RECITES

Revista Ciencia, Tecnología & Sociedad

Web page: https://revistas.unsxx.bo/index.php/RCTSXX

Dirección General de Investigación

Universidad Nacional "Siglo XX"

Research Article

Sistema Mamdani de inferencia difusa para diagnóstico vehicular: Validación computacional en Toyota Corolla 2023

Mamdani Fuzzy inference system for vehicle diagnostics: Computational validation using Toyota Corolla 2023

Juan Carlos Mamani Colque[1]* · Gregorio Mamani Mamani[1]

[1] Universidad Pública de El Alto, Doctorado en Ciencia de Datos, El Alto, Bolivia

* Autor de correspondencia: paztelecomunicaciones@gmail.com

Received: 27 Septembre 2026. Accepted: 20 October 2026. Published: 21 November 2026.

Abstract

Conventional vehicle diagnostic systems, which rely on fixed thresholds, often fail to adequately capture the progressive deterioration of mechanical components. To overcome this limitation, a Mamdani fuzzy inference prototype was developed and computationally evaluated. This prototype was designed to diagnose a 1.8-liter gasoline engine, using the 2023 Toyota Corolla as a reference vehicle. Its primary goal was to characterize system behavior through simulations, rather than to establish diagnostic validity under real-world operating conditions. The system incorporates seven input variables: engine temperature, vibration level, fuel consumption, oil pressure, lubricant temperature, fuel pressure, and engine speed. Each variable is represented by three fuzzy sets, and the knowledge base consists of eight expert-defined rules. The system was implemented in Python using the scikit-fuzzy library, with an interactive interface developed in Google Colab. The evaluation included three operating scenarios (optimal, warning, and critical), univariate sensitivity analysis, 100 repeated executions, and 1,000 randomly generated input combinations. The resulting scores were 16.9, 61.1, and 70.8 out of 100, respectively, which were consistent with the predefined categories. The system demonstrated repeatable outputs and inference times of only a few milliseconds. However, 8.7% of the random input combinations produced no output due to incomplete rule coverage. The findings indicate that this prototype offers an interpretable approach with potential educational and decision-support applications. Nevertheless, operational deployment would require completing the rule base, calibrating input ranges, and validating the model through expert assessment and real-world data.

Keywords: fault diagnosis; expert systems; uncertainty; fuzzy logic; combustion engine.

Resumen

Los sistemas de diagnóstico vehicular tradicionales, que utilizan umbrales fijos, no logran capturar el deterioro gradual de los componentes. Para abordar esta limitación, se desarrolló y evaluó computacionalmente un prototipo de inferencia difusa Mamdani. Este prototipo, diseñado para el diagnóstico de un motor de gasolina de 1.8 litros (tomando como referencia el Toyota Corolla 2023), busca caracterizar su comportamiento mediante simulaciones, sin pretender una validación diagnóstica en condiciones reales.El sistema incorpora siete variables de entrada: temperatura del motor, vibración, consumo de combustible, presión del aceite, temperatura del lubricante, presión del combustible y revoluciones del motor. Cada variable se define con tres conjuntos difusos, y la base de conocimiento consta de ocho reglas establecidas por juicio experto. La implementación se realizó en Python utilizando la librería scikit-fuzzy, con una interfaz interactiva desarrollada en Google Colab. La evaluación incluyó tres escenarios operativos (óptimo, advertencia y crítico), un análisis de sensibilidad univariado, cien ejecuciones repetidas y mil combinaciones aleatorias. Las puntuaciones obtenidas fueron 16.9, 61.1 y 70.8 sobre 100, respectivamente, lo que concuerda con las categorías esperadas. El sistema demostró resultados repetibles y tiempos de inferencia de pocos milisegundos. No obstante, el 8.7 % de las combinaciones aleatorias no arrojó resultados debido a la cobertura incompleta de las reglas. Se concluye que este prototipo es una herramienta interpretable con potencial educativo y de apoyo. Para su aplicación operativa, es necesario completar las reglas, calibrar los rangos y validar el modelo con expertos y datos reales.

Keywords: diagnóstico de fallas; sistemas expertos; incertidumbre; lógica difusa; motores de combustión.

Introducción

El diagnóstico del estado de un motor de combustión interna a menudo se basa en códigos de falla y umbrales fijos que clasifican cada magnitud como normal o anormal (**Isermann, 2005; Celik & Bayir, 2007**). Sin embargo, este esquema binario no describe adecuadamente el deterioro progresivo de los componentes (**Isermann, 2005**). Una lectura puede estar cerca del límite sin haberlo superado, y múltiples lecturas con desviaciones moderadas pueden, en conjunto, indicar una condición de riesgo. Esta limitación se agrava por la incertidumbre de las mediciones y el razonamiento cualitativo de un técnico experimentado, quien podría describir una temperatura como "algo alta" o una vibración como "media" (**Zadeh, 1975**).

La teoría de conjuntos difusos, propuesta por **Zadeh (1965)**, permite representar esta gradualidad mediante grados de pertenencia entre cero y uno. Su aplicación al diagnóstico de motores tiene precedentes: **Celik & Bayir (2007)** desarrollaron un clasificador difuso conectado a un banco de pruebas que diagnosticó diez fallas generales en tiempo real, utilizando reglas basadas en conocimiento teórico, experto y experimental. **Lu et al. (1998)** implementaron un sistema difuso para detectar fugas de vacío utilizando datos de plantas de ensamblaje. Por su parte, **Gharib & Kovács (2024)** analizaron su uso en la operación y el mantenimiento preventivo de motores diésel marinos.

Trabajos recientes combinan la lógica difusa con el aprendizaje automático como: **Wu (2025)** propuso un modelo de diagnóstico de fallas para motores automotrices que integra aprendizaje automático y teoría de control difuso, reportando una exactitud del 98,7 %. **Ochoa Durazno et al. (2025)** desarrollaron un sistema difuso para el diagnóstico de emisiones en motores de inyección multipunto, con errores de diagnóstico que oscilaron entre 0,46 % y 45,1 % según la variable evaluada. **Mahale et al. (2025)** abordaron el diagnóstico de fallas vehiculares con aprendizaje automático híbrido, utilizando parámetros como las revoluciones del motor y la temperatura del refrigerante.

El método de **Mamdani & Assilian (1975)** es una técnica de inferencia difusa que utiliza reglas lingüísticas del tipo "si-entonces". Estas reglas son comprensibles y modificables por técnicos, lo que facilita su aplicación en talleres y entornos educativos (**Ross, 2010**). A pesar de su utilidad, es menos común encontrar herramientas difusas abiertas, interpretables y reproducibles, con una evaluación explícita de la cobertura de su base de reglas, para modelos específicos de vehículos comerciales. Los enfoques que reportan mayor precisión suelen depender de grandes conjuntos de datos y procesos de entrenamiento.

