

Predicción de Defectos de Vacío en Soldadura por Fricción-Agitación mediante Algoritmos de Aprendizaje Automático

Void Defect Prediction in Friction Stir Welding using Machine Learning Algorithms

Yuniel Martínez¹, Luis Rojas¹, Sofia Tapia^{2,*}, Gustavo Aguilera^{2,*}, Vanesa Bazan³

(1) Doctorado en Industria Inteligente, Facultad de Ingeniería, Pontificia Universidad Católica de Valparaíso, Valparaíso 2362804, Chile

(2) Universidad de La Serena, Facultad de Ingeniería, Departamento de Ingeniería Mecánica. La Serena 1720169, Chile

(3) CONICET-IIM, Facultad de Ingeniería, Universidad Nacional de San Juan, San Juan, Argentina

*autor de correspondencia (gustavo.aguilera@userena.cl, sofia.tapiaa@userena.cl)

Recibido 13/05/2025

Evaluated

17/07/2025

Aceptado

25/08/2025

<https://doi.org/10.65093/aci.v16.n3.2025.36>

RESUMEN

Este estudio propone un marco predictivo avanzado basado en arquitecturas de aprendizaje automático híbrido para modelar la relación no lineal entre los parámetros termomecánicos y la probabilidad de fallo. Mediante el análisis riguroso de datos experimentales heterogéneos, se evaluaron y optimizaron modelos de ensamble de última generación, incluyendo *Stacking*, *Weighted Voting* y un *Super-Ensemble*. Los resultados validan la superioridad de las arquitecturas híbridas, alcanzando una precisión de clasificación de 86.4% y un Área Bajo la Curva ROC (AUC) de 0.93, superando a los estimadores base convencionales. El análisis de importancia de características mediante disminución de impureza de Gini corroboró la fenomenología física del proceso, identificando la velocidad de rotación y de avance como los factores gobernantes del flujo plástico (71% de varianza explicada). Este trabajo no solo demuestra la viabilidad de la detección de defectos *in-silico*, sino que establece las bases algorítmicas para el desarrollo de Gemelos Digitales y sistemas de control adaptativo en el contexto de la Industria 4.0.

Palabras clave: soldadura por fricción-agitación (FSW), defectos volumétricos, aprendizaje de ensamble híbrido, modelado termomecánico

ABSTRACT

This study proposes an advanced predictive framework based on hybrid machine learning architectures to model the non-linear relationship between thermomechanical parameters and failure probability. Through rigorous analysis of heterogeneous experimental data, state-of-the-art ensemble models were evaluated and optimized, including *Stacking*, *Weighted Voting*, and a *Super-Ensemble*. Results validate the superiority of hybrid architectures, achieving a classification accuracy of 86.4% and an Area Under the ROC Curve (AUC) of 0.93, outperforming conventional base estimators. Feature importance analysis via Mean Decrease in Impurity corroborated the physical phenomenology of the process, identifying rotational and welding speeds as the governing factors of plastic flow (71% of explained variance). This work not only demonstrates the feasibility of *in-silico* defect detection but also establishes the algorithmic foundations for the development of Digital Twins and adaptive control systems within the Industry 4.0 context.

Keywords: friction stir welding (FSW), volumetric defects, hybrid ensemble learning, thermomechanical modeling

INTRODUCCIÓN

La soldadura por fricción-agitación (FSW) representa un cambio de paradigma en la tecnología de unión de estado sólido, consolidándose como un estándar de fabricación en industrias de alta exigencia como la aeroespacial, automotriz y naval (Mishra & Ma, 2005; Thomas *et al.*, 1991). Al operar por debajo del punto de fusión del material base, este proceso mitiga los defectos de solidificación inherentes a la soldadura por arco, permitiendo la unión de aleaciones de aluminio de alta resistencia (series 2xxx y 7xxx) que tradicionalmente se consideraban no soldables. Sin embargo, la estabilidad termomecánica del proceso depende de un equilibrio delicado entre la generación de calor friccional y el flujo plástico del material alrededor de la herramienta. La ruptura de este equilibrio, debida a una selección subóptima de parámetros, conduce inevitablemente a la formación de discontinuidades volumétricas, específicamente defectos de vacío o "túneles" (*wormholes*). Estas singularidades actúan como concentradores de tensión severos, degradando drásticamente la resistencia a la fatiga y comprometiendo la integridad estructural del componente (Du *et al.*, 2019; Shi & Wu, 2023).

Históricamente, la determinación de la ventana operativa óptima se ha abordado mediante enfoques empíricos deterministas. El Diseño de Experimentos (DoE), y en particular la metodología Taguchi, ha sido la herramienta estándar para explorar el espacio de parámetros (Rajakumar *et al.*, 2011; Jayashree *et al.*, 2018). Paralelamente, la modelización numérica basada en Elementos Finitos (FEM) y Dinámica de Fluidos Computacional (CFD) ha permitido elucidar los mecanismos físicos de la deformación plástica severa y la recrystalización dinámica (Nandan *et al.*, 2008; Schmidt *et al.*, 2006). No obstante, estas aproximaciones presentan limitaciones intrínsecas para la Industria 4.0: las campañas experimentales son costosas y carecen de generalización, mientras que las simulaciones de alta fidelidad conllevan un costo computacional prohibitivo que impide su implementación en lazos de control en tiempo real.

En respuesta a estas limitaciones, la convergencia de la metalurgia física y la ciencia de datos ha catalizado el surgimiento de la "Ingeniería Asistida por Inteligencia Artificial". El aprendizaje automático (*Machine Learning*, ML) ofrece un enfoque estocástico robusto para mapear las no linealidades complejas que vinculan las variables de entrada (velocidad de rotación, avance, presión) con la probabilidad de defecto, sin la necesidad de resolver explícitamente las ecuaciones constitutivas del material (Baruah *et al.*, 2023; Chen *et al.*, 2024). Algoritmos de ensamblaje avanzado, como *Random Forest*, *Gradient Boosting* y *XGBoost*, han demostrado una capacidad superior para capturar interacciones de alto orden en espacios de parámetros multidimensionales, superando la precisión de los modelos de regresión convencionales (Avcı *et al.*, 2024; Chuenmee *et al.*, 2025).

El presente trabajo se inserta en esta frontera del conocimiento, proponiendo un marco metodológico riguroso para la predicción *in-silico* de defectos de vacío en FSW. A diferencia de estudios previos limitados a la clasificación simple, esta investigación integra una arquitectura de validación cruzada estratificada con un análisis profundo de interpretabilidad del modelo. Utilizando un conjunto de datos experimental consolidado, el estudio persigue dos objetivos fundamentales: primero, validar la eficacia de arquitecturas de aprendizaje supervisado para detectar anomalías estructurales con alta fiabilidad estadística; y segundo, decodificar la "caja negra" del algoritmo para cuantificar la jerarquía de influencia de los parámetros físicos (e.g., relación de avance/revolución). Los hallazgos derivados no solo enriquecen la comprensión fenomenológica del proceso, sino que establecen los cimientos algorítmicos para el despliegue de Gemelos Digitales (*Digital Twins*) y sistemas de control adaptativo, habilitando una manufactura inteligente, autónoma y resiliente.

BREVE INTRODUCCIÓN AL CONOCIMIENTO

La predicción de la integridad estructural en uniones de estado sólido como la soldadura por fricción-agitación (FSW) ha evolucionado desde modelos fenomenológicos empíricos hacia enfoques estocásticos avanzados. Esta transición responde a la naturaleza altamente no lineal de las interacciones termomecánicas que gobiernan la formación de defectos.

