
This is the **published version** of the bachelor thesis:

Sogas Linares, Ferran. *Disseny i implementació d'una arquitectura IoT Edge-to-Cloud per a la detecció de brots de MII a partir de dades passives de wearables.*

Treball de Final de Grau (Universitat Autònoma de Barcelona), 2026
(Enginyeria Informàtica)

This version is available at <https://ddd.uab.cat/record/334370>

under the terms of the  license.

Disseny i implementació d'una arquitectura IoT Edge-to-Cloud per a la detecció de brots de MII a partir de dades passives de wearables

Ferran Sogas Linares

Juny 2026

Resum— La Malaltia Inflamatòria Intestinal (MII) es gestiona avui de manera reactiva, quan el pacient ja presenta símptomes evidents. Evidència recent mostra que les dades passives de wearables s'alteren setmanes abans d'un brot, cosa que obre la porta a una detecció precoç i no invasiva. Aquest treball dissenya, implementa i valida una plataforma IoT Edge-to-Cloud que faria possible aquest monitoratge en un entorn hospitalari. L'aportació central és l'arquitectura completa i integrada extrem-a-extrem: una aplicació mòbil del pacient que pseudoanonimitza les dades en origen, una API REST sobre una base de dades de sèries temporals, un servei d'inferència que executa un model d'aprenentatge automàtic, i un quadre de comandament clínic. El sistema incorpora privacitat i seguretat per disseny, i s'ha validat empíricament: les proves de càrrega demostren que l'arquitectura suporta amb un marge molt ampli l'escala operativa prevista, amb degradació elegant i sense errors. El resultat és un MVP de plataforma robust sobre el qual un model entrenat amb dades reals podria operar en el futur.

Paraules clau— Arquitectura Edge-to-Cloud, Dades sintètiques, Internet de les Coses, Malaltia Inflamatòria Intestinal, Privacitat per disseny, Wearables.

Abstract— Inflammatory Bowel Disease (IBD) is currently managed reactively, once the patient already shows clear symptoms. Recent evidence shows that passive wearable data change weeks before a flare, opening the door to early, non-invasive detection. This work designs, implements and validates an Edge-to-Cloud IoT platform that would enable such monitoring in a hospital setting. Its central contribution is a complete, end-to-end integrated architecture: a patient mobile app that pseudonymises data at source, a REST API over a time-series database, an inference service running a machine learning model, and a clinical dashboard. The system embeds privacy and security by design, and has been empirically validated: load testing shows the architecture supports the intended operational scale with a wide margin, with graceful degradation and no errors. The result is a robust platform MVP on which a model trained with real data could operate in the future.

Keywords— Edge-to-Cloud Architecture, Inflammatory Bowel Disease, Internet of Things, Privacy by Design, Synthetic Data, Wearables.



1 INTRODUCCIÓ

LA Malaltia Inflamatòria Intestinal (MII), que engloba principalment la malaltia de Crohn i la Colitis Ulcerosa (CU), és una condició crònica caracteritzada per períodes de remissió intercalats amb episodis d'inflamació activa o *brots*. La gestió clínica actual és predominantment reactiva: les intervencions solen produir-se quan

• E-mail de contacte: ferran.sogas@autonoma.cat
• Menció realitzada: Enginyeria del Software
• Treball tutoritzat per: Miquel Trilla De Bruguera (Àrea de Ciències de la Computació i Intel·ligència Artificial)
• Curs 2025/26

el pacient ja presenta símptomes evidents, moment en què el dany pot ser avançat.

Els mètodes estàndard de monitoratge (analítics de sang, calprotectina fecal, ileocolonoscòpies) són invasius i constitueixen una “fotografia” estàtica en un moment puntual, deixant llargs períodes sense dades. L’IBD Forecast Study [1], realitzat per l’Icahn School of Medicine at Mount Sinai amb 309 pacients, va demostrar que les mètriques fisiològiques dels wearables s’alteren significativament fins a 7 setmanes abans de l’aparició clínica d’un brot, obrint la porta a un model de detecció precoç continu i no invasiu.

L’objectiu d’aquest treball és **dissenyar, implementar i validar la plataforma software IoT Edge-to-Cloud** que faria possible aquest monitoratge en un context clínic real, dirigida als hospitals. El projecte s’organitza en tres eixos: un mòdul Edge a l’aplicació del pacient amb anonimització per disseny, una infraestructura al núvol amb base de dades de sèries temporals, API i model d’IA, i un quadre de comandament clínic per a l’equip mèdic.

1.1 Aportacions principals

L’aportació central del treball és **una arquitectura Edge-to-Cloud completa, integrada i validada empíricament** per al cribratge poblacional de brots de MII. De manera concreta, les contribucions del treball són:

1. **Sistema extrem-a-extrem funcional:** el cicle complet mesura $\rightarrow$ API $\rightarrow$ base de dades de sèries temporals $\rightarrow$ inferència $\rightarrow$ visualització clínica, construït amb cinc components desacoblats i desplegats en un entorn que simula producció.
2. **Validació empírica del rendiment:** proves de càrrega reals que demostren que l’arquitectura supera l’objectiu de capacitat —es valida a l’escala operativa de 5.000 pacients actius, amb un sostre projectat unes $37\times$ superior— (Secció 6).
3. **Privacitat i seguretat per disseny verificables:** partició de la identitat en tres dominis disjunts i controls de compliment (RGPD, ENS, NIS2, AI Act) validats automàticament i coberts per tests.
4. **Un marc metodològic honest per a la IA amb dades sintètiques:** reconeixement explícit de les limitacions (validació circular, dependència d’un únic estudi) i reposicionament conscient del model com a peça funcional integrable.

