principal do sistema: submissão de uma leitura pela aplicação móvel, persistência, análise pelo motor de deteção, publicação de alerta e atualização em tempo real do dashboard clínico.

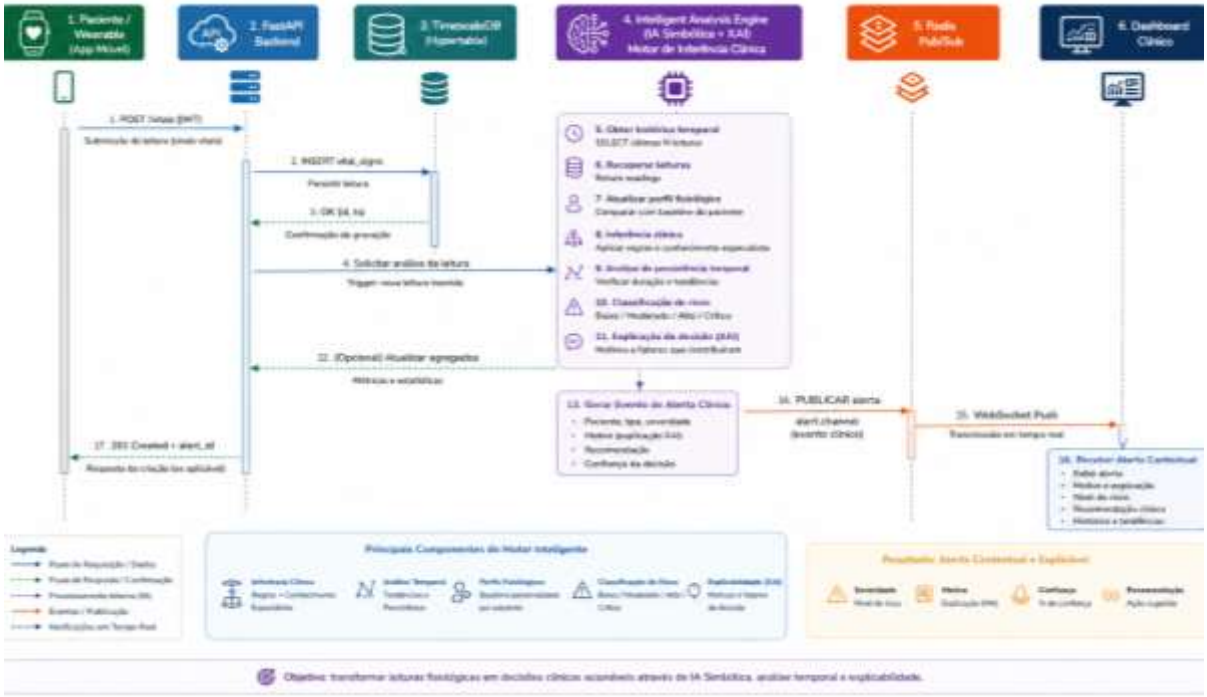


Figura 6. Diagrama de sequência do fluxo ponta a ponta. (Autoria própria, com apoio de IA para a renderização gráfica.)

5 Resultados

A validação experimental foi conduzida utilizando a coorte sintética descrita na Secção 3.5, ao longo de 72 horas de operação simulada. Todos os resultados desta secção foram obtidos em ambiente sintético controlado e validam a viabilidade técnica do pipeline, não a eficácia clínica em dados reais. O protocolo foi executado de forma reproduzível sobre uma instância isolada do backend, com base de dados SQLite temporária, sem alterar os dados de desenvolvimento. A coorte incluiu dez pacientes sintéticos; frequência cardíaca e SpO2 foram geradas a cada minuto, enquanto pressão arterial e temperatura foram geradas a cada 30 minutos, totalizando 90.770 leituras. Para a avaliação da deteção foram injetados 120 episódios positivos sustentados e 60 eventos

negativos destinados a testar o critério de persistência, dos quais 40 picos isolados e 20 sequências com N-1 leituras fora do limite.