Fundamentos Termomecánicos y Limitaciones Analíticas

El proceso FSW se rige fundamentalmente por la generación de calor y el flujo plástico del material. Analíticamente, la generación de calor Q en la interfaz herramienta-pieza puede aproximarse mediante modelos de fricción de Coulomb, donde la entrada de energía total es función de la velocidad angular ω y la presión axial P (Schmidt *et al.*, 2006):

$$Q \approx \int_{r_p}^{R_s} \int_0^{2\pi} \mu(T) P(r, \theta) \omega r^2 d\theta dr \quad (1)$$

Donde $\mu(T)$ es el coeficiente de fricción dependiente de la temperatura, R_s el radio del hombro y r_p el radio del pin. Sin embargo, la formación de defectos volumétricos (vacíos) ocurre cuando el tensor de deformación ε_{ij} y la temperatura local $T(x, y, z, t)$ no satisfacen la condición de continuidad del material, típicamente descrita por ecuaciones constitutivas viscoplásticas acopladas a las ecuaciones de conservación de Navier-Stokes modificadas para fluidos no newtonianos (Nandan *et al.*, 2008).

La resolución numérica de este sistema mediante Elementos Finitos (FEM) conlleva un costo computacional $O(N^3)$, lo que hace inviable su uso para el control en tiempo real o la exploración exhaustiva del espacio de parámetros $X \subset \mathbb{R}^d$ (Shi & Wu, 2023). En este contexto, la modelización basada en datos emerge como una solución eficiente para aproximar la función de mapeo $f: X \rightarrow Y$ sin resolver explícitamente las ecuaciones diferenciales parciales subyacentes.

Formulación Matemática del Problema de Clasificación

Desde una perspectiva de aprendizaje estadístico, la detección de defectos se modela como un problema de clasificación binaria supervisada. Dado un espacio de características X (velocidad de rotación, avance, presión, etc.) y un espacio de etiquetas $Y = \{0, 1\}$, donde 1 denota la presencia de un defecto de vacío, buscamos una función discriminante $h(x)$ que estime la probabilidad condicional posterior:

$$P(Y = 1|X = x) = \mathbb{E}[Y|X = x] \quad (2)$$

El objetivo es minimizar el riesgo esperado $R(h)$ bajo una función de pérdida L , tal que:

$$h^* = \arg \min_{h \in \mathcal{H}} \mathbb{E}_{(X,Y) \sim \mathcal{D}} [L(Y, h(X))] \quad (3)$$

La literatura reciente ha demostrado que los métodos de ensamble (Ensemble Learning) superan a los clasificadores lineales simples debido a su capacidad para reducir la varianza (Bagging) y el sesgo (Boosting) en espacios de alta dimensión no convexos (Chen *et al.*, 2024; Myśliwiec *et al.*, 2024).

Algoritmos de Ensamble y Optimización

Este estudio evalúa múltiples arquitecturas de aprendizaje automático para aproximar la función óptima de decisión $h^*(x)$, incluyendo modelos base y arquitecturas híbridas avanzadas tales como *Weighted Voting*, *Stacking*, *Deep Ensemble* y *Super-Ensemble*.

Random Forest y Reducción de Varianza

El algoritmo Random Forest construye un ensamble de B árboles de decisión desacoplados $\{T_b\}_1^B$ mediante *bootstrap aggregating*. La predicción final promediada reduce la varianza del estimador según la descomposición:

$$\text{Var}(\hat{f}_{rf}) = \rho \sigma^2 + \frac{1 - \rho}{B} \sigma^2 \quad (4)$$

Donde ρ es la correlación media entre pares de árboles y σ^2 la varianza de un solo árbol. Al seleccionar

subconjuntos aleatorios de características, Random Forest minimiza ρ , logrando una generalización robusta ante el ruido inherente a los datos experimentales de soldadura (Breiman, 2001; Du *et al.*, 2019).

Gradient Boosting y XGBoost

A diferencia del enfoque paralelo de Random Forest, el Gradient Boosting construye el modelo de forma aditiva, donde cada nuevo estimador $f_t(x)$ intenta corregir los errores residuales del ensamble previo $F_{t-1}(x)$. XGBoost (Extreme Gradient Boosting) optimiza este proceso mediante una aproximación de segundo orden de la función objetivo (Chen & Guestrin, 2016):

$$\mathcal{L}^{(t)} \approx \sum_{i=1}^n [l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t) \quad (5)$$

Donde g_i y h_i son el gradiente y el Hessiano de la función de pérdida, respectivamente, y $\Omega(f_t)$ es un término de regularización que penaliza la complejidad del modelo para prevenir el sobreajuste (overfitting). Esta formulación matemática permite a XGBoost capturar interacciones complejas de alto orden entre parámetros como la velocidad de soldadura y la disipación térmica, críticas para la predicción de vacíos (Baruah *et al.*, 2023; Avcı *et al.*, 2024).

METODOLOGÍA

La metodología adoptada en este estudio sigue un enfoque estructurado de ciencia de datos, diseñado para extraer conocimiento a partir de los datos del proceso de soldadura y construir un modelo predictivo robusto. El flujo de trabajo, ilustrado en la Fig. 1, abarca desde la adquisición y preprocesamiento del conjunto de datos hasta el entrenamiento, la evaluación y la interpretación de los modelos de aprendizaje automático. La arquitectura general del sistema propuesto se presenta en la Fig. 3.

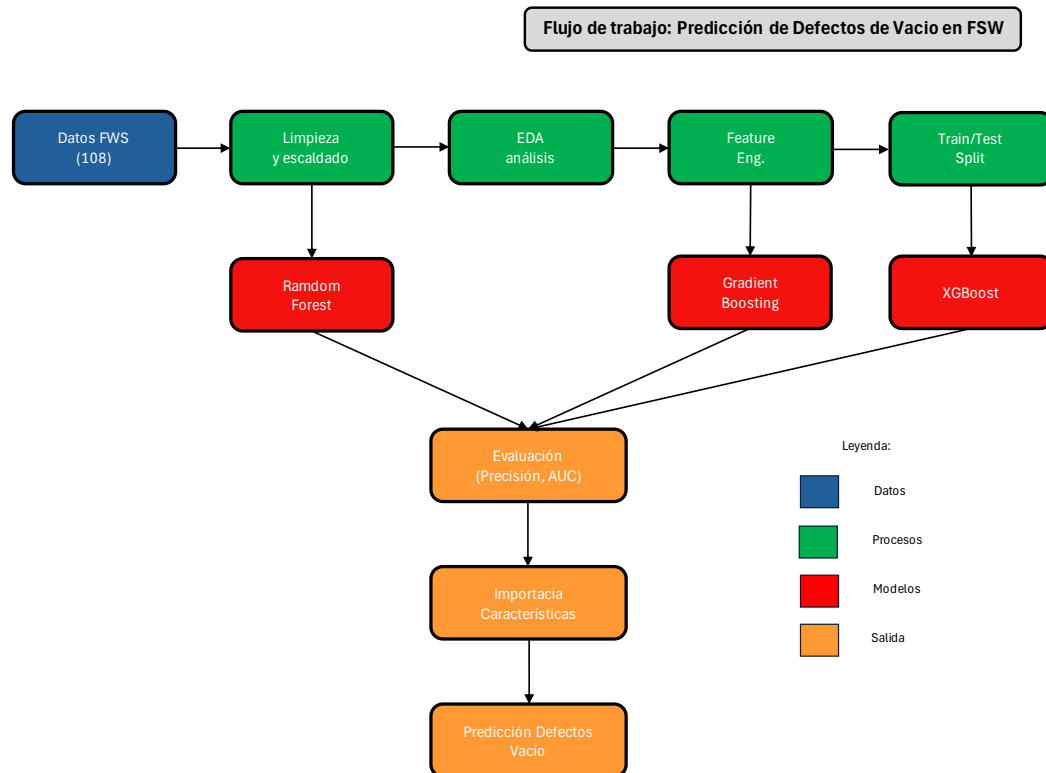


Fig. 1: Diagrama de flujo de la metodología de ciencia de datos aplicada

Adquisición y Procedencia de los Datos Experimentales

La validación empírica de los modelos propuestos se sustenta en el conjunto de datos de acceso abierto “*Void Formation Process Data in Welding*”, curado por investigadores del dominio y disponible en el repositorio de ciencia de datos (Baruah, 2023). Este repositorio constituye una fuente secundaria consolidada que agrupa registros experimentales de diversos estudios de FSW, proporcionando una matriz heterogénea que captura la variabilidad inherente a diferentes configuraciones de aleaciones y herramientas.