Existen otras líneas de investigación complementarias, como los sistemas difusos de tipo 2 y temporales, que modelan explícitamente la incertidumbre y las condiciones cambiantes. Los modelos neurodifusos y basados en datos, como LSTM o la fusión multimodal, mejoran la detección pero a menudo sacrifican la interpretabilidad. Asimismo, los marcos de selección de características permiten reducir la redundancia antes de la inducción de reglas. Este trabajo se enfoca en la interpretabilidad y la baja complejidad, posicionándose como una capa transparente de pre-cribado o un módulo de explicación, sin buscar competir en precisión diagnóstica con los enfoques basados en datos.

La principal contribución de este trabajo, radica en abordar la falta de herramientas difusas abiertas, interpretables y reproducibles para un modelo de vehículo comercial específico, con una evaluación explícita de la cobertura de su base de reglas, más que en la precisión diagnóstica. La revisión bibliográfica se realizó en Scopus, IEEE Xplore y Google Scholar, utilizando los términos "fuzzy logic engine diagnosis", "Mamdani fault detection" y "automotive diagnostic fuzzy". Se priorizaron las publicaciones entre 1998 y 2025 relacionadas con motores de combustión.

El presente estudio, se centra en el diseño y la evaluación computacional de un prototipo de sistema de inferencia difusa Mamdani, desarrollado en Python, para el diagnóstico de un motor de gasolina de 1.8 litros, tomando como modelo de referencia el Toyota Corolla 2023. El sistema se fundamenta en siete variables de entrada y ocho reglas difusas. Su rendimiento se evalúa en tres escenarios operativos (óptimo, advertencia y crítico), considerando criterios como la sensibilidad, repetibilidad, tiempo de respuesta y cobertura de reglas. Se espera que las puntuaciones generadas reflejen la gravedad progresiva de cada escenario y se alineen con las categorías predefinidas. Es importante destacar que la evaluación se limita al comportamiento computacional del modelo mediante simulación, sin incluir una validación diagnóstica en condiciones reales.

Recites 2026; 4(2): https://doi.org/10.70598/dizh1635vs60h

Materiales y métodos

Diseño de investigación

Se llevó a cabo una investigación aplicada con un enfoque cuantitativo y alcance descriptivo. Esta se centró en el desarrollo tecnológico y la simulación computacional de un sistema de inferencia difusa. El estudio no incluyó mediciones de vehículos en operación; en su lugar, los valores de entrada correspondieron a escenarios construidos por los autores para representar condiciones óptimas, de advertencia y críticas. La estructura del sistema sigue el esquema de Mamdani, tal como lo describe **Ross (2010)**.

Materiales e insumos

El sistema se programó en Python y se ejecutó en Google Colab. Para la inferencia difusa, se empleó la biblioteca scikit-fuzzy (**Warner et al., 2019**); para el cálculo numérico, NumPy; para las gráficas, Matplotlib; y para la interfaz interactiva, ipywidgets. Los resultados de este artículo se reprodujeron con Python 3.12, NumPy 2.4.4 y scikit-fuzzy 0.5.0, esta última siendo la versión instalada por defecto con el gestor pip al realizar la verificación. El código completo se entrega como material suplementario.

Objeto y contexto de aplicación

El objeto de estudio es un motor de gasolina de cuatro cilindros y 1,8 L de la familia ZR de Toyota, tomando como referencia el Corolla 2023 equipado con el motor híbrido 2ZR-FXE de ciclo Atkinson (**Matsuo et al., 2016**), cuyo consumo homologado es de 3,9 L/100 km según la norma ADR 81/02 (Australian Government, 2023). Los rangos de consumo utilizados en el prototipo (7–10 L/100 km) son valores genéricos de motores no híbridos y no representan una calibración específica del 2ZR-FXE. Su ajuste con datos del manual de servicio queda pendiente para futuras investigaciones. El contexto de aplicación comprende talleres de diagnóstico y centros de formación en ingeniería automotriz, donde los datos se introducen manualmente mediante controles deslizantes.

Variables y conjuntos difusos

Se definieron siete variables de entrada y una de salida (**Tabla 1**), cada una con tres conjuntos difusos, mediante funciones trapezoidales en los extremos y triangulares en el centro. Los rangos de referencia, establecidos por los autores, se contrastaron con las especificaciones de servicio disponibles (**Tabla 2**). La salida corresponde a una puntuación de 0 a 100, clasificada en tres categorías: óptima (≤40), advertencia (>40–70) y crítica (>70). La base de ocho reglas constituye un núcleo mínimo interpretable frente a las 2.187 combinaciones posibles (3^7), priorizando la trazabilidad sobre la cobertura exhaustiva; esta limitación dejó un 8,7 % de combinaciones sin salida. Además, la regla R5, basada en el operador O sobre cuatro condiciones, se activa completamente incluso en el escenario crítico, comprimiendo la puntuación alrededor del umbral de 70 y evidenciando la necesidad de revisar su formulación.

El contraste con las especificaciones disponibles mostró concordancia parcial para la presión del aceite, discrepancias en el consumo de combustible y ausencia de valores oficiales localizados para las demás variables (**Tabla 2**). La presión del aceite coincide parcialmente con los datos de servicio del motor 2ZR-FE a 3000 rpm (Toyota Motor Corporation, 2008). Los rangos de consumo (7–10 L/100 km) corresponden a motores no híbridos y no al consumo homologado de la versión híbrida (Australian Government, 2023). Por tanto, los parámetros adoptados son referenciales y requieren calibración específica con datos del fabricante y mediciones del vehículo objetivo. El contexto de aplicación comprende talleres de diagnóstico y centros de formación en ingeniería automotriz, donde un operador introduce manualmente las lecturas mediante controles deslizantes.

Bases de reglas difusas

La base de conocimiento se compone de ocho reglas, estructuradas como condicionales "SI (antecedente) ENTONCES (consecuente)", las cuales fueron establecidas mediante el juicio experto de los autores (**Tabla 3**). Por ejemplo, la regla 1 requiere que las siete variables se encuentren simultáneamente en su conjunto normal, mientras que la regla 5 integra cuatro condiciones mediante el operador lógico"O".

