

CAEPIA 2026

ESTYLF

CONGRESO ESPAÑOL • SOFT COMPUTING & FUZZY LOGIC

11•13 NOV 2026 UNIVERSIDAD DE JAEN



Libro de resúmenes del XXIV Congreso Español sobre Tecnologías y Lógica Fuzzy – ESTYLF 2026

Trabajos en curso. Jaén, 11–13 de noviembre de 2026

Universidad de Jaén

AEPIA
ASOCIACIÓN ESPAÑOLA PARA LA INTELIGENCIA ARTIFICIAL



Libro de resúmenes del XXIV Congreso Español sobre Tecnologías y Lógica Fuzzy – ESTYLF 2026

Antigua Escuela de Magisterio de Jaén. Universidad de Jaén

Jaén, España

11-13 de noviembre de 2026

Publicador por:
Universidad de Jaén
http:https://simidat.ujaen.es/caepia26/conferencias/estylf

ISBN: 978-84-09-92828-6

Credits:
Portada: Luis Jiménez Jiménez & Juan Moreno García
LaTeX editores: Macarena Espinilla Estévez, Luis Jiménez Linares, Luis Magdalena Layos y Juan Moreno García
Actas generadas con LaTeX's 'confproc' package, version 0.8 (optional: by V. Verfaille)

Selección difusa de clientes para detección federada del estrés en dispositivos IoMT

José L. López Ruiz[1 [0000−0003−2583−8638]⋆], Carlos Montoya-Peña[2 [0009−0007−3111−3146]], Juan Francisco Gaitán Guerrero[1 [0009−0007−6872−1401]], Antonio Pedro Albín Rodríguez[1 [0000−0003−3447−2260]], Macarena Espinilla[1 [0000−0003−1118−7782]], and Carlos Fernández-Basso[3 [0000−0002−8809−8676]]

[1] Dpto. Informática, Universidad de Jaén, España
{llopez,jgaitan,aalbin,mestevez}@ujaen.es
[2] Facultad de Ingeniería, Universidad Don Bosco, Soyapango, El Salvador
carlos.montoya@udb.edu.sv
[3] Dpto. de Ciencias de la Computación e IA, Universidad de Granada, España
cjferba@ugr.es

Resumen. El estrés crónico es un factor de riesgo cardiovascular y mental cuya detección continua mediante dispositivos vestibles del Internet de las Cosas Médicas constituye una alternativa no invasiva viable en el borde. Llevar esa solución a un despliegue real exige aprendizaje federado; sin embargo, el algoritmo canónico FedAvg no contempla factores determinantes como la calidad de la señal, el movimiento, la batería o la antigüedad de la calibración. Proponemos un sistema basado en reglas difusas de tipo Mamdani que toma esos cuatro factores como antecedentes operacionales y devuelve dos salidas continuas y auditables, una probabilidad de inclusión π_c y un peso de agregación ω_c, mediante una base de once reglas. Se ha desarrollado un prototipo en `scikit-fuzzy` evaluado sobre cinco perfiles de cliente, base de un futuro sistema federado de detección de estrés desplegado sobre dispositivos de bajo coste.

Palabras clave: Aprendizaje federado · Lógica difusa · Monitorización del estrés · Variabilidad de la frecuencia cardíaca · Internet de las Cosas Médicas.

1 Introducción

El estrés crónico afecta a cerca del 13 % de la población adulta y es un factor de riesgo cardiovascular y mental [7]. La evaluación clínica convencional resulta intrusiva y poco apta para la monitorización ambulatoria, mientras que el Internet de las Cosas Médicas (IoMT) y los dispositivos vestibles han abierto una vía no invasiva basada en la Variabilidad de la Frecuencia Cardíaca (HRV) y el ritmo respiratorio, viable incluso sobre dispositivos de cómputo reducido [4]. El salto a un despliegue real choca, sin embargo, con dos obstáculos: la marcada

⋆ Autor de correspondencia: llopez@ujaen.es

variabilidad inter-sujeto obliga a personalizar el modelo a cada paciente, y las restricciones regulatorias y éticas sobre la centralización de datos biométricos limitan la agregación de información.

El aprendizaje federado (FL) [3] responde a ambos problemas: mantiene los datos en el dispositivo y habilita el entrenamiento colaborativo. En nuestra propuesta basada en dispositivos vestibles biométricos, FedAvg presenta limitaciones operacionales: trata la inclusión como decisión binaria que descarta el matiz de indicadores como el Índice de Calidad de la Señal (Signal Quality Index, SQI) [5], combina evidencias heterogéneas (señal, batería, calibración) mediante umbrales independientes y no proporciona trazabilidad clínica de la exclusión. Para abordarlas proponemos un sistema basado en reglas difusas [2] de tipo Mamdani, en adelante módulo difuso, concebido para integrarse en arquitecturas federadas como las validadas previamente en entornos clínicos e IoMT [6].