5.1 Latência de Propagação Ponta a Ponta

A latência foi medida em 300 eventos executados através da API pública do backend. Para cada evento, registou-se o instante de submissão da leitura que confirmou a anomalia e o primeiro instante em que um dashboard emulado, consultando o endpoint de alertas a cada 3 segundos, conseguiu observar o alerta. O servidor e o cliente de teste correram na mesma máquina, pelo que a medição não inclui latência de rede pública nem tempo de renderização do navegador. Em complemento, foi medida a latência do próprio servidor entre submissão e resposta, cuja média foi de 6,0 ms.

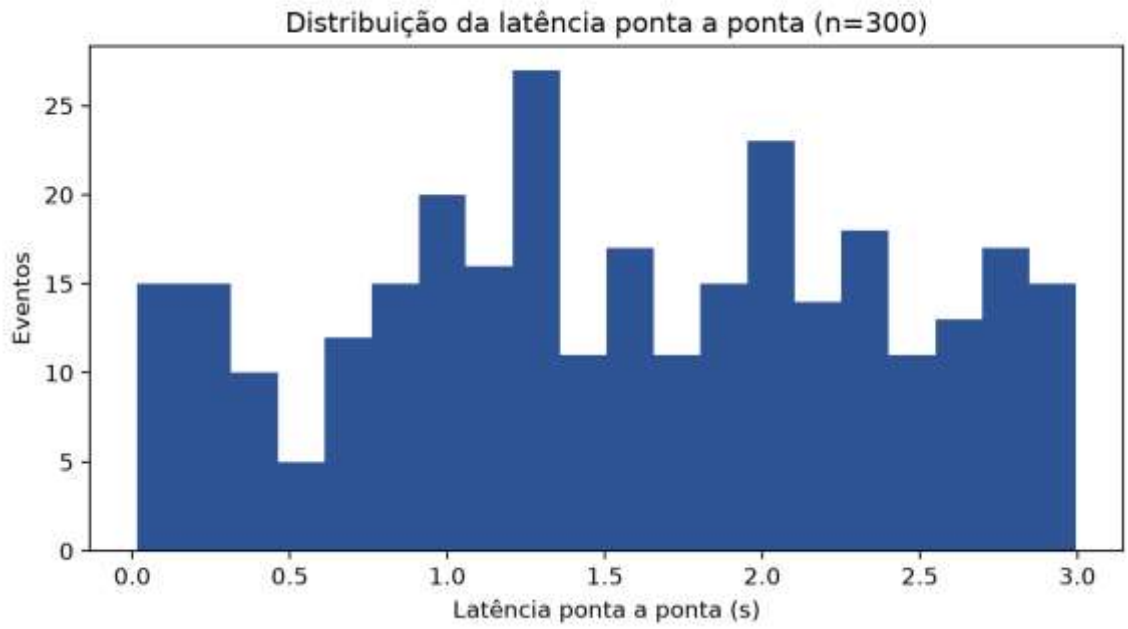


Figura 7. Histograma de distribuição da latência ponta a ponta (n=300). (Autoria própria.)

A Figura 7 apresenta a distribuição das 300 medições de latência ponta a ponta. Os valores distribuem-se entre 0,02 e 3,00 segundos, comportamento compatível com o intervalo de polling de 3 segundos utilizado pelo dashboard emulado. Para

complementar esta análise visual, a Tabela 8 apresenta média, mediana, percentis 95 e 99, mínimo e máximo, bem como a verificação dos critérios definidos no RNF1.

Tabela 8. Métricas de latência ponta a ponta (n=300 eventos). Critérios de aceitação definidos no RNF1.