Tabla 1. Variables, universos de discurso y conjuntos difusos del sistema

Variable	Unidad	Universo	Conjuntos (trap = trapezoidal; tri = triangular)
Temperatura motor	°C	[50; 120]	baja: trap(50; 50; 65; 75); normal: tri(75; 90; 105); alta: trap(95; 105; 120; 120)
Nivel vibración	escala 0–100	[0; 100]	baja: trap(0; 0; 20; 40); media: tri(30; 50; 70); alta: trap(60; 80; 100; 100)
Consumo combustible	L/100 km	[5; 15]	bajo: trap(5; 5; 6,5; 7,5); normal: tri(7; 8,5; 10); alto: trap(9; 11; 15; 15)
Presión aceite	psi	[10; 80]	baja: trap(10; 10; 20; 30); normal: tri(25; 45; 65); alta: trap(60; 70; 80; 80)
Temperatura lubricante	°C	[50; 120]	baja: trap(50; 50; 65; 75); normal: tri(70; 85; 100); alta: trap(95; 105; 120; 120)
Presión combustible	psi	[30; 70]	baja: trap(30; 30; 35; 45); normal: tri(40; 50; 60); alta: trap(55; 65; 70; 70)
Revoluciones motor	rpm	[500; 6500]	bajas: trap(500; 500; 1000; 2000); medias: tri(1500; 3000; 4500); altas: trap(4000; 5000; 6500; 6500)
Diagnóstico (salida)	puntuación	[0; 100]	óptimo: trap(0; 0; 20; 40); advertencia: tri(30; 50; 70); crítico: trap(60; 80; 100; 100)

Tabla 2. Contraste de los rangos de referencia del modelo con datos de servicio publicados

Variable	Rango normal del modelo*	Dato publicado localizado	Concordancia
Presión aceite	25–65 psi (máximo en 45 psi)	Motor 2ZR-FE: en ralentí, 3,7 psi o más; a 3000 rpm, 21,8–58,0 psi (Toyota Motor Corporation, 2008)	Parcial: el límite superior del modelo excede el publicado
Consumo combustible	7–10 L/100 km (máximo en 8,5)	Corolla 1,8 L 2023, motor 2ZR-FXE: 3,9 L/100 km combinado (Australian Government, 2023)	No concuerda: requiere aclarar la versión y recalibrar
Temperatura motor	75–105 °C (máximo en 90)	No se localizó especificación oficial	Sin dato
Temperatura lubricante	70–100 °C (máximo en 85)	No se localizó especificación oficial	Sin dato
Presión combustible	40–60 psi (máximo en 50)	No se localizó especificación oficial	Sin dato
Revoluciones motor	Medias: 1500–4500 rpm	No se localizó especificación oficial	Sin dato
Nivel vibración	Escala de 0 a 100	Escala definida por los autores	No aplica

*Los rangos del modelo son criterios operativos definidos por los autores y deben calibrarse con el manual de servicio del vehículo objetivo.

Tabla 3. Base de reglas difusas del sistema

N.º	Antecedente	Operador	Consecuente
R1	temperatura del motor normal, vibración baja, consumo normal, presión del aceite normal, temperatura del lubricante normal, presión del combustible normal y revoluciones medias	Y	óptimo
R2	temperatura del motor alta y presión del aceite baja	Y	crítico
R3	vibración alta y revoluciones altas	Y	crítico
R4	consumo alto y temperatura del motor alta	Y	crítico
R5	temperatura del motor alta, o vibración media, o consumo alto, o presión del aceite baja	O	advertencia
R6	presión del combustible baja y consumo alto	Y	advertencia
R7	temperatura del motor baja y consumo alto	Y	advertencia
R8	revoluciones altas y vibración media	Y	advertencia

Proceso de inferencia

Se aplicó el método de Mamdani en cuatro etapas. Primero, la fusificación convierte cada lectura nítida en grados de pertenencia a los conjuntos de su variable. Segundo, el grado de activación α de cada regla se obtiene con el mínimo para la conjunción y el máximo para la disyunción (ecuaciones 1a y 1b). Tercero, el consecuente de cada regla se recorta al nivel α y las salidas se agregan con el máximo (ecuación 2). Cuarto, la desfusificación mediante el centroide entrega la puntuación nítida (ecuación 3).

Recites 2026; 4(2): https://doi.org/10.70598/revcts.7k291m

$$\alpha_i = \min_{k \in K_i} \ \mu_{A_{ik}}(x_k) \quad (1a)$$

$$\alpha_i = \max_{k \in K_i} \ \mu_{A_{ik}}(x_k) \quad (1b)$$

$$\mu_{agr}(z) = \max_{i=1,\ldots,8} [\ \min(\alpha_i, \mu_{C_i}(z))\ ] \quad (2)$$

$$z^* = \frac{\Sigma_j \, z_j \cdot \mu_{agr}(z_j)}{\Sigma_j \, \mu_{agr}(z_j)} \quad (3)$$

donde αi es el grado de activación de la regla i; Ki, el conjunto de variables que intervienen en su antecedente; μAik, la función de pertenencia del conjunto antecedente de la variable k en la regla i; xk, la lectura nítida de la variable k; Ci, el conjunto de salida de la regla i; z, la variable de salida (0–100); zj, los puntos discretizados de su universo, con zj ⊚ [0, 100]; y z⊚, la puntuación nítida de diagnóstico. Cuando ninguna regla se activa, μagr(z) = 0 para todo z y el centroide no está definido.

Procedimiento

El procedimiento siguió nueve pasos secuenciales: (1) seleccionar las siete variables; (2) fijar universos y conjuntos difusos; (3) formular las ocho reglas; (4) implementar el sistema de inferencia en Python; (5) construir la interfaz con controles deslizantes; (6) definir a priori tres escenarios de entrada, con la categoría esperada para cada uno; (7) ejecutar los escenarios y registrar la puntuación y las reglas activadas; (8) ejecutar los análisis de sensibilidad, repetibilidad, tiempo y cobertura; y (9) contrastar los resultados con la hipótesis (Figura 1).

Criterios de evaluación, validez y confiabilidad

La validez de los resultados se evaluó comparando la categoría obtenida con la esperada en cada escenario. La sensibilidad se analizó mediante un barrido univariado: cada variable recorrió 71 puntos equiespaciados de su rango, mientras las demás se mantuvieron en los valores del escenario óptimo. Se registraron el mínimo, el máximo y la amplitud de los resultados, así como la cobertura, definida como el porcentaje de puntos con un resultado definido. La repetibilidad y el tiempo de inferencia se midieron con 100 ejecuciones consecutivas del escenario de advertencia, incluyendo la creación de la simulación en cada ejecución. La cobertura global se estimó con 1000 combinaciones de entradas muestreadas de forma uniforme y aleatoria dentro de los rangos (semilla 42).

No se realizó una evaluación por expertos ni se contrastó el sistema con casos reales de falla; ambas etapas se proponen como trabajo futuro (véase la Discusión). Por lo tanto, la validez se limita a la coherencia con las categorías previstas por los autores y al contraste parcial de los rangos con datos publicados. Los escenarios sintéticos no demuestran precisión diagnóstica frente a fallas reales. Como trabajo futuro se propone: (i) someter las ocho reglas a un panel de tres a cinco expertos en ingeniería automotriz y calcular el coeficiente V de Aiken para la validez de contenido; (ii) contrastar el sistema con un conjunto de casos de falla documentados o datos OBD-II etiquetados; y (iii) reportar la sensibilidad, especificidad y AUROC frente a una línea base de umbrales fijos.