El caso de uso de referencia [4] aborda la clasificación estrés/no-estrés sobre WESAD con un esquema de dos etapas (entrenamiento poblacional y fine-tuning por sujeto) en dispositivos de borde. Se proyecta sobre un esquema FL con personalización local persistente: cada sujeto es un cliente que entrena de forma incremental sobre sus registros HRV y respiratorios, conserva el modelo afinado y participa en rondas periódicas de agregación con un nodo central, sobre las que actúa la capa difusa descrita a continuación.

2 Sistema basado en reglas difusas para selección y ponderación federada de clientes

El módulo difuso recibe cuatro señales operacionales por cliente, detalladas en la Figura 1: el SQI cardíaco (índice de Orphanidou en $[0, 1]$) gobierna la validez de las características de HRV; el movimiento distingue un sensor mal ajustado de la actividad física; la energía condiciona la comunicación con el nodo y la fiabilidad de las medidas; y la antigüedad de la calibración refleja que la medicación puede desfasar los valores de referencia en pocas horas.

El módulo difuso produce dos consecuentes funcionalmente desacoplados: la inclusión π_c (¿debe participar el cliente en la ronda actual?) y el peso ω_c (¿cuánto debe contribuir su actualización al modelo agregado?). Ambos comparten las mismas cinco etiquetas trapezoidales (muy baja a muy alta) de la Figura 1. Cada cliente evalúa las 11 reglas en local combinando los antecedentes con la T-norma, agrega las contribuciones activadas con la t-conorma del máximo y obtiene (π_c, ω_c) por defuzzificación de centroide, siguiendo el tratamiento estándar de Mamdani [2]. Las reglas, derivadas de conocimiento experto, cubren la exclusión (mala señal, movimiento o batería crítica), la inclusión graduada por SQI, energía y antigüedad de la calibración, y la reducción del peso ante una calibración obsoleta; una regla de soporte residual (R11) garantiza por construcción $\pi_c \geq \pi_{\min}$.

Integración con FedAvg. En la ronda t cada cliente c evalúa localmente su módulo difuso sobre las cuatro señales y transmite al nodo central el par (π_c^t, ω_c^t). El nodo realiza para cada cliente una tirada de Bernoulli con probabilidad π_c^t; el

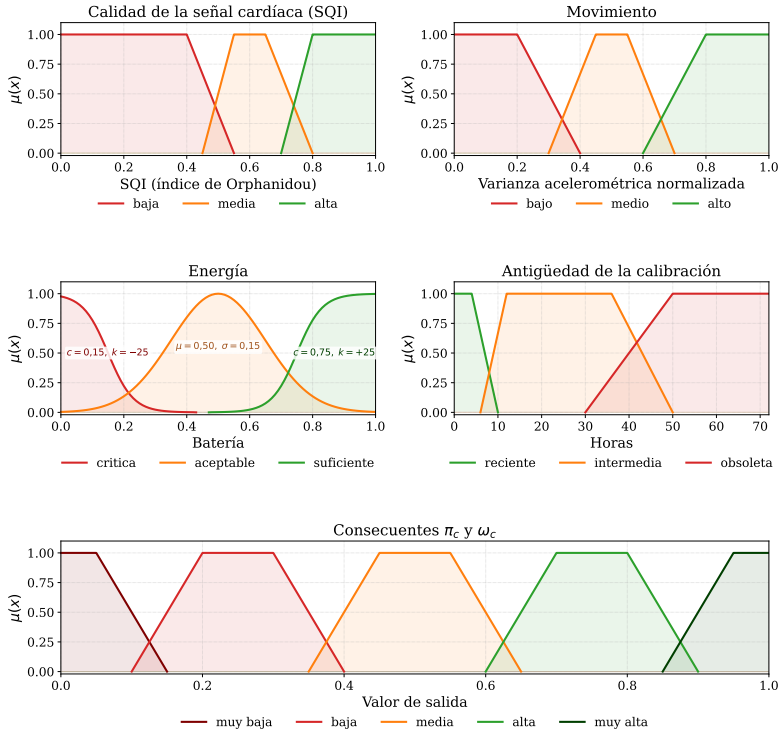


Fig. 1. Funciones de pertenencia del módulo difuso: cuatro antecedentes operacionales (SQI cardíaco, movimiento, energía, antigüedad de la calibración) y la partición de salida compartida por π_c y ω_c.