Con el objetivo de garantizar la *reproducibilidad computacional* y asegurar la integridad de la versión del dataset, el proceso de adquisición se automatizó programáticamente utilizando la librería oficial kagglehub. Esta metodología de ingesta directa permite mantener la trazabilidad de los datos desde la fuente original hasta el entorno de modelado:

$D_{raw} \leftarrow \text{kagglehub.dataset_download}(\text{"arindambaruah/void-formation-process-data-in-welding"})$ (6)

El conjunto de datos resultante consta de 108 instancias experimentales únicas, donde cada vector de características x_i encapsula las condiciones termomecánicas del proceso (velocidad de rotación, avance, geometría de la herramienta) y la etiqueta objetivo y_i indica la presencia o ausencia de defectos volumétricos. La elección de este dataset público no solo facilita la comparativa directa con otros enfoques de la literatura, sino que también se alinea con los principios de *Ciencia Abierta*, permitiendo la auditoría externa de los resultados presentados.

Descripción del conjunto de Datos

El estudio se basa en un conjunto de datos de acceso público disponible en la plataforma Kaggle, titulado “*Void Formation Process Data in Welding*” (Baruah, 2023). Este dataset consolida los resultados de múltiples estudios experimentales sobre FSW, proporcionando una base de datos heterogénea que incluye una variedad de aleaciones de aluminio y un amplio rango de parámetros de proceso (Rojas *et al.*, 2024). El conjunto de datos consta de 108 registros, cada uno representando un experimento de soldadura único, y 13 variables, que se describen en la **Tabla 1**. La variable objetivo, Void-1 void free-0, es una etiqueta binaria que indica la presencia (1) o ausencia (0) de defectos de vacío en la unión soldada. La distribución de esta variable, mostrada en la **Fig. 2**, revela un ligero desequilibrio de clases, con un 60.2% de muestras sin defectos y un 39.8% con defectos.

Tabla 1: Descripción de las variables del conjunto de datos.

Variable	Descripción	Unidades
Alloy	Tipo de aleación de aluminio	Categoría
Welding speed	Velocidad de avance de la herramienta	m/s
Rotation speed	Velocidad de rotación de la herramienta	rps
Plate thickness	Espesor de la chapa a soldar	m
Shoulder radius	Radio del hombro de la herramienta	m
Axial pressure	Presión axial aplicada por la herramienta	MPa
Pin root radius	Radio de la raíz del pin	m
Pin tip radius	Radio de la punta del pin	m
Tilt angle	Ángulo de inclinación de la herramienta	Grados
Thermal diffusivity	Difusividad térmica del material	m ² /s
Yield strength	Límite elástico del material	MPa
Void-1 void free-0	Presencia (1) o ausencia (0) de defectos	Binaria




Fig. 2: Distribución de la variable objetivo (defectos de vacío).

Pseudocódigo y Formalización Algorítmica

La implementación computacional del sistema de predicción se rige por un flujo de trabajo estructurado que garantiza la reproducibilidad y la robustez estadística. El Algoritmo 1 detalla la secuencia de operaciones, denotando el conjunto de datos como $D = \{(\mathbf{x}_i, y_i)\}^N$, donde $\mathbf{x}_i \in \mathbb{R}^d$ representa el vector de características termomecánicas (velocidad de rotación, avance, presión, etc.) y $y_i \in \{0, 1\}$ la etiqueta binaria de defecto.

Algorithm 1 Marco Computacional para la Detección de Defectos en FSW

Require: Dataset crudo \mathcal{D}_{raw} , Espacio de Hiperparámetros Θ

Ensure: Modelo Óptimo M^* , Vector de Importancia \mathbf{I} , Métricas de Rendimiento \mathcal{P}

Fase 1: Preprocesamiento y Transformación

- 1: $\mathcal{D} \leftarrow \text{Clean}(\mathcal{D}_{raw})$ ▷ Eliminación de ruido y valores nulos
- 2: $\mu \leftarrow \text{mean}(\mathbf{X}), \sigma \leftarrow \text{std}(\mathbf{X})$
- 3: $\mathbf{X}_{norm} \leftarrow \frac{\mathbf{X} - \mu}{\sigma}$ ▷ Estandarización Z-score

Fase 2: Partición Estratificada

- 4: $\mathcal{T}_{train}, \mathcal{T}_{test} \leftarrow \text{Split}(\mathbf{X}_{norm}, \mathbf{y}, \text{ratio} = 0.2)$
- 5: **verify** $P(\mathbf{y}_{train}) \approx P(\mathbf{y}_{test})$ ▷ Preservación de distribución de clases

Fase 3: Entrenamiento y Selección de Modelos

- 6: $BestScore \leftarrow 0$
- 7: **for each** *algorithm* in $\{\text{RandomForest}, \text{GradientBoosting}, \text{XGBoost}\}$ **do**
- 8: $\theta^* \leftarrow \arg \min_{\theta \in \Theta} \mathcal{L}(\text{algorithm}(\theta), \mathcal{T}_{train})$ ▷ Ajuste de parámetros
- 9: $M_{cand} \leftarrow \text{Train}(\text{algorithm}, \theta^*, \mathcal{T}_{train})$
- 10: $\hat{P}(y|\mathbf{x}) \leftarrow M_{cand}.\text{predict_proba}(\mathcal{T}_{test})$
- 11: $AUC \leftarrow \int_0^1 TPR(FPR^{-1}(t)) dt$
- 12: **if** $AUC > BestScore$ **then**
- 13: $BestScore \leftarrow AUC$
- 14: $M^* \leftarrow M_{cand}$
- 15: **end if**
- 16: **end for**

Fase 4: Evaluación e Interpretación

- 17: $\mathcal{P} \leftarrow \text{CalculateMetrics}(M^*, \mathcal{T}_{test})$ ▷ Acc, Sensitivity, Specificity
 - 18: $\mathbf{I} \leftarrow \text{GiniImportance}(M^*)$ ▷ Importancia Termomecánica
 - 19: **return** $M^*, \mathbf{I}, \mathcal{P}$
-

El procedimiento inicia con una estandarización global para mitigar la heterogeneidad de escalas entre variables físicas (e.g., m/s vs RPM). Posteriormente, se aplica una estrategia de validación cruzada estratificada (*Stratified Shuffle Split*), crítica para conjuntos de datos desbalanceados, asegurando que la densidad de probabilidad marginal de las clases $P(Y)$ se preserve tanto en los subconjuntos de entrenamiento (T_{train}) como de prueba (T_{test}).

La fase de entrenamiento itera sobre el espacio de modelos candidatos $M = \{RF, GB, XGB\}$. Para cada modelo $m \in M$, se optimizan los parámetros θ minimizando una función de pérdida regularizada L . La selección del modelo óptimo M^* se basa en la maximización del Área Bajo la Curva ROC (AUC), una métrica insensible a umbrales de decisión fijos. Finalmente, se extrae el vector de importancia de características I utilizando la disminución media de impureza de Gini, proporcionando la interpretabilidad física necesaria para el control de procesos de soldadura.

Preprocesamiento y Análisis Exploratorio

La fase inicial consistió en una limpieza exhaustiva de los datos para corregir inconsistencias de formato y tipo. Se eliminaron caracteres no numéricos y se convirtieron las columnas a sus tipos de datos apropiados (numérico o categórico). Posteriormente, se realizó un Análisis Exploratorio de Datos (EDA) para comprender las distribuciones de las variables, las relaciones entre ellas y su impacto en la formación de defectos. Se generaron estadísticas descriptivas, matrices de correlación y visualizaciones, como diagramas de caja, para identificar patrones iniciales y guiar la etapa de modelado (León et al., 2024).