Resultados

Implementación del sistema

Las siete variables de entrada del motor se clasifican mediante funciones de pertenencia en conjuntos difusos (bajo, normal y alto, según corresponda, Figura 2). Las funciones triangulares y trapezoidales, con grados de pertenencia entre 0 y 1, permiten representar transiciones graduales y solapamientos entre estados operativos. La variable de salida (h), con una puntuación de 0 a 100, establece tres categorías de diagnóstico: óptimo, advertencia y crítico. Estas funciones sustentan el sistema de inferencia difusa, aunque sus umbrales deben validarse con datos experimentales y especificaciones del fabricante.

Salida del sistema en los tres escenarios

El sistema asignó 16,9 puntos al escenario óptimo, 61,1 al de advertencia y 70,8 al crítico (Tabla 4, Figura 3). Las tres salidas se ordenaron y se mantuvieron dentro de la categoría prevista, con el escenario crítico superando el umbral de 70 puntos por solo 0,8 puntos. En el escenario óptimo, se activó únicamente la regla 1 (grado 0,67). En el de advertencia, se activó la regla 5 (grado 1,00) junto con las reglas 4 y 6 (grado 0,30). Finalmente, en el escenario crítico, las reglas 2 a 6 se activaron con un grado de 1,00.

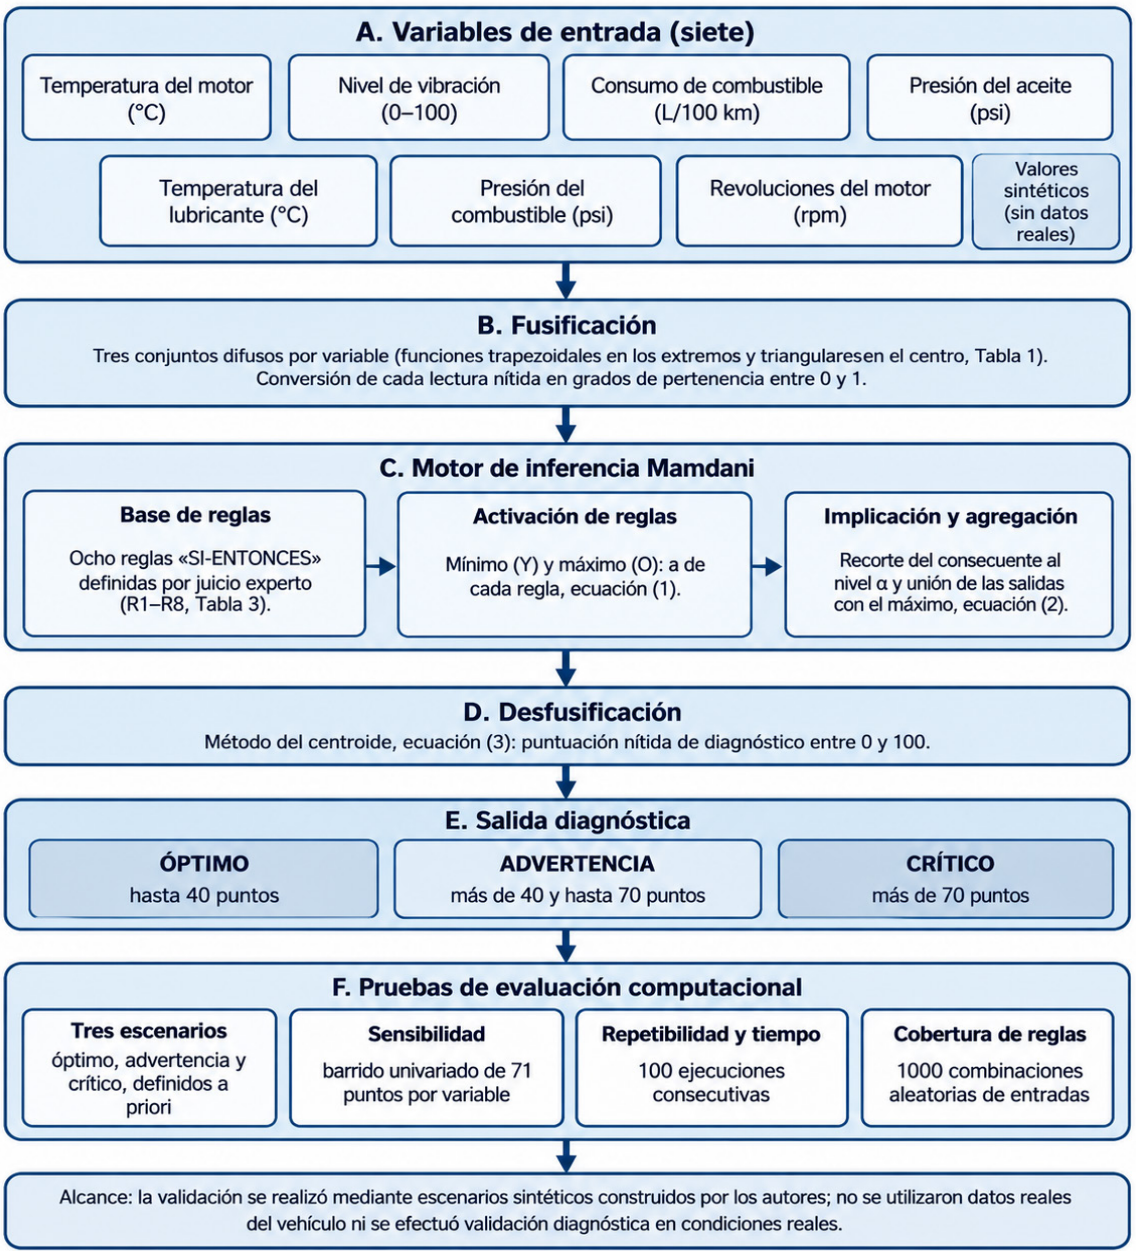

Figura 1. Arquitectura metodológica del sistema de diagnóstico difuso tipo Mamdani: El flujo parte de siete variables de entrada (A), que se fusifican con tres conjuntos difusos por variable (B), se procesan con ocho reglas SI–ENTONCES mediante activación, implicación y agregación (C), se desfusifican con el método del centroide (D) y se clasifican como óptimo, advertencia o crítico (E). La evaluación computacional (F) comprende tres escenarios, un barrido de sensibilidad, repetibilidad y cobertura de reglas.

Salida del sistema en los tres escenarios

El sistema asignó 16,9 puntos al escenario óptimo, 61,1 al de advertencia y 70,8 al crítico (Tabla 4, Figura 3). Las tres salidas se ordenaron y se mantuvieron dentro de la categoría prevista, con el escenario crítico superando el umbral de 70 puntos por solo 0,8 puntos. En el escenario óptimo, se activó únicamente la regla 1 (grado 0,67). En el de advertencia, se activó la regla 5 (grado 1,00) junto con las reglas 4 y 6 (grado 0,30). Finalmente, en el escenario crítico, las reglas 2 a 6 se activaron con un grado de 1,00.