Métrica de Latência	Valor Medido	Critério de aceitação (RNF1)	Avaliação
Média	1,55 s	< 5,0 s	Conforme
Mediana	1,54 s	N/A	Descritivo
Percentil 95 (p95)	2,84 s	N/A	Descritivo
Percentil 99 (p99)	2,97 s	< 10,0 s	Conforme
Mínimo	0,02 s	N/A	–
Máximo	3,00 s	N/A	–

Os resultados apresentados na Tabela 8 confirmam o cumprimento do RNF1 no ambiente experimental controlado. A latência média ponta a ponta foi de 1,55 segundos, com mediana de 1,54 segundos, percentil 95 de 2,84 segundos e percentil 99 de 2,97 segundos. O valor máximo observado foi de 3,00 segundos. A média permaneceu abaixo do limite de 5 segundos e o p99 abaixo do limite de 10 segundos definidos para o requisito.

5.2 Integridade dos Dados

A integridade dos dados foi avaliada através de perda de registos, duplicação, idempotência e concorrência. Foram enviadas 90.770 leituras e as 90.770 foram persistidas pelo servidor, sem perdas e sem registos adicionais ou duplicados. O ensaio experimental utilizou uma instância isolada do backend com uma base de dados SQLite

temporária, de modo a garantir reprodutibilidade e separação dos dados de desenvolvimento. A integridade foi verificada adicionalmente por retransmissão e por testes concorrentes de escrita.

A idempotência da ingestão foi verificada através do reenvio integral das 9.077 leituras do paciente P001: nenhuma nova leitura foi criada, todas foram reconhecidas como duplicadas e não foram gerados novos alertas. Adicionalmente, 20 escritas simultâneas da mesma leitura resultaram numa única criação e 19 respostas de duplicação, enquanto 20 escritas simultâneas de leituras distintas foram todas aceites sem erros de servidor.

5.3 Precisão da Deteção de Anomalias

A avaliação do motor de deteção foi realizada ao nível de episódios e alertas. A verdade de terreno foi definida pelo próprio protocolo experimental: episódios sustentados, com pelo menos N leituras consecutivas para além do limite, constituíram os casos positivos; picos isolados e sequências com N-1 leituras foram tratados como eventos negativos que não deveriam gerar alerta. Os resultados obtidos são apresentados na Tabela 9.

Tabela 9. Métricas de desempenho do motor de deteção de anomalias ao nível de episódios e alertas (120 episódios positivos e 60 eventos negativos).

Métrica	Valor	Interpretação
Verdadeiros Positivos (TP)	120	Episódios com alerta correspondente
Falsos Positivos (FP)	0	Alertas sem episódio correspondente
Falsos Negativos (FN)	0	Episódios sem alerta
Verdadeiros Negativos (TN)	60	Artefactos corretamente ignorados
Precisão (Precision)	100,0%	TP / (TP + FP)

Sensibilidade (Recall)	100,0%	TP / (TP + FN)
Especificidade	100,0%	TN / (TN + eventos negativos que geraram alerta)
F1-Score	1,000	2×P×R / (P+R)
Exatidão balanceada	100,0%	(Sensibilidade + Especificidade) / 2

A unidade de análise adotada foi o episódio/alerta. Dos 120 episódios anómalos sustentados injetados, todos produziram pelo menos um alerta correspondente, enquanto os 60 eventos negativos — 40 picos isolados e 20 sequências com N-1 leituras fora do limite — foram corretamente ignorados pelo mecanismo com persistência configurada. Como experiência comparativa, o mesmo fluxo foi processado com persistência N=1. Nessa configuração foram observados 73 falsos alertas, com precisão de 62,2% e F1-Score de 0,767, enquanto a sensibilidade permaneceu em 100%. A comparação evidencia que o critério de persistência temporal reduz substancialmente a geração de alertas espúrios no cenário sintético controlado.