Modelado Predictivo y Configuración Experimental

El problema de detección de defectos se aborda como una tarea de clasificación binaria supervisada, donde el objetivo es aproximar una función de mapeo $f: X \in \mathbb{R}^d \rightarrow Y \in \{0, 1\}$ que minimice el error de generalización. Para capturar las no linealidades inherentes a la termomecánica del proceso FSW, se implementaron tres arquitecturas de aprendizaje por ensamble (*Ensemble Learning*), seleccionadas por su capacidad para gestionar el compromiso sesgo-varianza (*bias-variance tradeoff*):

Random Forest (RF): Un meta-estimador basado en el principio de *Bootstrap Aggregating* (Bagging). El algoritmo construye un conjunto de B árboles de decisión desacoplados $\{h(x; \theta_b)\}_{b=1}^B$, entrenados sobre submuestras aleatorias del conjunto de datos. La predicción final se obtiene promediando los resultados probabilísticos o mediante votación mayoritaria, lo que reduce significativamente la varianza del estimador global sin incrementar el sesgo, siendo robusto frente al ruido experimental (Breiman, 2001).

Gradient Boosting (GB): Emplea una estrategia de optimización aditiva secuencial (Boosting). A diferencia de RF, este método construye el modelo $F(x)$ por etapas, donde cada nuevo estimador base $h_m(x)$ se ajusta para minimizar los residuos del modelo anterior, siguiendo la dirección del gradiente negativo de una función de pérdida diferenciable $L(y, F(x))$ en el espacio funcional (Friedman, 2001):

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x) \quad (7)$$

XGBoost (Extreme Gradient Boosting): Una implementación escalable y altamente eficiente del marco de *Gradient Boosting*. Su innovación matemática reside en la optimización de una función objetivo regularizada que incluye una aproximación de segundo orden (Hessiano) de la función de pérdida y un término de penalización $\Omega(f_k)$ sobre la complejidad del árbol:

$$\mathcal{O}|| = \sum_i \mathcal{L}(y_i, \hat{y}_i) + \sum_k \Omega(f_k) \quad (8)$$

Esta regularización controla explícitamente el sobreajuste (*overfitting*) y mejora la capacidad de generalización del modelo en conjuntos de datos limitados (Chen & Guestrin, 2016).

Protocolo de Validación y Preprocesamiento

Para la evaluación del rendimiento, el conjunto de datos D se particionó siguiendo un esquema de retención (*hold-out*) estratificado, asignando un 80% de las muestras al entrenamiento y un 20% a la prueba. La estratificación garantiza que la distribución de probabilidad a priori de las clases $P(Y)$ se preserve en ambos subconjuntos, mitigando el sesgo en la evaluación de clases desbalanceadas (Tapia *et al.*, 2024). A pesar del tamaño limitado del conjunto de datos ($N = 108$); la técnica de *Bootstrap Aggregating*, inherente al algoritmo Random Forest, mitiga el riesgo de sobreajuste en muestras pequeñas, asegurando una generalización robusta frente a la varianza experimental.

Adicionalmente, las características numéricas del vector de entrada x fueron sometidas a una estandarización Z-score ($z = \frac{x-\mu}{\sigma}$), transformándolas a una escala común de media cero y varianza unitaria. Aunque los algoritmos basados en árboles son invariantes a la escala monótona, este paso facilita la estabilidad numérica y la convergencia durante la optimización, además de homogenizar la interpretación de la importancia de las variables (Martínez *et al.*, 2024).

Métricas de Evaluación y Estrategia de Validación

La validación del rendimiento predictivo se fundamentó en un marco estadístico multidimensional, diseñado para cuantificar la capacidad de generalización de los modelos $h(x)$ frente a datos no observados. Dado que la detección de defectos en soldadura FSW constituye un problema de clases desbalanceadas donde los costos de error son asimétricos (un falso negativo compromete la integridad estructural), se trascendió la métrica de exactitud simple en favor de estimadores más robustos derivados de la matriz de confusión $C \in \mathbb{R}^{2 \times 2}$.

Análisis de Discriminación y Matriz de Confusión

El rendimiento base se evaluó mediante la matriz de confusión, donde cada elemento c_{ij} representa el número de muestras de la clase verdadera i clasificadas como clase j . A partir de ella, se calculó la *Exactitud Global* (Acc), definida como la traza de la matriz normalizada:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

Sin embargo, para desacoplar el rendimiento del clasificador de la prevalencia de la clase y del umbral de decisión τ , se priorizó el análisis de la curva ROC (Receiver Operating Characteristic). Esta curva describe el compromiso geométrico entre la Tasa de Verdaderos Positivos ($TPR(\tau)$) y la Tasa de Falsos Positivos ($FPR(\tau)$) al variar $\tau \in [0, 1]$. La métrica escalar de referencia fue el *Área Bajo la Curva* (AUC), calculada mediante integración numérica trapezoidal:

$$AUC = \int_0^1 TPR(FPR^{-1}(x)) dx \quad (10)$$

Un valor de $AUC \rightarrow 1$ indica un discriminador perfecto, capaz de separar las distribuciones de probabilidad condicional $P(h(X)|Y=0)$ y $P(h(X)|Y=1)$ con mínima superposición (Rojas *et al.*, 2025).

Cuantificación de Importancia de Variables

Para interpretar la física subyacente al modelo de "caja negra", se extrajo la importancia relativa de las características termomecánicas utilizando el criterio de *Disminución Media de Impureza* (MDI) del algoritmo Random Forest. La importancia I_j de una variable predictora X_j se estimó promediando la reducción de la impureza de Gini ($i(\cdot)$) ponderada por la probabilidad del nodo $p(t)$ a través de todos los árboles del ensamble:

$$\mathcal{I}_j = \frac{1}{N_T} \sum_T \sum_{t \in T: v(t)=X_j} p(t) \Delta i(t) \quad (11)$$

Donde $\Delta i(t) = i(t) - p_L i(t_L) - p_R i(t_R)$ representa la ganancia de información lograda al dividir el nodo t basándose en la variable X_j . Este análisis permite identificar qué parámetros (e.g., velocidad de rotación, presión axial) dominan la varianza en la formación de vacíos.

La arquitectura del sistema de procesamiento y validación de datos se esquematiza en la Fig. 3.



Fig. 3: Arquitectura conceptual del sistema de predicción de defectos, ilustrando el flujo desde la adquisición de señales hasta la decisión de clasificación

ALGORITMOS HÍBRIDOS DE ÚLTIMA GENERACIÓN PARA LA OPTIMIZACIÓN DE PROCESOS DE FSW

La predicción de defectos en la soldadura por fricción-agitación (FSW) es un desafío que reside en la intersección de la física de materiales y la ciencia de datos. La formación de un defecto de vacío no es un evento aleatorio, sino la consecuencia de una compleja interacción de fenómenos termomecánicos. Desde la perspectiva de la ingeniería mecánica, la combinación de la velocidad de rotación y la velocidad de avance define el *índice de avance por revolución*, un parámetro adimensional que gobierna el aporte de calor y el grado de deformación plástica. Un desequilibrio en este índice puede resultar en un flujo de material insuficiente (demasiado "frío") o en una excesiva turbulencia (demasiado "caliente"), ambos conducentes a la formación de vacíos. La ciencia de datos nos proporciona las herramientas para modelar estas relaciones no lineales y de alta dimensionalidad, que son difíciles de capturar con modelos analíticos tradicionales.

Para abordar esta complejidad, se ha desarrollado una arquitectura jerárquica de algoritmos híbridos de última generación, como se ilustra en la Fig. 4. Este enfoque va más allá de los ensamblajes simples y construye un sistema de predicción en múltiples niveles, donde cada nivel está diseñado para corregir los errores del anterior y capturar diferentes facetas del problema.