Sensibilidad del sistema

En el barrido univariado, la temperatura del motor, la vibración, el consumo y la presión del aceite modificaron la salida en 33,1 puntos, entre 16,9 y 50,0. La temperatura del lubricante, la presión del combustible y las revoluciones del motor produjeron amplitudes de 2,8, 3,0 y 3,4 puntos, respectivamente (Tabla 5, Figura 4). Ninguna variable aislada llevó la salida por encima de 50 puntos. La cobertura por variable varió entre 40,8 % y 80,3 %, de modo que en una parte de los puntos del barrido ninguna regla produjo salida.

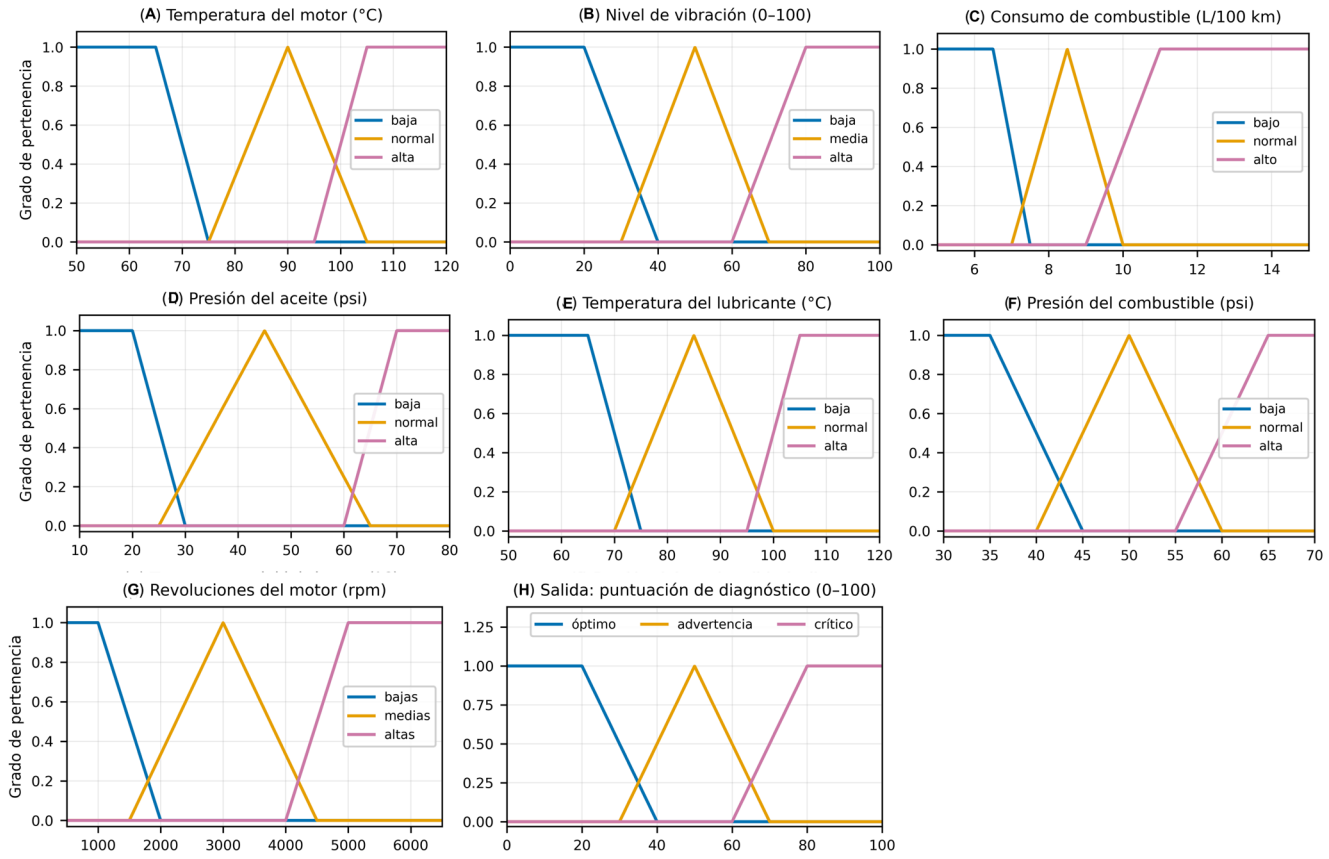

Figura 2. Funciones de pertenencia de las siete variables de entrada y de la variable de salida del sistema Mamdani: (A) temperatura del motor (°C), (B) nivel de vibración (0–100), (C) consumo de combustible (L/100 km), (d) presión del aceite (psi), (e) temperatura del lubricante (°C), (f) presión del combustible (psi), (g) revoluciones del motor (rpm) y (h) puntuación de diagnóstico (0–100). Cada variable tiene tres conjuntos difusos (trapezoidales en los extremos y triangulares en el centro); el eje vertical indica el grado de pertenencia (0–1).

Tabla 1. Variables, universos de discurso y conjuntos difusos del sistema

Variable	Óptimo	Advertencia	Crítico
Temperatura del motor (°C)	88	98	110
Nivel de vibración (0–100)	25	55	80
Consumo de combustible (L/100 km)	8,2	11,5	13,5
Presión del aceite (psi)	45	35	20
Temperatura del lubricante (°C)	85	95	105
Presión del combustible (psi)	48	42	35
Revoluciones del motor (rpm)	2500	3500	5500
Reglas activadas (grado)	R1 (0,67)	R4 (0,30); R5 (1,00); R6 (0,30)	R2 a R6 (1,00)
Puntuación de diagnóstico	16,9	61,1	70,8
Categoría obtenida*	Óptimo	Advertencia	Crítico

*Categorías de la puntuación de diagnóstico: óptimo ≤ 40; advertencia > 40 y ≤ 70; crítico > 70.

Repetibilidad, tiempo de inferencia y cobertura global

En 100 ejecuciones consecutivas del escenario de advertencia, la desviación estándar de la salida fue prácticamente nula (del orden de 10^{-13} puntos) y la categoría no cambió, lo que indica un comportamiento determinista. El tiempo medio por diagnóstico fue de entre 3 y 7 milisegundos según la ejecución y el equipo, en el entorno utilizado para la verificación. De las 1000 combinaciones aleatorias de entradas, 87 (8,7 %) no produjeron salida definida porque ninguna regla se activó.