Importa contextualizar cuidadosamente o desempenho observado na Tabela 9. As anomalias sustentadas foram injetadas através da violação controlada dos mesmos limites fisiológicos utilizados pelo motor de deteção, pelo que as métricas obtidas avaliam sobretudo a consistência interna do mecanismo no cenário experimental e não a sua capacidade discriminativa clínica em populações reais. Para reduzir a ambiguidade da análise, a unidade de avaliação foi definida ao nível de episódios e alertas: episódios sustentados constituem casos positivos e artefactos transitórios constituem casos negativos. A experiência de ablação, realizada sobre o mesmo fluxo de leituras com persistência N=1, fornece uma comparação direta do efeito desta regra, mas continua limitada ao ambiente sintético. Assim, os resultados não devem ser interpretados como evidência de eficácia clínica sobre variabilidade fisiológica real, ruído de sensores ou apresentações atípicas de doença, limitações discutidas na Secção 6.6.

6 Discussão dos Resultados

Os resultados obtidos confirmam a viabilidade técnica do ecossistema proposto e a adequação das escolhas arquiteturais ao problema de monitorização proativa de sinais vitais. A discussão organiza-se em torno de quatro dimensões: análise de desempenho, comparação com trabalhos relacionados, limitações e implicações práticas.

6.1 Interpretação dos Resultados Obtidos

Os resultados experimentais demonstraram que o ecossistema proposto foi capaz de cumprir os critérios técnicos definidos para o ambiente controlado. Foram processadas 90.770 leituras sem perdas ou duplicações, e os 120 episódios anómalos sustentados foram corretamente associados a alertas, sem falsos positivos ou falsos negativos no protocolo utilizado. A latência ponta a ponta apresentou média de 1,55 s e p99 de 2,97 s, cumprindo o RNF1. Adicionalmente, a experiência de ablação mostrou que, ao desativar a persistência temporal (N=1), o número de falsos alertas aumentou para 73 e a precisão caiu para 62,2%, reforçando empiricamente a utilidade do critério de persistência no controlo de alertas espúrios.

O desempenho observado resulta da combinação de vários fatores arquiteturais. A utilização de comunicação assíncrona, armazenamento otimizado para séries temporais e mecanismos de processamento desacoplados contribuiu para reduzir tempos de resposta e garantir consistência dos dados ao longo de todo o pipeline.

Adicionalmente, a utilização de perfis fisiológicos individualizados permitiu adaptar os mecanismos de deteção às características específicas de cada paciente, reduzindo classificações incorretas associadas à utilização de limiares universais.

6.2 Comparação com a Literatura

Os resultados obtidos são coerentes com a preocupação, presente na literatura de monitorização contínua, de reduzir alarmes espúrios e contextualizar medições fisiológicas antes de produzir informação de suporte à decisão (Clifton et al., 2014). No

presente trabalho, o efeito específico da persistência temporal é sustentado pela experiência de ablação realizada sobre o próprio fluxo experimental, e não atribuído diretamente a resultados quantitativos daquele estudo.

De forma semelhante, estudos como Perez et al. (2019) demonstram que dispositivos wearable podem fornecer informação fisiológica relevante para mecanismos de rastreio e monitorização. No presente trabalho, contudo, a integração com wearable foi simulada; por isso, os resultados obtidos sustentam apenas a viabilidade técnica do pipeline experimental.

Relativamente aos trabalhos baseados em Deep Learning, como Hannun et al. (2019), importa salientar que o presente sistema adota uma estratégia distinta. Em vez de privilegiar exclusivamente desempenho preditivo, procura equilibrar precisão, interpretabilidade e auditabilidade, aspetos considerados fundamentais em contextos clínicos regulados.

6.3 Impacto dos Dados Sintéticos

A componente inteligente implementada desempenhou um papel central no comportamento do ecossistema. Ao invés de se limitar à comparação direta entre leituras e limiares fixos, o sistema incorpora mecanismos de interpretação contextual, persistência temporal e inferência baseada em conhecimento clínico.