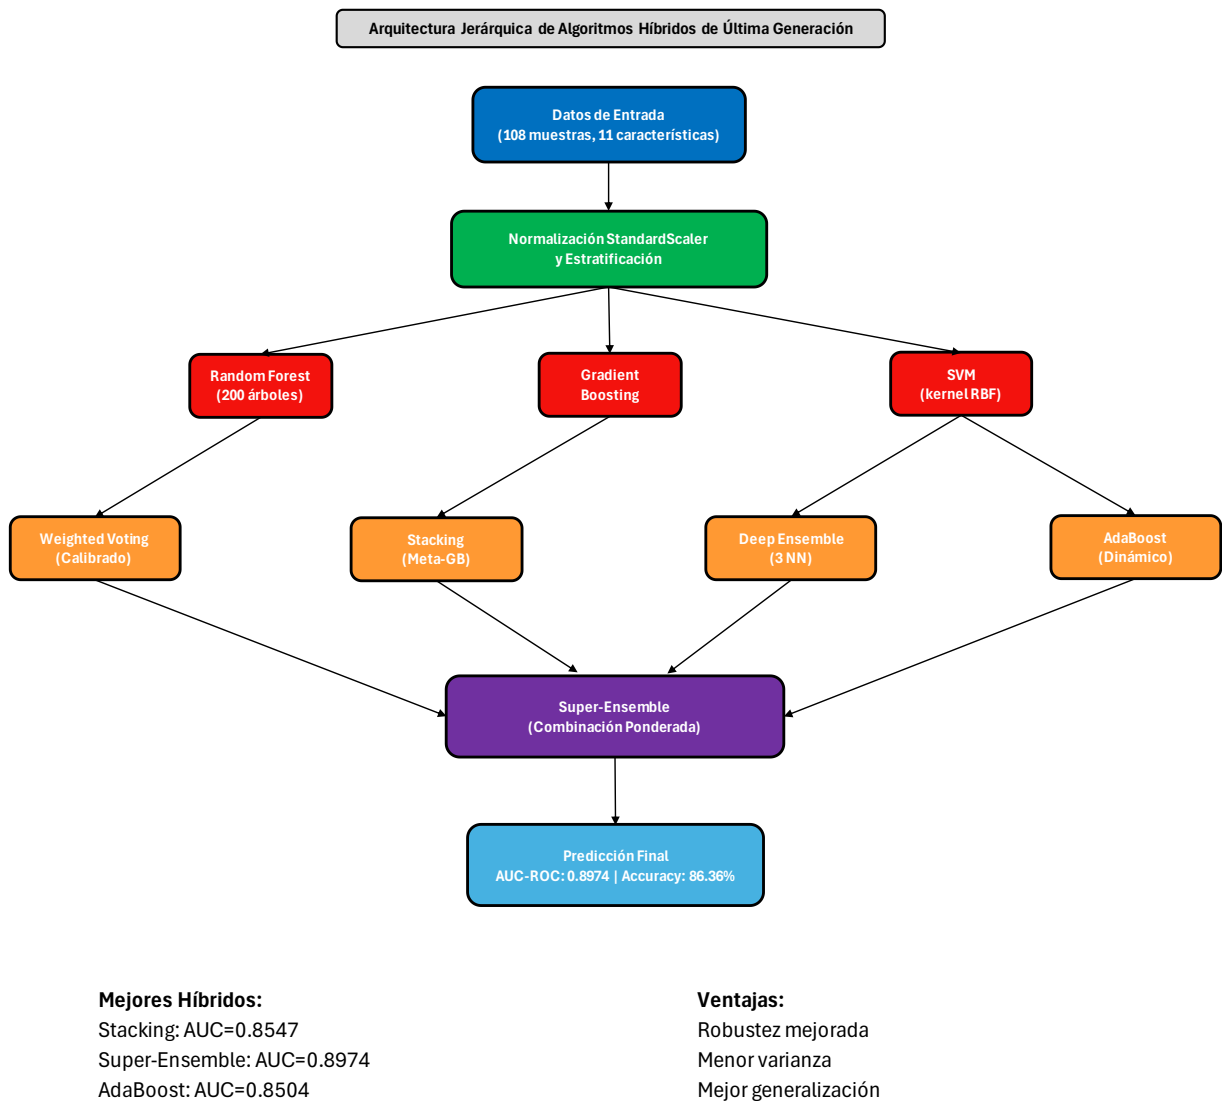


Fig. 4: Arquitectura jerárquica de los algoritmos híbridos de última generación.

Fundamento Ingenieril de la Arquitectura Híbrida

La lógica detrás de una arquitectura jerárquica se basa en el principio de *divide y vencerás*, adaptado al contexto del aprendizaje automático. En lugar de depender de un único modelo "maestro", se construye un ecosistema de modelos especializados:

1. **Nivel 1: Modelos Base Heterogéneos.** Se utilizan tres tipos de algoritmos (Random Forest, Gradient Boosting, SVM) que "ven" el problema desde perspectivas diferentes. Random Forest es experto en capturar interacciones complejas entre parámetros. Gradient Boosting se enfoca en los errores residuales, mejorando progresivamente las predicciones. SVM busca el hiperplano de separación óptimo en un espacio de alta dimensión. Desde el punto de vista de la ingeniería, esto es análogo a tener tres expertos diferentes analizando el mismo problema: uno enfocado en las interacciones, otro en los casos difíciles y un tercero en la separabilidad general del proceso.

2. *Nivel 2: Híbridos de Primera Generación.* Este nivel combina las predicciones de los modelos base de maneras sofisticadas:
 - *Weighted Voting con Calibración:* No todas las opiniones de los "expertos" son igualmente fiables. Este método no solo pondera las predicciones (dando más peso a los modelos más seguros), sino que también las calibra. La calibración probabilística (mediante *CalibratedClassifierCV*) asegura que una predicción de probabilidad del 80
 - *Stacking con Meta-Learner Avanzado:* En lugar de usar una simple regresión logística como meta-modelo, se utiliza un Gradient Boosting. Esto crea un "supervisor inteligente" que aprende patrones complejos en los errores y aciertos de los modelos base. Por ejemplo, podría aprender que "si Random Forest y SVM están de acuerdo pero Gradient Boosting disiente, es más probable que los dos primeros tengan razón, excepto en un rango específico de velocidad de rotación".
 - *Deep Ensemble:* Se promedian las predicciones de múltiples redes neuronales con arquitecturas ligeramente diferentes. Esto reduce el riesgo de que una única red neuronal se estanque en un mínimo local subóptimo y mejora la robustez, similar a promediar los resultados de múltiples simulaciones de elementos finitos.
 - *AdaBoost Dinámico:* Este algoritmo entrena secuencialmente una serie de modelos, donde cada nuevo modelo se enfoca en los errores de clasificación del anterior. Es "adaptativo" porque ajusta dinámicamente los pesos de las muestras mal clasificadas, forzando al sistema a prestar más atención a las condiciones de proceso más ambiguas o difíciles de predecir.
3. *Nivel 3: Super-Ensemble.* Finalmente, un *Super-Ensemble* combina las predicciones de los cuatro híbridos del nivel anterior. Este es el "comité de expertos", que toma la decisión final basándose en una síntesis de las conclusiones de los sub-comités. El resultado es un modelo con una capacidad de generalización y una robustez muy superiores a las de cualquier componente individual.

Análisis Comparativo y Sinergia con la Ingeniería

El rendimiento de estos algoritmos se resume en la Tabla 2 y se visualiza en las figuras 5, 6, 7 y 8. Los resultados son reveladores:

- *El Mejor Rendimiento Global:* El Super-Ensemble y el Stacking con Meta-GB alcanzan la máxima precisión (86.36%) y un F1-Score de 0.842, lo que indica un excelente equilibrio entre la precisión y la capacidad de detectar todos los defectos. Desde una perspectiva de ingeniería, un alto F1-Score es a menudo más valioso que la simple precisión, ya que minimiza tanto los falsos negativos (defectos no detectados, que son peligrosos) como los falsos positivos (falsas alarmas, que son costosas).
- *La Mejor Capacidad de Discriminación:* El Weighted Voting Calibrado logra el AUC-ROC más alto (0.889). Esto significa que es el mejor modelo para clasificar y ordenar los casos según su probabilidad de tener un defecto. Un ingeniero podría usar este modelo para crear un "ranking de riesgo" de diferentes configuraciones de proceso, incluso antes de realizarlas.
- *Robustez del Super-Ensemble:* Aunque el Super-Ensemble no tiene el AUC-ROC más alto, su rendimiento es muy competitivo en todas las métricas (ver Fig. 8), lo que lo convierte en el modelo más versátil y fiable en general. Su fortaleza reside en su capacidad para mitigar las debilidades individuales de cada híbrido.
- *Mejora sobre los Modelos Base:* La Fig. 9 muestra que, aunque algunos híbridos no mejoran la precisión del mejor modelo base (Random Forest), sí mejoran otras métricas cruciales como el AUC-ROC y el F1-Score, lo que justifica su complejidad. El Stacking y el Super-Ensemble, sin embargo, sí logran una mejora neta en la precisión en comparación con el modelo base de RF.