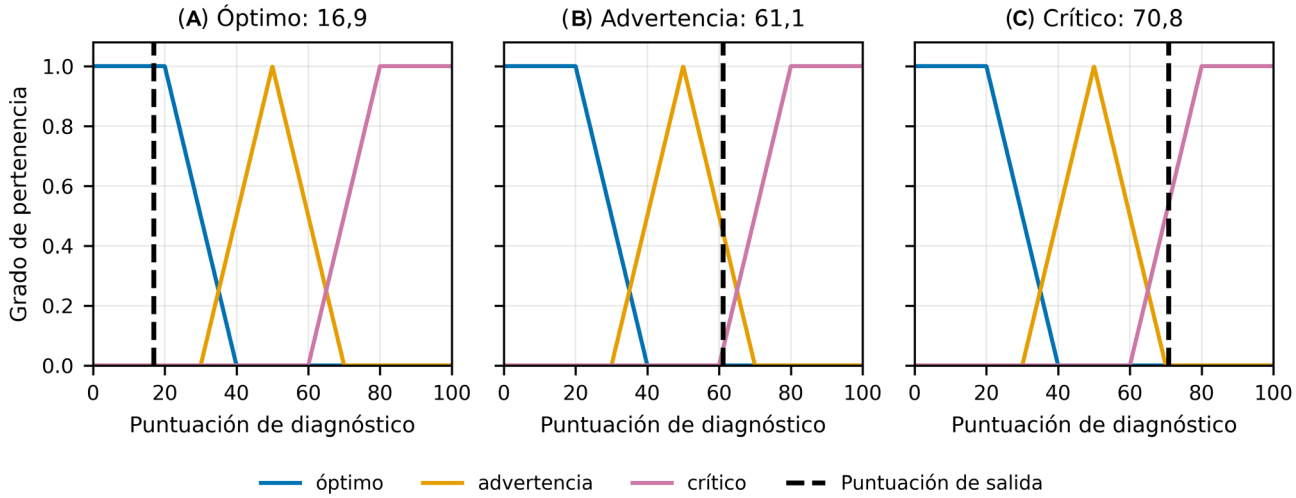

Figura 3. Posición de la puntuación de salida (línea discontinua) sobre los tres conjuntos difusos de la variable de diagnóstico (óptimo, advertencia y crítico) en tres escenarios sintéticos: (A) escenario óptimo, salida de 16,9; (B) escenario de advertencia, 61,1; (C) escenario crítico, 70,8. El eje horizontal es la puntuación de diagnóstico (0–100) y el vertical, el grado de pertenencia (0–1). Cada puntuación cae en el rango de la categoría prevista.

Tabla 5. Resultados del barrido univariado de sensibilidad (71 puntos por variable; las demás variables se mantuvieron en los valores del escenario óptimo).

Variable	Mínimo	Máximo	Amplitud (puntos)	Cobertura (%)*
Temperatura motor	16,9	50,0	33,1	63,4
Nivel vibración	16,9	50,0	33,1	69,0
Consumo combustible	16,9	50,0	33,1	80,3
Presión aceite	16,9	50,0	33,1	77,5
Temperatura lubricante	16,9	19,7	2,8	40,8
Presión combustible	16,9	19,9	3,0	49,3
Revoluciones del motor	16,5	19,9	3,4	49,3

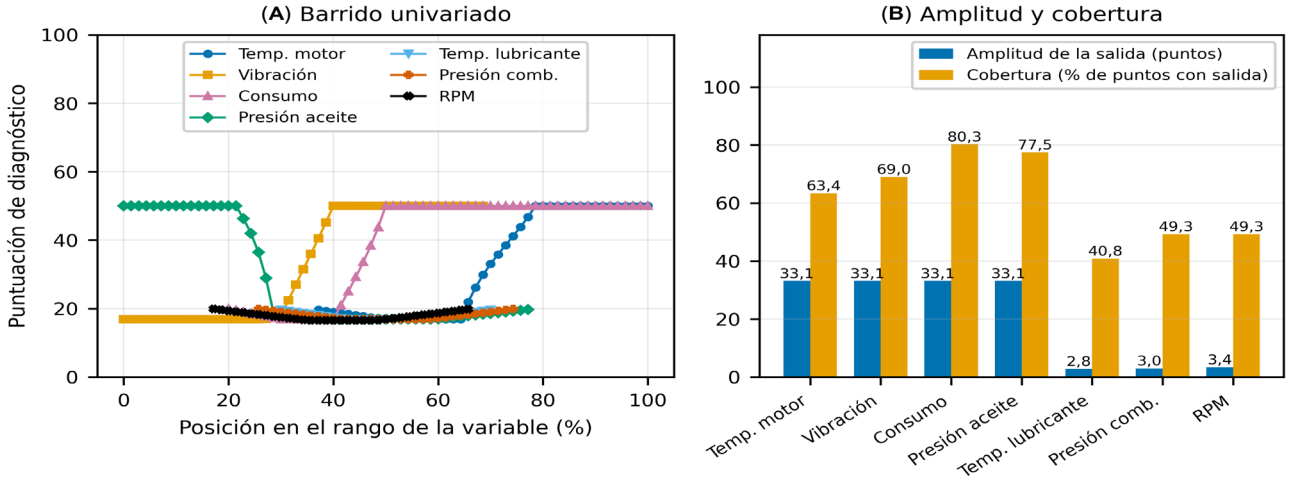

Figura 4. Sensibilidad univariada del sistema (71 puntos por variable, con las demás variables en el escenario óptimo): (a) puntuación de diagnóstico según la posición de cada variable dentro de su rango; los tramos sin línea corresponden a puntos sin salida definida; (b) amplitud de la salida (puntos) y cobertura de reglas (% de puntos con salida definida) por variable.

Repetibilidad, tiempo de inferencia y cobertura global

En 100 ejecuciones consecutivas del escenario de advertencia, la desviación estándar de la salida fue prácticamente nula (del orden de 10^{-13} puntos) y la categoría no cambió, lo que indica un comportamiento determinista. El tiempo medio por diagnóstico fue de entre 3 y 7 milisegundos según la ejecución y el equipo, en el entorno utilizado para la verificación. De las 1000 combinaciones aleatorias de entradas, 87 (8,7 %) no produjeron salida definida porque ninguna regla se activó.

Discusión

El orden de las puntuaciones respalda la hipótesis, pero la distancia entre los escenarios no es proporcional a la gravedad de las condiciones. La puntuación del escenario crítico fue inferior a lo que sugiere un deterioro generalizado, ya que las reglas de consecuente crítico (R2, R3 y R4) y las de consecuente de advertencia (R5 y R6) se activaron simultáneamente con un grado de 1,00. El máximo de la agregación provoca que ambas áreas se superpongan y el centroide se sitúe en una posición intermedia, cerca del umbral de 70 puntos. Esta compresión explica que el margen sobre el umbral sea de solo 0,8 puntos y sugiere que la regla 5, formulada con el operador O sobre cuatro condiciones, activa la advertencia incluso cuando ya existe evidencia clara de una condición crítica.