1.2 Estructura del document

La Secció 2 fixa els objectius i justifica la seva revisió; la 3 resumeix l’estat de l’art; la 4 descriu la metodologia i l’arquitectura del sistema amb tots els components; la 5 detalla la privacitat, la seguretat i el compliment normatiu; la 6 presenta i discuteix els resultats (dataset, model, proves de càrrega, tests); la 7 fa l’anàlisi crítica i de riscos; la 8 repassa la planificació; i la 9 tanca amb les conclusions i el treball futur.

2 OBJECTIUS DEL PROJECTE I REVISIÓ

2.1 Objectius vigents

Els objectius del projecte, revisats durant el desenvolupament, són:

O1 – Arquitectura i rendiment. Implementar una arquitectura IoT basada en microserveis capaç de suportar la injecció concurrent de dades d’almenys 500 pacients virtuals amb una latència de processament inferior a 1 segon per registre, sobre una base de dades de sèries temporals optimitzada per a la càrrega d’ingesta i les consultes per finestra.

O2 – Privacitat per disseny. Garantir que el 100% de les dades transmeses al núvol estiguin pseudoanonimitzades i lliures d’Informació d’Identificació Personal (PII), complint el RGPD i el marc normatiu sanitari, i que la identitat associativa entre persona i registres resideixi exclusivament al dispositiu Edge i al sistema d’informació hospitalari.

O3 – Integració extrem-a-extrem. Disposar d’un mòdul Edge funcional (aplicació mòbil del pacient) que s’autentiqui contra el núvol, mantingui una cua de sincronització resilient i comuniqui amb el backend, demostrant la viabilitat operativa del cicle complet de mesura.

O4 – Component d’IA funcional. Generar un dataset sintètic d’almenys 500 pacients virtuals i entrenar un model d’aprenentatge automàtic que sigui *funcionalment integrable* a la plataforma: que produeixi prediccions a través del servei d’inferència, conservi la traçabilitat de la versió del model i serveixi com a substitut realista de la càrrega computacional del model real en proves de càrrega.

O5 – Quadre de comandament clínic. Construir un dashboard web per al metge que permeti consultar pacients, mesures i prediccions, i emetre alertes per als pacients amb risc elevat.

2.2 Justificació de la revisió

Els objectius (1), (2), (3) i (5) corresponen als originals del treball. En un punt del desenvolupament es va fer una modificació afectant l’objectiu (4), que substituïa l’objectiu original d’*assolir un $F1\text{-score} \geq 80\%$* . **Aquesta revisió va ser una decisió metodològica conscient, no una justificació a posteriori:** es va prendre en analitzar l’estructura de l’evidència disponible, abans de construir el model, i és precisament la que ha permès l’aportació central del treball.

Limitació estructural de l’evidència disponible. Tota la base científica del projecte prové d’un únic estudi [1]. No existeixen, a la data d’aquest treball, conjunts de dades públics longitudinals que combinin (i) mesures contínues d’Apple Watch en pacients amb MII, (ii) etiquetes de brot validades amb biomarcadors objectius i (iii) un volum suficient per a entrenar models supervisats independents. Aquesta absència de dades reals fa inviable construir un model d’IA clínicament validable, i la dependència d’una única font primària posa un sostre a la qualitat predictiva de qualsevol model entrenat sobre dades derivades.

Conseqüència productiva de la decisió. Reconèixer aquest límit *abans* d’invertir temps en una comparació exhaustiva de models—que no podria canviar la conclusió clínica—va alliberar esforç que es va redirigir a completar i validar la integració Edge-Cloud. El model conserva

el seu lloc com a *simulador realista* de la peça d'IA d'un sistema definitiu: tanca el cicle extrem-a-extrem, dimensiona la càrrega computacional del servei d'inferència i valida els contractes de dades entre mòduls. Així, la prioritat no és una precisió clínica concreta—que les dades no permeten—sinó consolidar la infraestructura sobre la qual un model definitiu, entrenat amb dades reals en el futur, podria operar. Els resultats de la Secció 6 confirmen que aquesta tria va ser encertada.

3 ESTAT DE L'ART

IBD Forecast Study. L'estudi de referència [1] va analitzar 309 participants amb Apple Watch (255), Fitbit (53) i Oura Ring (16). L'estat clínic es defineix sobre dos eixos: l'*inflamatori* (calprotectina fecal >150 mg/g, PCR >5 mg/dL o VSG >30 mm/h) i el *simptomàtic* (qüestionari PRO-2 diaris), donant lloc a quatre estats (remissió completa, brot inflamatori, brot simptomàtic i brot mixt). L'Apple Watch va ser triat com a dispositiu mestre perquè és l'únic que proporciona el perfil circadià complet de HRV (mitjançant el model cosinor) i SpO₂ contínua. L'estudi reporta un AUC de 0,98 i un F1-score de 0,88 a t+7 dies en brots inflamatoris amb una regressió logística mixta amb intercepte aleatori per pacient.