subconjunto resultante S_t se corrige para satisfacer la restricción de cardinalidad $|S_t| \in [K_{\min}, K_{\max}]$. El peso canónico de FedAvg n_c/n se sustituye por el peso compuesto $\omega_c^t\, n_c / \sum_{c' \in S_t} \omega_{c'}^t\, n_{c'}$, de modo que los clientes con menor calidad operacional contribuyen menos al modelo agregado. Este es el régimen de biased client sampling de [1], cuyas garantías de convergencia se preservan bajo dos condiciones constructivas: (i) $\pi_c^t \geq \pi_{\min} > 0$ para todo c, t, impuesta por R11; y (ii) la respuesta continua y acotada del módulo a sus entradas, que se verifica para nuestras particiones trapezoidales y los operadores mínimo/máximo.

3 Resultados preliminares

Implementamos el módulo difuso en `scikit-fuzzy` con las 11 reglas y las particiones de la Figura 1, y lo evaluamos sobre los cinco perfiles de la Tabla 1. El rango operativo $\pi_c, \omega_c \in [0{,}27;\ 0{,}93]$ reproduce la jerarquía cualitativa esperada (condiciones ideales arriba, batería crítica abajo pese a su señal casi perfecta) sin umbrales duros, y cada salida es trazable a las etiquetas lingüísticas activadas. El

Table 1. Salidas π_c y ω_c defuzzificadas por centroide sobre cinco perfiles representativos de cliente.

Perfil	SQI	Artef.	Energ.	Cal. (h)	π_c	ω_c
Nominal	0.72	0.30	0.55	6	0.57	0.57
Sujeto en movimiento	0.45	0.75	0.60	12	0.38	0.38
Batería crítica	0.85	0.15	0.10	4	0.27	0.27
Condiciones ideales	0.92	0.10	0.90	2	0.93	0.93
Calibración obsoleta	0.55	0.20	0.50	60	0.50	0.38

perfil de calibración obsoleta ilustra el desacoplo entre consecuentes ($\pi_c = 0{,}50$ frente a $\omega_c = 0{,}38$): el cliente sigue siendo seleccionable pero su gradiente pesa menos porque el módulo reconoce que el fine-tuning local está desfasado.

4 Trabajo en desarrollo

Los resultados validan el comportamiento del módulo difuso a nivel de cliente; el siguiente paso es integrarlo en el bucle federado completo, desplegándolo sobre dispositivos vestibles biométricos y un nodo central de agregación para evaluar su comportamiento conjunto con FedAvg en condiciones operativas reales.

Agradecimientos. This work has been partially supported by grant PID2024-156412OB-I00 funded by MICIU/AEI/10.13039/501100011033 and by "ERDF/EU" and grant M.2 PDC_000756 funded by Consejería de Universidad, Investigación e Innovación and by ERDF Andalusia Program 2021-2027.

Conflicto de intereses. Los autores declaran no tener intereses en conflicto.

Referencias

1. Cho, Y.J., Wang, J., Joshi, G.: Towards understanding biased client selection in federated learning. In: AISTATS. pp. 10351–10375 (2022)
2. Mamdani, E.H.: Application of fuzzy algorithms for control of simple dynamic plant. Proc. IEE **121**(12), 1585–1588 (1975)
3. McMahan, B., Moore, E., Ramage, D., Hampson, S., Aguera y Arcas, B.: Communication-efficient learning of deep networks from decentralized data. In: AISTATS. pp. 1273–1282 (2017)
4. Montoya-Peña, C., Gaitán Guerrero, J.F., Espinilla, M., López, J.L.: Towards lightweight stress monitoring on biometric data for IoMT environments. Computer Methods and Programs in Biomedicine **279**, 109287 (2026)
5. Orphanidou, C., Bonnici, T., Charlton, P., Clifton, D., Vallance, D., Tarassenko, L.: Signal-quality indices for the ECG and PPG. IEEE J. Biomed. Health Inform. **19**(3), 832–838 (2015)
6. Rivas, J.M., Fernandez-Basso, C., Morcillo-Jimenez, R., Paños-Basterra, J., Ruiz, M.D., Martin-Bautista, M.J.: SimulaFed: an enhanced federated simulated environment for privacy and security in health. Computing **107**(3) (2025)
7. World Health Organization: World mental health report (2022)