Una alternativa a evaluar es fragmentar R5 en reglas independientes por condición (temperatura alta-advertencia; vibración media-advertencia; consumo alto-advertencia; presión de aceite baja ⊙ advertencia) y asignar pesos a los consecuentes, de modo que la evidencia crítica (R2–R4) prevalezca sobre la advertencia cuando ambas se activen simultáneamente. Otra opción es el uso de consecuentes TSK o sistemas implicativos, que manejan mejor la evidencia aditiva y evitan la compresión del centroide cerca de los límites entre categorías. La ausencia de salidas por encima de 50 puntos en el barrido univariado es consecuencia de la estructura de las reglas: las tres reglas de consecuente crítico exigen dos condiciones simultáneas, de modo que el deterioro de un solo sensor solo puede escalar hasta advertencia. Este diseño evita alarmas críticas por una lectura aislada, pero también implica que una falla grave manifestada en una única variable no se clasificaría como crítica. Esta decisión debe contrastarse con técnicos expertos y con registros reales de fallas.

La baja influencia de la temperatura del lubricante, la presión del combustible y las revoluciones del motor (amplitudes menores de 3,5 puntos) también responde al diseño de la base de reglas y no necesariamente a su importancia física. La temperatura del lubricante solo interviene en la regla 1, la presión del combustible aparece en la regla 1 y en la regla 6, y las revoluciones solo participan en combinación con la vibración. Una base de reglas con mayor respaldo empírico, como la de **Celik & Bayir (2007)**, que combinó conocimiento teórico, experto y resultados de ensayos con fallas inducidas, permitiría ajustar la contribución real de cada variable.

El análisis de sensibilidad realizado es univariado y, por tanto, no captura interacciones entre variables. Un análisis de sensibilidad global (por ejemplo, índices de Sobol o mapas de calor de cobertura por pares) permitiría identificar regiones críticas y guiar la expansión de la base de reglas. Asimismo, no se evaluó la robustez frente al ruido de los sensores y la deriva de calibración; se plantea como trabajo futuro perturbar los puntos de quiebre de las funciones de pertenencia y medir la estabilidad de la salida. La inferencia estática por captura puntual ignora la dinámica temporal, la histéresis y la tasa de cambio, elementos centrales en el diagnóstico de motores. Incorporar promedios móviles, tasas de cambio o un marco difuso temporal (por ejemplo, tipo-2 temporal) permitiría capturar condiciones en evolución y reducir falsas alarmas por lecturas transitorias.

El hallazgo de que el 8,7 % de las combinaciones aleatorias no produce salida indica que la base de ocho reglas no es completa. Los huecos se concentran en las zonas de transición entre los conjuntos "normal" y "alto", donde ninguna regla alcanza un grado positivo. En una herramienta de taller, este comportamiento es crítico, porque el sistema devolvería un error en lugar de un diagnóstico. Para mitigar esta limitación se proponen tres estrategias complementarias: (i) una regla por defecto que asigne una categoría de advertencia cuando ninguna regla se active, evitando el error silencioso; (ii) la inducción de reglas a partir de mapas de cobertura por pares de variables; y (iii) la expansión controlada de la base con reglas para las transiciones "normal–alto". La relación entre eliminar regiones no cubiertas e incrementar falsos positivos deberá cuantificarse en trabajos futuros con datos etiquetados. La regla por defecto no se implementó en esta versión y se deja como trabajo futuro prioritario.

Los rangos de referencia son otra fuente de incertidumbre. La presión del aceite fue la única variable que pudo contrastarse con una especificación de servicio del motor 2ZR-FE; su límite superior en el modelo (65 psi) excede el valor publicado (58,0 psi). El rango de consumo (7 a 10 L/100 km) no coincide con el consumo homologado de 3,9 L/100 km para la versión de 1,8 litros del Corolla 2023, que utiliza el motor híbrido 2ZR-FXE (Australian Government, 2023). Este rango solo sería válido para una versión de gasolina no híbrida o si representa condiciones reales de uso, y necesita ser aclarado y calibrado con mediciones. Para las demás variables, no se encontró una especificación oficial, por lo que sus conjuntos difusos se basan en criterios de los autores y deben calibrarse con el manual de servicio del vehículo objetivo. La Tabla 2 muestra la discrepancia entre los rangos del modelo y los datos publicados, lo que llevó a reformular el alcance del trabajo: el caso Corolla 2023 se toma como referencia de la familia ZR, no como una calibración exacta de la versión híbrida.

A diferencia de los enfoques basados en datos, el sistema presentado no se entrenó ni evaluó con casos etiquetados. Por lo tanto, no es posible estimar una exactitud comparable a la reportada por **Wu (2025)**, cuyo modelo integra aprendizaje automático y control difuso, ni por Mahale et al. (2025), que trabajan con parámetros del motor registrados. Sin embargo, el sistema mantiene reglas legibles y modificables por un técnico. Los errores reportados por **Ochoa Durazno et al. (2025)**, que varían del 0,46 % al 45,1 % según la variable, demuestran que el rendimiento de un sistema difuso depende del modelado de cada magnitud, lo que subraya la necesidad de contrastar empíricamente cada conjunto y cada regla. Por otro lado, **Prommachan et al. (2024)** compararon su modelo difuso de mantenimiento predictivo con la norma ISO 10816-3; el presente estudio carece de una referencia normativa equivalente, y su incorporación debería considerarse en el diseño de futuras versiones.

A diferencia del modelo de **Prommachan et al. (2024)**, que se enfoca en el mantenimiento predictivo, este prototipo clasifica la severidad actual y no predice fallas futuras. Coincidentemente con **Gharib y Kovács (2024)**, los resultados sugieren que la lógica difusa es una vía adecuada para representar el razonamiento del mantenimiento preventivo, siempre que la base de conocimiento sea validada. No se realizó una comparación cuantitativa con una línea base de umbrales fijos ni con otros modelos difusos (TSK, tipo-2) debido a la falta de datos etiquetados. Como trabajo futuro, se propone construir un conjunto de casos sintéticos curados con fallas etiquetadas y reportar la sensibilidad, especificidad y AUROC frente a: (i) umbrales del fabricante; (ii) lógica DTC; y (iii) un clasificador difuso TSK.

Para una futura aplicación práctica segura, se requiere: (i) completar la cobertura de la base de reglas; (ii) calibrar los rangos con el manual de servicio del vehículo objetivo; (iii) validar con expertos y datos reales; (iv) implementar una regla por defecto y mecanismos de alerta ante la ausencia de salida; y (v) documentar mapas de cobertura por pares de variables como parte del procedimiento de diseño. La transición del prototipo didáctico al despliegue operacional exige, por tanto, garantías integrales de cobertura y seguridad.

Las principales limitaciones del estudio radican en el uso de escenarios sintéticos, restringidos a tres casos, sin datos reales del vehículo ni lecturas del sistema de diagnóstico a bordo (OBD-II). Los rangos y las reglas se definieron según el criterio de los autores y se contrastaron parcialmente con datos publicados, sin evaluación por expertos ni validación con fallas reales. Además, el sistema demanda el ingreso manual de datos, no considera su evolución temporal y presenta una cobertura incompleta del espacio de entrada, con un 8,7 % de combinaciones sin salida y sin una regla por defecto. La regla R5 comprime el centroide cerca del umbral crítico, mientras que el análisis de sensibilidad univariado no contempla las interacciones entre variables ni la robustez ante el ruido. Finalmente, no se realizó una comparación cuantitativa con sistemas basados en umbrales fijos o modelos difusos alternativos.