Solucions comercials properes. L'única solució comercial propera és Flarity [14], una app B2C en fase de proves que processa les dades exclusivament en local. El projecte aquí presentat es diferencia en tres dimensions clau: *enfocament B2B* dirigit als hospitals, *arquitectura centralitzada* al núvol per a anàlisi de cohorts i operació clínica, i *Privacitat per Disseny* amb pseudoanonimització a l'Edge.

4 METODOLOGIA I ARQUITECTURA DEL SISTEMA

4.1 Metodologia general

S'ha seguit **Kanban** com a metodologia àgil, amb tauler digital i estats *To Do*, *In Progress* i *Done*. El codi es gestiona amb Git, amb un repositori per cada component independent (model d'IA, API REST, servei d'inferència, mòdul Edge i dashboard clínic) i un repositori d'orquestració que aixeca i connecta el conjunt, amb contenidors Docker [4] propis quan escau. Aquesta separació reflecteix els cicles de vida i dependències que tindria el sistema en producció, i permet desplegar i provar cada peça de forma aïllada.

Les tecnologies principals són Python (generació de dades, ML i servei d'inferència), PostgreSQL amb TimescaleDB [2] (sèries temporals), FastAPI [3] (backend), scikit-learn [8] (model d'IA), Expo + React Native + TypeScript (mòdul Edge) i React + Vite + Material UI (dashboard clínic). El conjunt s'integra i es desplega en un entorn local que *simula producció*.

4.2 Arquitectura Edge-to-Cloud

El sistema és una arquitectura de microserveis desacoblats que es comuniquen mitjançant contractes REST ben definits. La Figura 1 en mostra la visió global. Cap component accedeix directament a l'estat d'un altre: l'app del pacient i el dashboard només parlen amb l'API; el servei d'inferència

també hi parla (mai directament amb la base de dades); i la base de dades és l'únic dipòsit d'estat. Aquesta disciplina és el que fa el sistema desplegable per peces i escalable de manera independent.

4.3 Pipeline de generació de dades sintètiques

Davant la inexistència de datasets públics amb la combinació necessària (dades longitudinals d'Apple Watch, etiquetes de brot i perfil clínic), s'ha generat un dataset sintètic parametritzat a partir de l'evidència científica.

Les variables del model són: MESOR, amplitud i acrofase del perfil circadià d'HRV (paràmetres del model cosinor sobre RMSSD horari), HR mitjana diària, RHR diària i SpO₂ mitjana diària; edat, sexe i BMI s'inclouen com a covariables. El generador s'organitza en tres classes (PatientProfileGenerator, ClinicalTrajectoryGenerator, PhysiologicalSignalGenerator) i una classe pipeline orquestradora. Els baselines individuals s'apliquen seqüencialment (taula per rang d'edat, ajust per sexe, BMI i medicació). La trajectòria clínica intercala remissions i brots (onset, durada 14–56 dies, tipus i recuperació) i injecta esdeveniments de confusió (infeccions, estrès agut, privació de son, exercici intens) només en remissió, perquè el model n'aprengui la distinció.

La degradació pre-brot de 49 dies s'implementa amb una funció de transició logística,

$$f(t) = \frac{1}{1 + e^{-0,15 \cdot (t - (-14))}}, \quad (1)$$

que produeix una degradació lenta a les setmanes 6–3 i una acceleració a les dues últimes, amb una recuperació post-brot anàloga però més suau. La diferència temporal és la clau discriminatòria: un brot de MII es degrada al llarg de 7 setmanes, mentre que una infecció respiratòria té inici agut en hores i es resol en 1–3 setmanes. La validació fisiològica del dataset es presenta a la Secció 6.1.

4.4 Base de dades i API REST

S'ha triat PostgreSQL amb l'extensió TimescaleDB perquè el sistema combina dades relacionals (metges, pacients, invitacions, prediccions amb metadades) i sèries temporals d'alta cardinalitat (mesures diàries). L'extensió afegeix el concepte d'*hypertable*, un particionat per finestres temporals que accelera les consultes típiques ("últimes N mesures d'un pacient") sense canviar el contracte SQL. L'esquema té cinc taules: doctors, patients, patient_invitations, daily_measurements (*hypertable*) i flare_predictions (*hypertable*), més la taula d'auditoria access_audit (Secció 5). La Figura 2 en mostra el model entitat-relació.

S'ha implementat una API REST amb FastAPI [3] com a intermediari entre els clients i la base de dades; la resta de l'*stack* és Python i FastAPI ofereix validació automàtica amb Pydantic [7], documentació OpenAPI i suport *async* natiu (l'ORM SQLAlchemy [6] + *asyncpg* gestiona les connexions). Es defineixen tres tipus d'usuari amb autenticació diferenciada. El **metge** fa login amb email + contrasenya i rep un JWT signat amb RS256; aquest mecanisme és




Fig. 1: Arquitectura Edge-to-Cloud de la plataforma MII. El cicle complet (mesura → API → BD → inferència → dashboard) opera amb components desacoblats darrere d'un únic perímetre TLS.




Fig. 2: Model entitat-relació. Les *hypertables* (en groc) emmagatzemen les sèries temporals; *access.audit* és immutable (*append-only*).

el del MVP i en un desplegament real se substituiria per la integració amb el sistema de credencials de l'hospital (SSO via SAML o OIDC) [13]. El **pacient** no té contrasenya: el metge el crea i genera una invitació UUID; el pacient escaneja un QR o introdueix manualment el codi, envia el seu *device_id* i rep un JWT que inclou *token_version* i *device_id*, verificats a cada petició. El **servidor d'inferència** s'autentica amb una API key estàtica al header *X-API-Key*. La invalidació per *token_version* permet la revocació i la migració de dispositiu sense intervenció del metge.