Esta abordagem permitiu reduzir alertas desnecessários e melhorar a qualidade da informação disponibilizada ao profissional de saúde. O sistema foi capaz de distinguir oscilações fisiológicas transitórias de padrões persistentes potencialmente associados a situações de risco.

Embora a arquitetura atual utilize Inteligência Artificial Simbólica e Sistemas Especialistas, os resultados obtidos demonstram que mecanismos explicáveis podem constituir uma alternativa válida a abordagens exclusivamente baseadas em aprendizagem automática, particularmente em cenários onde transparência e auditabilidade são requisitos fundamentais.

6.4 Escalabilidade

Apesar da validação experimental ter sido realizada com uma coorte sintética de dez pacientes, a arquitetura foi concebida com requisitos explícitos de escalabilidade. É importante clarificar que esta secção apresenta uma análise arquitetural, e não uma validação experimental de escalabilidade: as 90.770 leituras processadas correspondem a um único nó de processamento num ensaio controlado, não tendo sido conduzidos testes de carga com aumento progressivo do número de pacientes ou utilizadores concorrentes. A afirmação de escalabilidade assenta, portanto, em propriedades de desenho — separação modular entre aquisição, processamento, armazenamento e visualização, comunicação assíncrona e utilização de tecnologias adequadas a séries temporais — e não em medições empíricas do comportamento da arquitetura sob carga crescente.

A utilização de FastAPI assíncrono e a opção arquitetural por armazenamento orientado a séries temporais fornecem uma base tecnológica compatível com evolução para cenários de maior volume (Freedman et al., 2019), mas a transposição destas propriedades teóricas para centenas ou milhares de pacientes simultâneos exige confirmação empírica que este trabalho não realizou. Como trabalho futuro imediato, propõe-se um protocolo de teste de carga com ferramentas como Locust ou k6, simulando populações progressivas de utilizadores concorrentes (por exemplo, 50, 250, 1.000 e 5.000 pacientes ativos), medindo latência p95/p99, taxa de erros e utilização de CPU/memória em cada patamar, de modo a identificar empiricamente o ponto de degradação da arquitetura e a necessidade real de balanceamento de carga ou escalabilidade horizontal.

6.5 Wearables Reais

O sistema foi concebido para integração futura com dispositivos wearable reais, incluindo equipamentos da família Xiaomi Mi Band. Embora a validação experimental tenha recorrido a mecanismos de simulação compatíveis com Bluetooth Low Energy

(BLE), a arquitetura encontra-se preparada para receber dados provenientes de sensores físicos sem alterações significativas ao pipeline de processamento.

A utilização de dispositivos reais introduzirá naturalmente novos desafios relacionados com estabilidade da comunicação, autonomia energética, sincronização de leituras e qualidade dos sensores. Estes fatores poderão influenciar o desempenho observado e deverão ser avaliados em trabalhos futuros.

6.6 Limitações Metodológicas e Validade dos Resultados

Apesar dos resultados obtidos demonstrarem níveis elevados de desempenho técnico, a sua interpretação deve considerar cuidadosamente as limitações metodológicas associadas ao presente estudo.

A principal limitação decorre da utilização de dados sintéticos para validação do ecossistema. Embora os perfis dos pacientes tenham sido construídos com base em valores fisiológicos descritos na literatura científica e em referências clínicas amplamente aceites, os dados gerados não reproduzem integralmente a complexidade observada em ambientes reais de monitorização contínua.

Em contexto clínico real, os sinais vitais são influenciados por múltiplos fatores difíceis de simular com precisão, incluindo atividade física imprevisível, estados emocionais, condições ambientais, utilização irregular dos dispositivos, artefactos de medição, falhas de sensores e variabilidade fisiológica individual. Consequentemente, os resultados obtidos em ambiente controlado tendem a apresentar menor variabilidade do que aquela observada em cenários reais.