Como líneas futuras de investigación, se propone calibrar los rangos con documentación del fabricante, completar y verificar la cobertura de la base de reglas, revisar la regla R5 mediante su fragmentación o ponderación, y explorar consecuentes Takagi-Sugeno-Kang (TSK). Se recomienda también incorporar una regla por defecto, realizar análisis de sensibilidad global mediante índices de Sobol y mapas de calor por pares, y evaluar la robustez frente al ruido de los sensores y la deriva de calibración. Asimismo, se plantea integrar características temporales y datos reales mediante OBD-II y códigos de diagnóstico de fallas (DTC), comparar el desempeño con umbrales fijos y clasificadores TSK utilizando sensibilidad, especificidad y el área bajo la curva ROC (AUROC), y validar las reglas con expertos a través de estadísticos de concordancia y el coeficiente V de Aiken para evaluar su validez de contenido.

Conclusiones

El sistema difuso Mamdani, con siete variables y ocho reglas, clasificó correctamente tres escenarios operativos. Los resultados fueron repetibles, con tiempos de respuesta de milisegundos, lo que lo convierte en un prototipo interpretable para apoyo y enseñanza. No obstante, el escenario crítico excedió el umbral por 0,8 puntos. Además, el 8,7 % de las combinaciones aleatorias no generaron salida, y la regla R5 comprimió el centroide cerca del umbral crítico. Estos resultados no permiten asegurar la precisión diagnóstica del sistema ante fallas reales; solo demuestran coherencia computacional en escenarios sintéticos. Para su uso operativo, es necesario completar las reglas, implementar una regla por defecto, calibrar los rangos con el manual de servicio, fragmentar o ponderar R5, y validar el sistema con datos reales y evaluación experta (V de Aiken).

Declaración ética

El estudio se realizó mediante simulación computacional, sin participación de seres humanos ni animales; por tanto, no requirió aprobación de un comité de ética.

Declaración de conflictos de interés

Los autores declaran no tener conflictos de interés financieros, personales o profesionales que pudieran influir en el desarrollo del estudio o en la interpretación de sus resultados.

Contribución de los autores

J.C.M.C., conceptualización, metodología, desarrollo del software, análisis formal, investigación, visualización, redacción del borrador original y administración del proyecto. G.M.M. conceptualización, validación, investigación, curación de datos, revisión y edición del manuscrito, y supervisión. Ambos autores revisaron y aprobaron la versión final del manuscrito y asumen la responsabilidad por su contenido.

Agradecimientos

No aplica.

Material suplementario

El código Python, el script de reproducción y la captura de la interfaz se encuentran disponibles en Github: https://github.com/juanquiBO/Prototipo_de_sistema_de_inferencia_difusa_Mamdani_para_diagn-stico_vehicular.git (Mamani Colque & Mamani Mamani, 2026).

Referencias

Australian Government. (2023). Green Vehicle Guide: ficha del Toyota Corolla 1,8 L híbrido [Base de datos oficial]. https://toyotamanuals.com.au/document/landing_page/corolla-hybrid-owners-manual-sept-22-current (fecha de acceso: [31/10/2026]).

Celik, M. B., & Bayir, R. (2007). Fault detection in internal combustion engines using fuzzy logic. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 221(5), 579–587. https://doi.org/10.1243/09544070JAUTO366

Gharib, H., & Kovács, G. (2024). Implementation and possibilities of fuzzy logic for optimal operation and maintenance of marine diesel engines. Machines, 12(6), Article 425. https://doi.org/10.3390/machines12060425

Isermann, R. (2005). Model-based fault-detection and diagnosis – status and applications. Annual Reviews in Control, 29(1), 71–85. https://doi.org/10.1016/j.arcontrol.2004.12.002

Lu, Y., Chen, T., & Hamilton, B. (1998). A fuzzy system for automotive fault diagnosis (SAE Technical Paper 981074). SAE International. https://doi.org/10.4271/981074

Mahale, Y., Kolhar, S., & More, A. S. (2025). Automated vehicle fault diagnosis and report generation using hybrid machine learning with multi-step RAG approach. Discover Computing, 28, Article 283. https://doi.org/10.1007/s10791-025-09823-8

Mamdani, E. H., & Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. International Journal of Man-Machine Studies, 7(1), 1–13. https://doi.org/10.1016/S0020-7373(75)80002-2

Matsuo, S., Ikeda, E., Ito, Y., & Nishiura, H. (2016). The new Toyota inline 4 cylinder 1.8L ESTEC 2ZR-FXE gasoline engine for hybrid car (SAE Technical Paper 2016-01-0684). SAE International. https://doi.org/10.4271/2016-01-0684

Ochoa Durazno, N. A., Bermeo Naula, A. K., & Rivera-Campoverde, N. D. (2025). Development of a fuzzy system for emission diagnosis in MPFI engine systems. In C. Kahraman et al. (Eds.), Intelligent and fuzzy systems: INFUS 2025 (Lecture Notes in Networks and Systems, Vol. 1529, pp. 205–211). Springer. https://doi.org/10.1007/978-3-031-97992-7_24

Prommachan, W., Surin, P., Srinoi, P., & Pipathattakul, M. (2024). A fuzzy logic modelling of predictive maintenance in rotating machinery. Archives of Materials Science and Engineering, 126(1), 15–22. https://doi.org/10.5604/01.3001.0054.6779

Ross, T. J. (2010). Fuzzy logic with engineering applications (3rd ed.). Wiley. https://doi.org/10.1002/9781119994374

Toyota Motor Corporation. (2008). Scion xD repair manual: Engine 2ZR-FE – Lubrication system, oil pressure check [Manual de reparación]. Toyota Technical Information System. https://techinfo.toyota.com (fecha de acceso: [31/10/2026]).

Warner, J., Sexauer, J., & scikit-fuzzy contributors. (2019). scikit-fuzzy [Computer software]. Zenodo. https://doi.org/10.5281/zenodo.802396

Wu, W. (2025). Automotive motor fault diagnosis model integrating machine learning algorithm and fuzzy control theory. International Journal of Fuzzy Systems, 27, 2721–2734. https://doi.org/10.1007/s40815-024-01926-6

Zadeh, L. A. (1965). Fuzzy sets. Information and Control, 8(3), 338–353. https://doi.org/10.1016/S0019-9958(65)90241-X

Zadeh, L. A. (1975). The concept of a linguistic variable and its application to approximate reasoning – I. Information Sciences, 8(3), 199–249. https://doi.org/10.1016/0020-0255(75)90036-5