4.5 Servei d'inferència

El servei d'inferència és un microservei *batch* independent i contenidoritzat que carrega els models d'IA i genera prediccions a través de l'API REST. Un cop al dia (*cron* intern via *APScheduler*, 03:00 UTC), per a cada pacient actiu elegible recupera les seves últimes mesures vàlides, replica el preprocessament del mòdul d'entrenament (*z-score* sobre el *warm-up*, estadístics de finestra i normalització de covariables), passa el vector resultant pels 7 models del seu tipus

de malaltia i escriu les 7 prediccions, una per horitzó. Cada predicció inclou la *model_version* per a la traçabilitat. El processament aïlla els errors per pacient: un pacient amb dades corruptes queda registrat com a fallit, però no atura la resta del lot.

Equivalència entre entrenament i inferència. Un servei d'inferència separat de l'entrenament introdueix un risc subtil però greu: que el codi que transforma les mesures en el vector d'entrada del model no sigui exactament el mateix en els dos entorns. Si les dues implementacions divergeixen ni que sigui en un detall mínim, el model rep dades lleugerament diferents de les que va veure durant l'entrenament i emet prediccions errònies sense que res ho assenyali. Per descartar-ho, el preprocessament no es reescriu al servei d'inferència: es reutilitza literalment el mateix codi del mòdul d'entrenament, i un test automàtic comprova que tots dos camins produeixen exactament el mateix resultat. Concretament, sobre un cas de pacient de prova es compara el vector de 39 *features* calculat per les dues implementacions amb tolerància numèrica estricta (*rtol=1e-9*); si discrepen en el més mínim, el desplegament es bloqueja. A més, en carregar cada model es verifica que el seu hash SHA256 coincideixi amb el declarat al *metadata.json*: si un artefacte ha estat alterat, el servei no arrenca. Aquesta verificació criptogràfica de la integritat del model és, alhora, un requisit de traçabilitat de l'AI Act [11].

4.6 Mòdul Edge: aplicació mòbil del pacient

L'aplicació mòbil, construïda amb **React Native + TypeScript** mitjançant Expo, materialitza el rol del pacient. En el context del MVP, l'app llegeix una sèrie temporal pregenerada (CSV sintètic empaquetat) i la puja al backend, substituint el processament HealthKit + *cosinor* que faria un Apple Watch real; aquesta decisió respon a la indisponibilitat d'un Apple Watch i de context clínic, i a les restriccions temporals del TFG. Els fluxos clau són l'**activació amb QR** (genera un *device_id* persistent i obté el JWT, desat a *expo-secure-store/Keychain*), la **sincronització de mesures** (motor *syncEngine* amb *catch-up* dels

dies pendents i cua de reintents persistent) i la **migració entre dispositius** (incrementa `token_version` i invalida el JWT anterior). La Figura 3 mostra la interfície.

Camí a la sincronització automàtica. El disparador de sincronització actual és l'obertura de l'app o un botó manual, perquè Expo no permet tasques en *background* fiables sense un compte de pagament d'Apple. Aquesta és una limitació de l'entorn de desenvolupament, no del disseny: el motor està *desacoblat* del disparador i és *idempotent amb catch-up*, de manera que passar a automàtic és només registrar la tasca (`expo-background-fetch + expo-task-manager`) en un *build* natiu, sense canviar la lògica de sincronització.




Fig. 3: Aplicació mòbil del pacient: pantalla de prediccions per horitzó.

4.7 Quadre de comandament clínic

El dashboard clínic és una SPA de React 18 + Vite + TypeScript + Material UI que consumeix exclusivament l'API REST. Cobreix el cicle de treball del metge: *login*, llistat de pacients amb la probabilitat resumida a t+7 i ressaltat dels que superen un llindar d'alerta configurable, vista de detall amb pestanyes (resum, prediccions per als 7 horitzons, mesures), i creació de pacient amb generació del QR d'invitació. Les decisions de disseny prioritzen la seguretat i la claredat clínica: *polling* lleuger (refresc cada 90 s) en lloc de WebSocket, suficient per a 5.000 pacients sense endpoints addicionals; estats buits i d'error explícits sense exposar cap *traceback*; i un **disclaimer mèdic** fix que recorda que el sistema mostra una *probabilitat*, no una decisió. La Figura 4 mostra la interfície. El dashboard es serveix com a *build* estàtic des d'un origen propi, separat del de l'API: en producció, el frontend i el backend viurien en dominis diferents i el backend autoritzaria explícitament l'origen del dashboard mitjançant CORS.

4.8 Model d'IA

S'ha implementat un `HistGradientBoostingClassifier` de `scikit-learn` [8] amb estadístics de finestra de 28 dies, entrenat de forma independent per a Crohn i CU i amb un model per cadascun dels 7 horitzons (t+7 fins a t+49), és a dir 14 models. L'elecció és pragmàtica per al rol assignat al model: un classificador tabular ben establert, ràpid a entrenar i a inferir, compacte i interpretable amb *feature importance*. **L'optimització i comparació exhaustiva contra alternatives més sofisticades queda fora de l'abast revisat del treball** perquè, en absència de dades reals, no canvia la conclusió.