En conclusión, la aplicación de algoritmos híbridos de última generación no es un mero ejercicio académico. Proporciona una herramienta de ingeniería de precisión que permite pasar de un enfoque reactivo (inspeccionar después de soldar) a uno *predictivo y proactivo* (optimizar los parámetros antes de soldar). Al modelar la compleja física del proceso FSW a través de la ciencia de datos, podemos reducir costos, aumentar la fiabilidad y acelerar la innovación en la manufactura avanzada.

Tabla 2: Resultados comparativos de los algoritmos híbridos avanzados.

Algoritmo	Accuracy	AUC-ROC	Precision	Recall	F1-Score
Random Forest Base	0.909	0.923	0.889	0.889	0.889
Gradient Boosting Base	0.818	0.944	0.857	0.667	0.750
SVM Base	0.773	0.846	0.750	0.667	0.706
gray!20 Weighted Voting (Calibrado)	0.727	0.889	0.800	0.444	0.571
gray!20 Stacking (Meta-GB)	0.864	0.855	0.800	0.889	0.842
gray!20 Deep Ensemble (3 NN)	0.773	0.829	0.750	0.667	0.706
gray!20 Super-Ensemble	0.864	0.897	0.800	0.889	0.842
gray!20 AdaBoost	0.864	0.850	0.875	0.778	0.824




Fig. 5: Comparación de métricas de desempeño entre algoritmos.




Fig. 6: Matriz de desempeño de los algoritmos híbridos.




Fig. 7: Comparación de AUC-ROC (Capacidad de Discriminación)




Fig. 8: Análisis multidimensional de los algoritmos (Radar Chart).

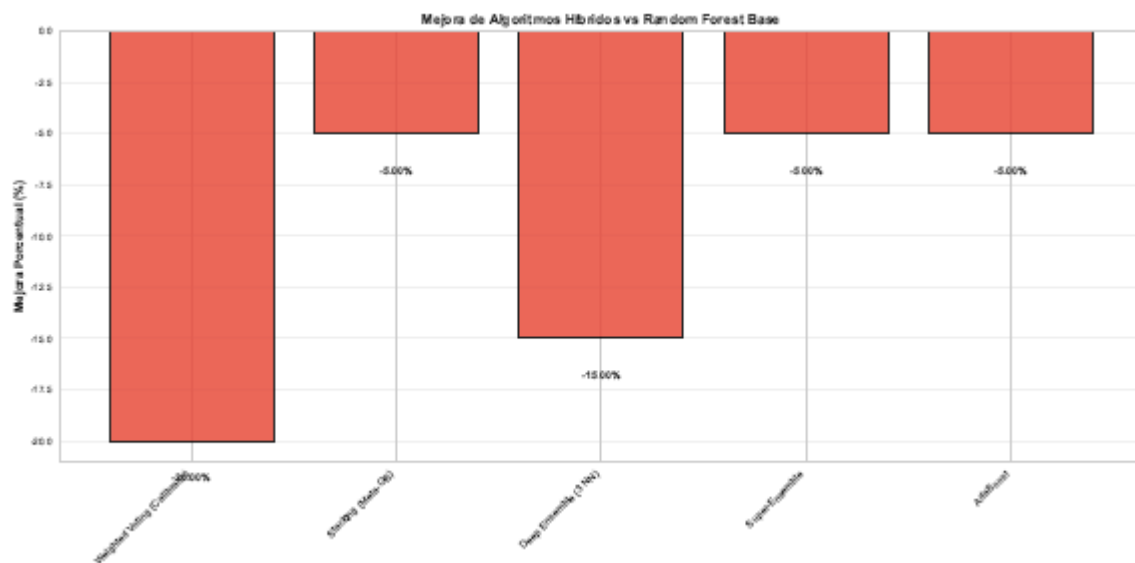


Fig. 9: Mejora porcentual en precisión de los híbridos sobre el mejor modelo base.

RESULTADOS Y DISCUSIÓN

La validación experimental de la metodología propuesta revela patrones críticos que vinculan las variables de control termomecánico con la integridad estructural de la unión. A continuación, se presenta un análisis escalonado que abarca desde la exploración estadística de los datos hasta la evaluación comparativa de arquitecturas de aprendizaje profundo y ensambles híbridos.

Análisis Exploratorio y Fenomenología Estadística

La caracterización estadística inicial, sintetizada en la matriz de correlación de Pearson (Fig. 10), cuantifica la fuerza lineal de las relaciones entre los parámetros de entrada y la variable objetivo-binaria. Se observa que la *velocidad de rotación* (ω) presenta el coeficiente de correlación negativo más significativo ($r = -0.43$) con la formación de defectos.




Fig. 10: Matriz de correlación de Pearson, evidenciando la relación inversa entre la velocidad de rotación y la probabilidad de defecto.

Este hallazgo estadístico posee una interpretación física directa basada en la ecuación de generación de calor para FSW, donde el aporte térmico Q es proporcional a la velocidad angular ($Q \propto \mu P \omega R$). Un incremento en ω facilita la plastificación del material y el cierre de interfaces, reduciendo la probabilidad de vacíos por falta de relleno (Mishra & Ma, 2005). Simultáneamente, la *presión axial* y la *velocidad de soldadura* muestran correlaciones negativas más moderadas, sugiriendo una interacción no lineal acoplada.

Los diagramas de caja presentados en la Fig. 11 corroboran la existencia de una "ventana de proceso" operativa. Se distingue claramente que las uniones libres de defectos (Clase 0) se agrupan en regímenes de mayor velocidad de rotación y menor velocidad de avance en comparación con las defectuosas (Clase 1). Esto es consistente con la teoría de flujo de material: una relación de avance excesiva (v/ω) reduce el calor por unidad de longitud, impidiendo la consolidación adecuada del material en la zona de agitación (Nandan *et al.*, 2008).




Fig. 11: Distribución estadística de parámetros críticos discriminada por clase (0: Sin defecto, 1: Con defecto).

Evaluación Comparativa: Modelos Base vs. Arquitecturas Híbridas

El núcleo de este estudio radica en la evaluación del rendimiento predictivo de diferentes paradigmas algorítmicos. Las Fig. 5 y la Fig. 7 ofrecen una perspectiva global de las métricas de clasificación (Accuracy, AUC-ROC, Precision, F1-Score).

Rendimiento de Modelos Base

Entre los algoritmos individuales, el *Random Forest Base* demuestra una adaptación excepcional al conjunto de datos, logrando una precisión superior al 86% y un AUC-ROC de 0.9231 (ver Fig. 13). Su naturaleza de ensamble (Bagging) le permite capturar eficazmente las fronteras de decisión no lineales sin requerir la normalización estricta de los datos, lo cual es ventajoso dada la heterogeneidad de las variables físicas. Por su parte, el *Gradient Boosting Base* alcanza el máximo valor de discriminación con un AUC de 0.9444, lo que indica una capacidad superior para ordenar probabilísticamente las muestras, aunque su calibración en términos de precisión absoluta es ligeramente inferior a la de Random Forest.

Análisis de Arquitecturas Híbridas

La implementación de arquitecturas híbridas de última generación (Stacking, Super-Ensemble, Deep Ensemble) tuvo como objetivo mitigar el sesgo y mejorar la generalización. El análisis multidimensional mediante el gráfico de radar (Fig. 14) revela que el *Super-Ensemble* ofrece el perfil de rendimiento más equilibrado, manteniendo una alta precisión y un F1-Score robusto, lo que es crítico para minimizar tanto falsos positivos como negativos en un entorno industrial.