Outra limitação relevante prende-se com a inexistência de pacientes reais durante a fase de validação experimental. O objetivo principal desta investigação consistiu na validação técnica da arquitetura proposta e dos mecanismos inteligentes de análise implementados, não tendo sido realizada recolha de dados clínicos reais nem estudos observacionais com participantes humanos. Por este motivo, não foi necessária aprovação por comissão de ética nem foram conduzidos ensaios clínicos.

Importa igualmente salientar que a integração com dispositivos wearable foi validada através de mecanismos de simulação compatíveis com Bluetooth Low Energy (BLE). Embora esta abordagem tenha permitido validar o pipeline completo de aquisição, processamento, armazenamento e visualização dos dados, não foram realizados testes prolongados com dispositivos físicos em condições reais de utilização.

A utilização futura de equipamentos reais, como a Xiaomi Mi Band ou dispositivos equivalentes, poderá introduzir desafios adicionais relacionados com estabilidade da comunicação Bluetooth, sincronização de leituras, autonomia energética, perdas temporárias de conectividade e qualidade efetiva das medições recolhidas pelos sensores.

Relativamente à componente de Inteligência Artificial, importa salientar que o ecossistema desenvolvido já incorpora mecanismos de análise inteligente e suporte à decisão baseados em conhecimento clínico, inferência explicável e análise temporal contextualizada dos sinais vitais. Contudo, a validação destes mecanismos foi realizada exclusivamente sobre dados simulados. Embora esta abordagem permita avaliar a coerência das regras clínicas, dos modelos de inferência e dos fluxos automatizados de decisão, não permite ainda confirmar o seu desempenho em ambiente clínico real.

Estas limitações têm impacto direto na validade externa dos resultados. Assim, embora os indicadores obtidos demonstrem a viabilidade técnica da arquitetura, do mecanismo inteligente de análise e da infraestrutura de monitorização proposta, não permitem concluir de forma definitiva sobre a eficácia clínica do sistema em populações reais.

As métricas de desempenho do mecanismo de deteção devem ser interpretadas exclusivamente no contexto do ambiente experimental controlado. A utilização de dados sintéticos e de anomalias introduzidas segundo critérios previamente definidos permite avaliar a consistência técnica do mecanismo, mas não constitui evidência de eficácia clínica. Adicionalmente, as métricas de classificação referem-se à unidade de análise adotada na avaliação experimental e devem ser distinguidas da geração de alertas finais, que depende do mecanismo de persistência temporal implementado no sistema.

Consequentemente, os resultados apresentados devem ser interpretados como evidência da viabilidade técnica e arquitetural do ecossistema desenvolvido, e não como validação clínica definitiva da sua utilização em contexto assistencial. A confirmação da eficácia clínica exigirá estudos futuros envolvendo pacientes reais, recolha contínua de sinais vitais através de dispositivos wearable físicos, aprovação ética institucional e colaboração com profissionais de saúde.

6.7 Síntese da Discussão

A análise crítica dos resultados demonstra que o ecossistema proposto atingiu os objetivos definidos para esta investigação, validando a viabilidade técnica da arquitetura, do mecanismo inteligente de suporte à decisão e dos fluxos de monitorização implementados.

Os resultados obtidos sustentam as hipóteses formuladas, demonstrando que a combinação de recolha contínua de sinais vitais, análise inteligente baseada em conhecimento clínico e geração automática de alertas constitui uma abordagem promissora para monitorização remota de pacientes.

Não obstante, a utilização de dados sintéticos e a ausência de validação clínica real impõem limitações à generalização dos resultados, reforçando a necessidade de estudos futuros envolvendo pacientes reais, dispositivos wearable físicos e colaboração com profissionais de saúde.