El pipeline és: càrrega i filtratge per malaltia i *split*; imputació per *forward-fill* limitat a 3 dies; normalització per pacient (*z-score* sobre els 90 dies de *warm-up*); generació de mostres tabulars amb estadístics dels últims 28 dies; construcció de 7 targets binaris derivats de `days_to_next_flare`; entrenament d'un model per horitzó amb `class_weight='balanced'`; i optimització del llindar de decisió sobre *validation* per maximitzar F1. El vector de features té 39 components: 30 estadístics de finestra (6 variables $\times$ 5 estadístics), 6 features d'acceleració i 3 covariables estàtiques. El `metadata.json` exportat formalitza el contracte amb el servei d'inferència (noms, ordre, llindars, mètriques i hash de reproductibilitat), i constitueix la *model card* del sistema d'acord amb les bones pràctiques i l'AI Act [11]. Els resultats es discuteixen a la Secció 6.2.

5 PRIVACITAT, SEGURETAT I COMPLIMENT NORMATIU

5.1 Partició d'identitat i minimització

El compliment es construeix sobre el principi de minimització: *el núvol no necessita conèixer la identitat del pacient per calcular les seves prediccions*. El sistema parteix la identitat en tres dominis disjunts. Al **domini hospitalari (HIS)** residiria el mapatge entre el `patient_id` opac (UUID) i la identitat real; aquesta taula no sortiria mai del HIS. El **domini del núvol** emmagatzema el `patient_id`, dades clíniques sense PII (edat, sexe, BMI, malaltia, classificació de Montreal, fase de tractament), les mesures i les prediccions; **la plataforma no emmagatzema noms, DNI, adreces, telèfons ni emails en cap taula**, i cap `claim` del JWT conté PII. El **domini Edge** coneix el `patient_id` i el `device_id` local, sense cap dada personal addicional.

5.2 Marc normatiu i controls implementats

El sistema s'ha fet robust davant d'un marc normatiu sanitari: **RGPD** [5] (Art. 5, 9, 25, 32, 35), **ENS** (RD 311/2022), **NIS2** [12] i **AI Act** [11]. L'entorn local que simula producció aplica **16 controls**, entre els quals: HTTPS forçat amb HSTS (terminat al reverse proxy Caddy [9]); CORS amb llista blanca; *rate limiting* i *lockout* exponencial al login (defensa contra força bruta); capçaleres de seguretat (CSP, X-Frame-Options, etc.); gestor d'excepcions que no filtra detalls interns en producció; **audit log append-only** (triggers a nivell de `STATEMENT` que bloquegen `UPDATE/DELETE`, garantint la immutabi-




Fig. 4: Quadre de comandament clínic: llistat de pacients amb alertes i detall amb prediccions per horitzó.

litat de la traça d'accessos); SSL a Postgres; i **JWT RS256** amb `/ .well-known/jwks . json`, que permet verificar tokens sense compartir secret i deixa preparada la federació OIDC futura. Els artefactes del model es verifiquen per SHA256 en carregar-se (AI Act Art. 14). Aquests controls es validen empíricament (Secció 6).

5.3 Drets ARCO i anàlisi de reidentificació

El sistema implementa els drets d'accés, rectificació, supressió, **portabilitat** (Art. 20: `/patients/me/export` retorna perfil, mesures, prediccions i invitacions) i **limitació del tractament** (Art. 18: amb la limitació activa, les mutacions del pacient es rebutgen amb 423 i el pacient queda exclòs del batch). La predicció *no és una decisió automatitzada* en el sentit de l'Art. 22 perquè el metge sempre intervé. Com a exercici de pensament crític, s'identifiquen dos vies potencials de reidentificació. Cal precisar que es tracta d'escenaris poc probables i extrems que requeririen condicions força específiques per materialitzar-se; per a cadascun s'apunta una mitigació plausible.

Empremta fisiològica. El baseline individual de HRV i RHR podria ser parcialment identificatiu: dos individus rarament tenen exactament el mateix perfil. Si un atacant disposés d'una mesura externa d'aquests valors, podria associar-les a un `patient.id` concret. *Possible mitigació:* el model d'IA ja opera sobre *z-scores* respecte el warm-up del propi pacient, no sobre valors absoluts; les visualitzaci-

ons agregades també es podrien presentar normalitzades, i els valors absoluts només es mostrarien al detall del pacient autenticat per al seu metge.

Filtració del mapatge HIS. El risc més greu en termes d'impacte seria una filtració de la taula del HIS que associa `patient.id` amb identitat real. Aquest risc queda **fora de l'abast tècnic de la plataforma**: és un risc del sistema d'informació hospitalari. *Possible mitigació:* documentar a la guia d'implantació la separació de privilegis (l'administrador del núvol no hauria de tenir accés al HIS i viceversa) i exigir xifrat en repòs de la taula del HIS.

6 RESULTATS

Aquesta secció presenta i discuteix els resultats empírics del treball en relació amb els objectius. Es distingeix nítidament entre el que les dades sintètiques *poden* demostrar (la coherència i el rendiment del sistema) i el que *no poden* (la capacitat clínica del model).