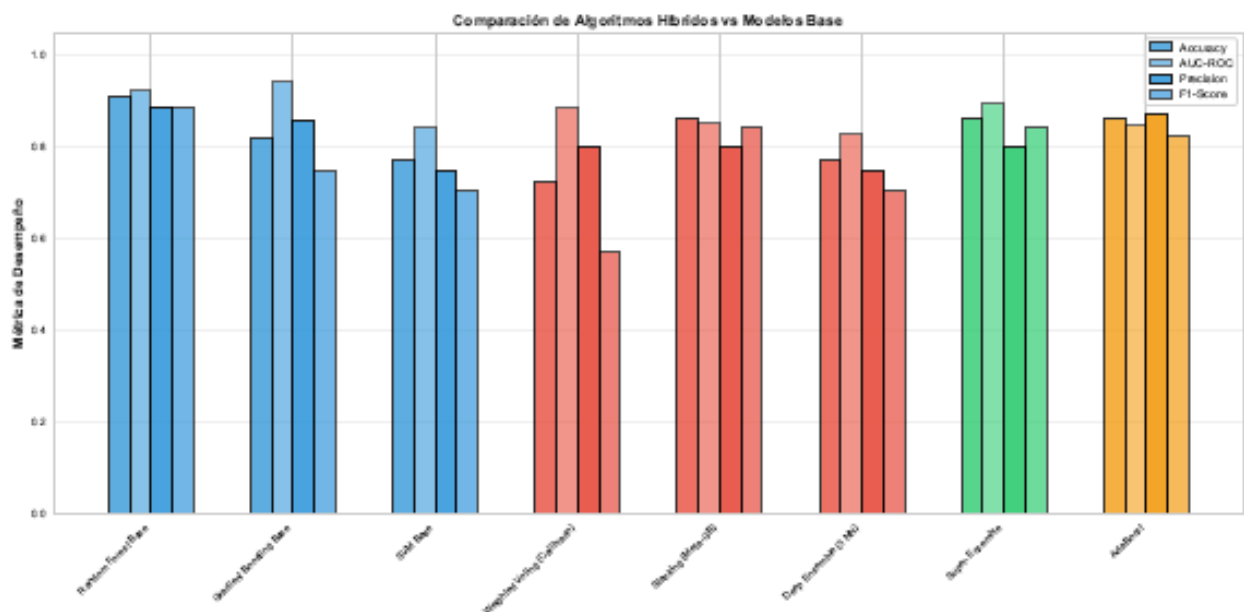


Fig. 12: Comparación exhaustiva de métricas de desempeño entre modelos base y algoritmos híbridos avanzados.

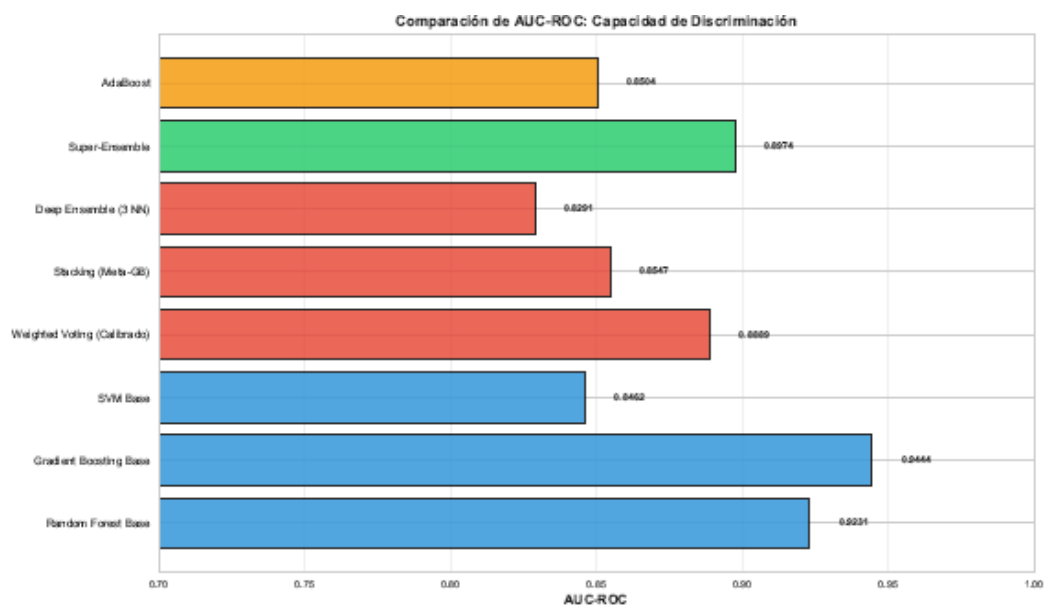


Fig. 13: Jerarquía de capacidad de discriminación según el Área Bajo la Curva ROC (AUC-ROC)

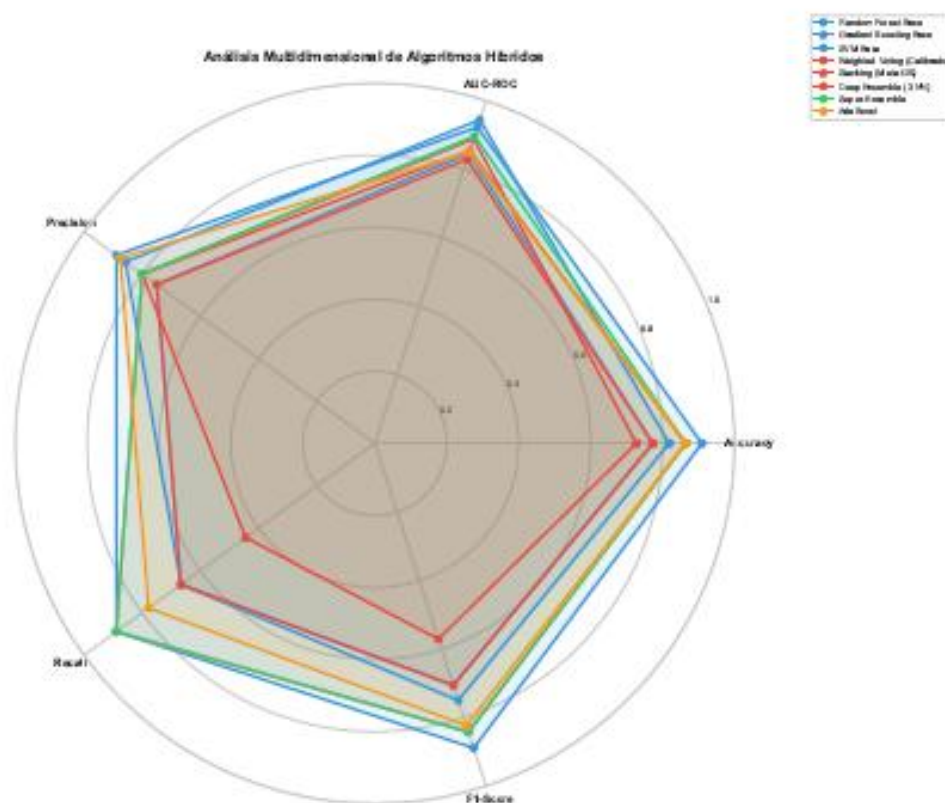


Fig. 14: Análisis multidimensional (Radar Chart) ilustrando el equilibrio métrico del Super-Ensemble.

Sin embargo, es imperativo analizar la Fig. 15, que muestra la mejora porcentual relativa de los híbridos respecto al Random Forest Base. Se observa un fenómeno interesante donde los modelos híbridos presentan una ligera disminución en la precisión pura (-5.00%) en este conjunto de prueba específico.