7 Conclusão e Trabalho Futuro

A presente dissertação apresentou o design, a implementação e a validação experimental de um ecossistema digital integrado para a monitorização proativa de sinais vitais, seguindo a metodologia Design Science Research. O artefacto desenvolvido demonstrou a viabilidade técnica de um pipeline ponta a ponta em ambiente sintético controlado: foram processadas 90.770 leituras sem perda ou duplicação de registos, a latência média ponta a ponta foi de 1,55 s, com p99 de 2,97 s, e o motor de deteção

identificou os 120 episódios anómalos sustentados injetados sem falsos positivos ou falsos negativos no protocolo experimental. A experiência de ablação, executada sobre o mesmo fluxo com o critério de persistência desativado (N=1), produziu 73 falsos alertas e reduziu a precisão para 62,2%, evidenciando o contributo da persistência temporal para a robustez do mecanismo. Estes resultados devem ser interpretados como evidência de consistência técnica e arquitetural, e não como validação da eficácia clínica do sistema.

A principal contribuição científica é uma arquitetura de referência modular, reprodutível e extensível para ecossistemas de saúde digital, que integra componentes de aquisição móvel, processamento assíncrono, armazenamento em série temporal e visualização clínica. A separação clara de responsabilidades entre camadas e a modularidade do motor de deteção facilitam a extensão futura sem necessidade de reestruturação da infraestrutura de suporte.

7.1 Trabalho Futuro

7.1.1 Integração de Modelos de IA Preditiva

A substituição do motor baseado em regras por um autoencoder LSTM para deteção não supervisionada de anomalias multivariadas representa uma extensão relevante. Modelos desta natureza podem aprender um padrão fisiológico de referência individualizado para cada paciente, permitindo investigar alterações graduais que podem não ser captadas por thresholds fixos. A infraestrutura de armazenamento TimescaleDB foi concebida para suportar séries temporais e poderá alimentar futuros pipelines de treino incremental.

7.1.2 Estudos de Usabilidade Clínica

A condução de uma avaliação formal de usabilidade (SUS + think-aloud) com pelo menos 10 clínicos em contexto de trabalho real é essencial para identificar fricções no fluxo do dashboard e orientar iterações de design voltadas à prática clínica. A ausência desta validação constitui a limitação mais relevante do presente trabalho para a sua adoção clínica.

7.1.3 Produção e Conformidade Regulatória

Uma eventual migração para produção exigiria, entre outros aspetos, mecanismos de implantação e escalabilidade, comunicações seguras, registos de auditoria e uma análise regulatória formal. No contexto da União Europeia, uma eventual qualificação e classificação do software como dispositivo médico teria de ser determinada a partir da finalidade prevista, das funcionalidades disponibilizadas e do enquadramento regulamentar aplicável. Assim, não se assume nesta dissertação uma classe regulamentar específica para o protótipo; essa determinação deverá integrar uma etapa própria de avaliação regulatória antes de qualquer utilização clínica.

Referências Bibliográficas

Ancker, J. S., Edwards, A., Nosal, S., Hauser, D., Mauer, E., & Kaushal, R. (2017). Effects of workload, work complexity, and repeated alerts on alert fatigue in a clinical decision support system. BMC Medical Informatics and Decision Making, 17(1), 36.

Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. Information Fusion, 58, 82–115. https://doi.org/10.1016/j.inffus.2019.12.012

Bellazzi, R., & Zupan, B. (2008). Predictive data mining in clinical medicine: current issues and guidelines. International Journal of Medical Informatics, 77(2), 81-97.

Clifton, L., Clifton, D. A., Pimentel, M. A. F., Watkinson, P. J., & Tarassenko, L. (2014). Predictive monitoring of mobile patients by combining clinical observations with data from wearable sensors. IEEE Journal of Biomedical and Health Informatics, 18(3), 722-730.

Farahani, B., Firouzi, F., Chang, V., Badaroglu, M., Constant, N., & Mankodiya, K. (2018). Towards fog-driven IoT eHealth: Promises and challenges of IoT in medicine and healthcare. Future Generation Computer Systems, 78, 659-676.

Fowler, M. (2002). Patterns of enterprise application architecture. Addison-Wesley Professional.