6.1 Validació del dataset sintètic

El dataset conté 5.000 pacients (3.170 Crohn, 1.830 CU) amb 365 dies cadascun. La distribució d'estats és: remissió completa 81,4%, brot inflamatori 6,5%, brot mixt 6,5%, brot simptomàtic 5,6%; durada mitjana de brots $34,5 \pm 12,0$ dies; mitjana de 2,1 brots/pacient. Després d'un calibratge amb 10.000 pacients simulats per corregir els *offsets* acu-

mulats, les mitjanes poblacionals en remissió reproduïen les de l'estudi de referència amb error baix (Taula 1).

TAULA 1: VALIDACIÓ FISIOLÒGICA EN REMISSIÓ

Variable	Generat	Estudi
HRV MESOR (ms)	40,49 ± 13,52	41,06
HR mitjana (lpm)	79,87 ± 6,46	78,92
RHR (lpm)	65,41 ± 5,42	64,64
SpO ₂ (%)	96,41 ± 0,49	96,49
HRV Amplitud (ms)	3,65 ± 1,09	3,69




Fig. 5: Evolució fisiològica d'un pacient sintètic al voltant d'un brot: degradació pre-brot (49 dies) i recuperació posterior.

6.2 Resultats del model d'IA

La Taula 2 mostra els resultats sobre *validation* amb llinard optimitzat per a Crohn (per a CU són lleugerament superiors a horitzons curts: F1=0,71, AUC=0,888 a t+7). Les mètriques són clarament inferiors a les de l'IBD Forecast Study [1] (F1=0,88, AUC=0,98 a t+7), cosa **coherent amb la naturalesa del dataset i amb el rol assignat al model**. Les raons són tres: la *resolució temporal* (el dataset agrega a registres diaris, no horaris com el paper); el *soroll injectat* deliberadament per evitar un sobreajust trivial a la funció generadora; i, sobretot, la *limitació estructural de la validació circular* (Secció 7).

TAULA 2: RESULTATS SOBRE VALIDATION (CROHN)

Horitzó	F1	Precis.	Recall	AUC
t+7	0,677	0,615	0,754	0,845
t+14	0,683	0,620	0,761	0,823
t+21	0,683	0,619	0,761	0,791
t+28	0,689	0,595	0,818	0,760
t+35	0,708	0,610	0,843	0,732
t+42	0,733	0,620	0,897	0,712
t+49	0,764	0,632	0,967	0,689

El que el resultat *sí* indica és que la *coherència* del pipeline és correcta: les variables més rellevants per

al classificador a t+7 són *hrv_amplitude_mean* (30,4%), *hrv_amplitude_trend* (15,2%) i *spo2_mean_daily_mean* (9,5%), exactament les identificades a l'estudi de referència (Figura 6). El model complex, doncs, el rol de l'objectiu O4: és funcionalment integrable, produeix prediccions a través del servei d'inferència, conserva la traçabilitat de versió i dimensiona la càrrega computacional (14 models de ~7 MB, latència d'inferència <10 ms per pacient) que el model definitiu hauria d'aguantar.




Fig. 6: Importància de features del model a t+7 (Crohn). El predomini del clúster HRV coincideix amb l'estudi de referència.

6.3 Proves de càrrega i rendiment

El resultat empíric central del treball és la validació de l'objectiu O1 mitjançant proves de càrrega reals sobre l'entorn local que simula producció (8 vCPU / 12 GB assignats a Docker), amb Locust [10] com a generador de càrrega. Es van mesurar tres eixos: estrès de l'API, estabilitat sostinguda (*soak*) i batch d'inferència a escala. **Tots els objectius es compleixen amb un marge molt ampli i amb 0 errors.**

Eix 1 — Estrès de l'API. Amb una mescla realista 2:1 metge:pacient i rampes de 50 a 400 usuaris concurrents (Taula 3), el sistema manté una capacitat còmoda de ~100–130 usuaris: a 100 usuaris els endpoints de treball tenen p95 de 96–180 ms i 0 errors (la p95 agregada superior s'explica pel login, que triga ~350 ms *per disseny*, pel factor de treball de *bcrypt*). El més rellevant és la **robustesa**: 0 errors a tots els nivells, fins i tot a 400 usuaris (~64.000 peticions). La degradació és *purament de latència* (el sistema encua i respon, no trenca): *graceful degradation* de manual. El coll d'ampolla identificat és la CPU de l'API (de 1,4 a 5,2 nuclis), mentre Postgres es manté per sota del 60%, de manera que l'**escalat natural és horitzontal** (replicar l'API darrere d'un balancejador).

Eix 2 — Estabilitat (*soak*). 50 usuaris constants durant 15 minuts (21.803 peticions): 0 errors, p95/p99 estables (310/350 ms) i **memòria plana** (+2%, l'API fins i tot baixa lleugerament). No hi ha indicis de fuga de memòria ni de connexions: el servei és estable en operació contínua.

Eix 3 — Batch d'inferència. El model no s'executa per pacient en temps real sinó en un batch diari, de manera que la validació dels "5.000 pacients actius" recau aquí. La Taula 4 mostra l'escalat: **els 5.000 pacients es processen en**

TAULA 3: ESTRÈS DE L'API: ESTAT ESTACIONARI PER NIVELL

Usuaris	RPS	p95 (ms)	% err.	CPU API
50	23,4	320	0,00	144%
100	46,6	340	0,00	283%
150	65,7	740	0,00	356%
200	71,8	1.900	0,00	519%
300	77,4	4.800	0,00	401%
400	73,9	10.000	0,00	428%

8,3 minuts, dins d'una finestra nocturna de 6 h (se n'usa el 2,3%). L'escalat és *lineal i predictable* (8,3 → 17,8 → 37,7 min per 5k → 10k → 20k) amb throughput estable (~9–10 pac/s) i 0 fallades en 35.000 inferències, donant un **sostre projectat de ~184.000 pacients**, unes **37× l'escala operativa de 5.000 pacients actius**.

TAULA 4: BATCH D'INFERÈNCIA: ESCALAT PER MIDA DE COHORT

Cohort	Durada	Throughput	ok/fail	Cap 6h
5.011	8,3 min	10 pac/s	5.007 / 0	✓
10.011	17,8 min	9 pac/s	10.007 / 0	✓
20.011	37,7 min	9 pac/s	20.007 / 0	✓

Interpretació respecte a l'objectiu O1. L'objectiu O1 —almenys 500 pacients amb latència inferior a 1 s per registre— es compleix amb un marge molt ampli: la latència d'escriptura per registre a càrrega còmoda es manté en desenes de mil·lisegons, molt per sota del segon, i la capacitat mesurada supera de llarg els 500 pacients. De fet, el sistema s'ha validat a l'escala operativa realista de 5.000 pacients actius, per tres vies independents: (i) la *ingesta passiva* és trivial—5.000 mesures/dia disperses ≈ 0,06 req/s de mitjana, >100× per sota de la capacitat mesurada; (ii) la *concurrència de metges* (≥100 simultanis amb 0 errors) supera amb escreix el pic realista d'un hospital; i (iii) el *batch nocturn* processa tota la cohort en minuts. La Figura 7 en resumeix el comportament.

6.4 Integració extrem-a-extrem assolida

Finalment, el resultat qualitatiu que sintetitza l'aportació del treball és que **el cicle complet opera de punta a punta**: l'app del pacient s'activa amb un QR generat pel dashboard, puja mesures contra el backend, el servei d'inferència les processa en el batch i n'escriu les prediccions, i el metge les consulta al dashboard—tot sobre HTTPS, amb auditoria d'accessos i amb cada artefacte de model verificat criptogràficament. Tota aquesta integració està sostinguda per una xarxa de prop de 180 proves automàtiques i per un script que comprova en viu els controls de compliment sobre l'entorn desplegat, de manera que la correcció del sistema és *verificable i reproducible*. El sistema deixa de ser un conjunt de peces per ser una plataforma.




Fig. 7: Resum de les proves de càrrega: latència p95 de l'API enfront del nombre de metges concurrents (a dalt) i escalat lineal del batch d'inferència (a baix). El throughput de l'API satura cap a 77 req/s i el batch dels 5.000 pacients triga 8,3 min dels 360 disponibles.

7 ANÀLISI CRÍTICA I RISCOS

Aquesta secció és l'exercici de *pensament crític* sobre el sistema construït, identificant-ne explícitament els límits.

Validació circular del model. El generador injecta el mateix patró fisiològic que el model intentarà aprendre. Per construcció, el model funciona bé sobre aquestes dades: qualsevol classificador raonable aprendrà la senyal que ha estat literalment programada al pipeline. **Aquesta correlació no és evidència de capacitat predictiva sobre dades reals**, i per això les mètriques de la Secció 6.2 no s'han de llegir com a rendiment clínic.

Falsos positius i decisió clínica. A t+7 el model genera ≈28% de falsos positius sobre dades sintètiques. En un desplegament real, la conseqüència depèn del flux d'actuació: una alerta que provoqui una calprotectina (cost baix) té un balanç favorable; una que provoqui una colonoscòpia (cost alt, invasiu), inacceptable amb aquesta precisió. Per això el dashboard mostra la *probabilitat*, no la decisió binària, amb un disclaimer explícit.

Abast de la validació de càrrega. Els números de la Secció 6.3 són una *fitxa inferior* conservadora: el generador de càrrega comparteix maquinari amb el sistema sota prova (8 vCPU compartits) i les dades són sintètiques (vàlides per a rendiment, no per a clínica). En un desplegament al núvol amb serveis separats, els sostres podrien variar. Tot i això, el marge mesurat és prou ampli perquè la conclusió sigui robusta.

Limitacions assumides conscientment. La sincronització automàtica de l'Edge i l'SSO multi-hospital no estan implementats; tots dos són decisions conscients amb el *groundwork* ja fet (motor de sync idempotent; JWT RS256 + JWKS) i documentats com a treball de desplegament, no com a límits arquitectònics.

8 SEGUIMENT DE LA PLANIFICACIÓ

La Taula 5 presenta el seguiment final de la planificació que s'ha seguit, **s'han completat totes les fases previstes**. L'únic ajust significatiu respecte a la proposta original va ser l'**avançament del servei d'inferència**, conseqüència directa de la revisió d'objectius (Secció 2): el temps que s'hauria dedicat a la comparació exhaustiva de models es va redirigir a la integració Edge-Cloud, que és l'eix de valor del treball.