Freedman, M., Pedreira, G., Kumar, A., & Morozov, D. (2019). TimescaleDB: Time-series data management in PostgreSQL. Proceedings of the VLDB Endowment, 12(12), 2182–2183. DOI: 10.14778/3352063.3352133

Gao, Y., Li, H., & Luo, Y. (2018). Wearable devices for health monitoring: A systematic review. Journal of Medical Systems, 42(12), 238.

Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P., & Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. Nature Medicine, 25(1), 65–69. https://doi.org/10.1038/s41591-018-0268-3

Hevner, A. R. (2007). A three cycle view of design science research. Scandinavian Journal of Information Systems, 19(2), 87-92.

Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). Design science in information systems research. MIS Quarterly, 28(1), 75-105.

Klasnja, P., & Pratt, W. (2012). Healthcare in the pocket: Mapping the space of mobile-phone health interventions. Journal of Biomedical Informatics, 45(1), 184-198.

Kvedar, J., Coye, M. J., & Everett, W. (2014). Connected health: a review of technologies and strategies to improve patient care with telemedicine and telehealth. Health Affairs, 33(2), 194-199.

Malhotra, P., Vig, L., Shroff, G., & Agarwal, P. (2015). Long short term memory networks for anomaly detection in time series. ESANN 2015 Proceedings, 23, 89-94.

Mandl, K. D., Gottlieb, D., & Mandel, J. C. (2024). Integration of AI in healthcare requires an interoperable digital data ecosystem. Nature Medicine, 30, 631–634. DOI: 10.1038/s41591-023-02783-w

Peffers, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2007). A design science research methodology for information systems research. Journal of Management Information Systems, 24(3), 45-77. DOI: 10.2753/MIS0742-1222240302

Pelkonen, T., Franklin, S., Cavallaro, P., Huang, Q., Meza, J., Teller, J., & Veeraraghavan, K. (2015). Gorilla: A fast, scalable, in-memory time series database. Proceedings of the VLDB Endowment, 8(12), 1816–1827. https://doi.org/10.14778/2824032.2824078

Perez, M. V., Mahaffey, K. W., Hedlin, H., Rumsfeld, J. S., Garcia, A., Ferris, T., Balasubramanian, V., Russo, A. M., Rajmane, A., Cheung, L., Hung, G., Lee, J., Kowey, P., Talati, N., Nag, D., Gummidipundi, S. E., Beatty, A., Hills, M. T., Desai, S., … Turakhia, M. P. (2019). Large-scale assessment of a smartwatch to identify atrial fibrillation. New England Journal of Medicine, 381(20), 1909–1917. DOI: 10.1056/NEJMoa1901183

Piwek, L., Ellis, D. A., Andrews, S., & Joinson, A. (2016). The rise of consumer health wearables: Promises and barriers. PLOS Medicine, 13(2), e1001953.

Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. New England Journal of Medicine, 380(14), 1347-1358.

Seneviratne, S., Hu, Y., Nguyen, T., Lan, G., Khalifa, S., Thilakarathna, K., Hassan, M., & Seneviratne, A. (2017). A survey of wearable devices and challenges. IEEE Communications Surveys & Tutorials, 19(4), 2573–2620. https://doi.org/10.1109/COMST.2017.2731979

Seto, E., Leonard, K. J., Cafazzo, J. A., Barnsley, J., Masino, C., & Ross, H. J. (2012). Mobile phone-based telemonitoring for heart failure management: a randomized controlled trial. Journal of Medical Internet Research, 14(1), e31.

Topol, E. J. (2019). Deep medicine: How artificial intelligence can make healthcare human again. Basic Books.

World Health Organization. (2021). Global strategy on digital health 2020-2025. WHO Press.

World Health Organization. (2023). Noncommunicable diseases: Key facts. WHO Factsheet.

Xu, J., Wu, H., Wang, J., & Long, M. (2021). Anomaly transformer: Time series anomaly detection with association discrepancy. arXiv:2110.02642.