TAULA 5: SEGUIMENT DE LA PLANIFICACIÓ TEMPORAL

Fase	Setm.	Estat
Documentació i informe inicial	1–4	Completat
Dataset sintètic: informe + pipeline	5–9	Completat
Disseny i creació BBDD	5–9	Completat
Desenvolupament API REST	5–9	Completat
Model d'IA (entrenament)	10–14	Completat
Mòdul Edge	10–14	Completat
Servei d'inferència	15–17	Completat
Dashboard clínic	15–17	Completat
Proves de càrrega i validació	18–20	Completat

9 CONCLUSIONS I TREBALL FUTUR

9.1 Conclusions

Aquest treball ha assolit amb èxit l'objectiu central de dissenyar, implementar i validar una arquitectura IoT Edge-to-Cloud completa i funcional per a la detecció precoç de brots de Malaltia Inflamatòria Intestinal (MII) en un entorn clínic. El sistema resultant cobreix tot el cicle de dades extrem-a-extrem, des de l'aplicació del pacient fins al quadre de comandament de l'equip mèdic, mitjançant cinc components desacoblats i integrats sota els principis de privacitat per disseny i compliment normatiu rigorós.

La validació empírica de l'arquitectura ha demostrat un rendiment robust, superant els requisits operatius establerts per a un total de 5.000 pacients actius, garantint temps de latència òptims i sense registrar errors sota situacions d'estrès.

La revisió d'objectius va ser un moviment metodològic conscient i encertat: reconèixer que el valor del treball es troba en *l'arquitectura completa i validada*, i no en una mètrica d'un model que no es pot validar amb garanties, va aportar coherència amb les limitacions del coneixement disponible i un focus en la solidesa de la integració arquitectònica. Les conclusions tècniques confirmen la idoneïtat de PostgreSQL+TimescaleDB, l'eficàcia de FastAPI i l'avançatge del patró d'invitació sense contrasenyes per als pacients.

En conclusió, aquest projecte no només compleix les fites d'enginyeria de programari proposades, sinó que estableix un Producte Mínim Viable (MVP) i un marc tecnològic totalment preparat per acollir models predictius definitius quan es disposi de conjunts de dades clíniques reals en el futur.

9.2 Treball futur

Si el projecte té continuïtat: un **estudi pilot prospectiu** amb pacients reals i biomarcadors objectius periòdics; el reenrenament i la validació clínica del model amb dades reals; el recalibratge dels paràmetres del generador a partir de les distribucions observades; l'exploració de models recurrents quan el volum de dades ho justifiqui; la integració amb HealthKit real i el processament cosinor al wearable; la sincronització automàtica de l'Edge en un *build* natiu; l'ús de SSO/OIDC per part de l'hospital; i el desplegament al núvol amb escalat horitzontal de l'API.

ÚS DE LA IA GENERATIVA

Per a la realització d'aquest treball s'han utilitzat eines d'intel·ligència artificial generativa (Claude i Perplexity) de manera puntual i controlada, com a suport durant el procés. El seu ús s'ha limitat a tres tasques: (1) la comprensió i consolidació de conceptes aliens a l'enginyeria; (2) la consulta de sintaxi i funcionalitats de llibreries i eines, de manera equivalent a l'ús de documentació oficial o fòrums tècnics; i (3) la millora de la claredat, l'estructura i la redacció del text. En cap cas la IA ha pres decisions de disseny, ha definit l'arquitectura, ha seleccionat les tecnologies ni ha analitzat els resultats.

AGRAÏMENTS

Agraïment especial al tutor del treball, Miquel Trilla, pel retorn crític continuat, que ha orientat de manera decisiva la consolidació del projecte. També a la família i les amistats pel suport constant.

REFERÈNCIES

- [1] R. P. Hirten et al., "Physiological Data Collected From Wearable Devices Identify and Predict Inflammatory Bowel Disease Flares," *Gastroenterology*, vol. 168, pp. 939–951, 2025.
- [2] Timescale, "TimescaleDB Documentation," 2025. [Online]. Disponible: <https://docs.timescale.com>
- [3] S. Ramírez, "FastAPI Documentation," 2025. [Online]. Disponible: <https://fastapi.tiangolo.com>
- [4] Docker Inc., "Docker Documentation," 2025. [Online]. Disponible: <https://docs.docker.com>
- [5] Reglament (UE) 2016/679 del Parlament Europeu i del Consell, de 27 d'abril de 2016, relatiu a la protecció de les persones físiques pel que fa al tractament de dades personals.
- [6] M. Bayer, "SQLAlchemy Documentation," 2025. [Online]. Disponible: <https://docs.sqlalchemy.org>
- [7] S. Colvin, "Pydantic: Data Validation using Python Type Hints," 2025. [Online]. Disponible: <https://docs.pydantic.dev>

- [8] F. Pedregosa et al., “Scikit-learn: Machine Learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [9] Caddy, “Caddy Web Server Documentation,” 2025. [Online]. Disponible: <https://caddyserver.com/docs>
- [10] Locust, “Locust: An open source load testing tool,” 2025. [Online]. Disponible: <https://locust.io>
- [11] Reglament (UE) 2024/1689 del Parlament Europeu i del Consell (Reglament d’Intel·ligència Artificial, AI Act), 2024.
- [12] Directiva (UE) 2022/2555 (NIS2) relativa a les mesures per a un elevat nivell comú de ciberseguretat a la Unió, 2022.
- [13] OpenID Foundation, “OpenID Connect Core 1.0,” 2014. [Online]. Disponible: https://openid.net/specs/openid-connect-core-1_0.html
- [14] Flarity, “Flarity – IBD Flare Prediction App,” 2025. [Online]. Disponible: <https://flarity.com>