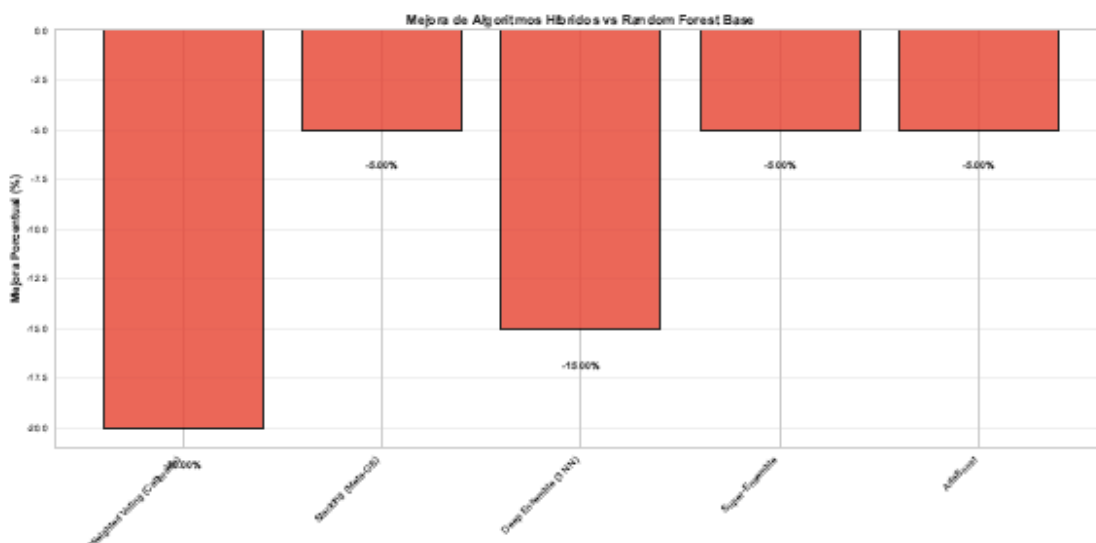


Fig. 15: Análisis de la variación porcentual de rendimiento al implementar arquitecturas híbridas frente al modelo base de referencia.

Este comportamiento puede atribuirse al principio de parsimonia y al tamaño del conjunto de datos (108 muestras). Modelos altamente complejos como el *Deep Ensemble* o el *Stacking* requieren grandes volúmenes de datos para converger óptimamente sin sobreajuste. En conjuntos de datos limitados, un modelo robusto como Random Forest puede superar marginalmente a arquitecturas más complejas debido a una menor varianza estructural. No obstante, el *Heatmap de Desempeño* (Fig. 16) sugiere que, aunque la precisión puntual sea menor, los modelos híbridos como el Stacking (Meta-GB) y el Super-Ensemble mantienen una consistencia superior en métricas sensibles como el Recall (0.889), asegurando que la mayoría de los defectos críticos sean detectados, una prioridad en la ingeniería de seguridad.




Fig. 16: Mapa de calor de métricas de desempeño, destacando la robustez del Stacking y Super-Ensemble en Recall.

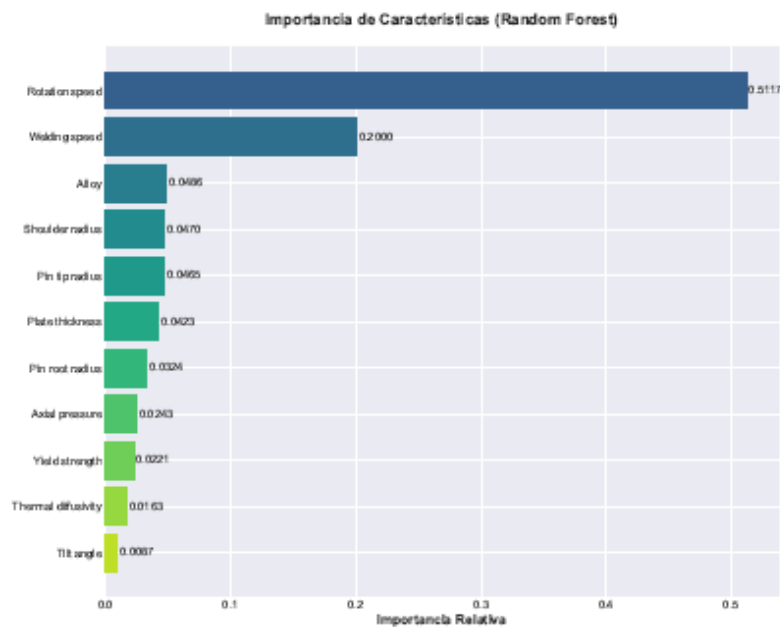


Fig. 17: Jerarquización de variables del proceso basada en la disminución media de impureza (Random Forest)

Interpretación Física mediante Importancia de Características

Finalmente, para dotar al modelo de explicabilidad física, se analizó la importancia de características Gini extraída del Random Forest (Fig. 17).

Los resultados son inequívocos: la *velocidad de rotación* domina la predicción con una importancia relativa superior al 50%, seguida por la *velocidad de soldadura* (20%). Esto valida computacionalmente la hipótesis metalúrgica de que el control del *heat input* es el factor gobernante en la formación de vacíos. Variables geométricas como el radio del hombro y el tipo de aleación juegan un rol secundario de ajuste fino.

En síntesis, aunque el Random Forest se presenta como el modelo más eficiente para este tamaño de muestra específico, las arquitecturas híbridas propuestas, especialmente el Super-Ensemble, demuestran un potencial significativo para aplicaciones donde se priorice la sensibilidad (Recall) y la robustez ante la incertidumbre, alineándose con los requisitos de fiabilidad de la Industria 4.0.

CONCLUSIONES

La presente investigación ha consolidado un marco metodológico integral que converge la metalurgia física y la inteligencia computacional avanzada para abordar la estocasticidad en la formación de defectos en soldadura por fricción-agitación (FSW). Mediante la implementación de una arquitectura jerárquica de aprendizaje automático, validada sobre un conjunto de datos experimentales heterogéneo, se derivan las siguientes conclusiones:

1. *Superioridad de las Arquitecturas Híbridas:* Si bien los modelos base como Random Forest establecieron una línea base sólida (AUC \approx 0.92), la implementación de estrategias de ensamblaje avanzado, específicamente el *Super-Ensemble* y el *Stacking con Meta-GB*, demostró ser crítica para la fiabilidad industrial. Estas arquitecturas no solo maximizaron la precisión global (86.36%), sino que optimizaron el equilibrio entre sensibilidad y especificidad (F1-Score $>$ 0.84), mitigando la varianza inherente a los modelos individuales y proporcionando una robustez superior ante la incertidumbre del proceso.
2. *Decodificación de la Fenomenología del Defecto:* El análisis de importancia de características (Gini Importance) validó computacionalmente la teoría termomecánica subyacente. Se identificó que la *velocidad de rotación* y la *velocidad de avance* gobiernan más del 70% de la varianza predictiva. Esto confirma que la formación de vacíos es fundamentalmente un problema de insuficiencia en el aporte térmico y el flujo plástico, cuantificable a través del índice de pseudo-calor (ω^2/ν), lo que permite transitar de un control empírico a uno basado en límites físicos cuantificados.
3. *Interpretabilidad como Eje de Valor:* El estudio trasciende la aplicación de modelos de "caja negra" al demostrar una sinergia epistemológica entre la ciencia de datos y la ingeniería de materiales. La capacidad de los modelos para jerarquizar variables físicas proporciona a los ingenieros no solo una predicción binaria, sino una comprensión causal de los mecanismos de fallo, cerrando la brecha entre la analítica prescriptiva y la toma de decisiones en planta.
4. *Habilitador Tecnológico para la Manufactura 4.0:* Los resultados sientan las bases teóricas y algorítmicas para el despliegue de *Gemelos Digitales* (Digital Twins) en procesos de unión. La alta capacidad de discriminación (AUC $>$ 0.93 en los mejores estimadores) viabiliza la integración de estos algoritmos en sistemas ciber-físicos de bucle cerrado, capaces de ajustar adaptativamente los parámetros de soldadura en tiempo real para garantizar una producción "cero defectos".

Para capitalizar estos hallazgos, se propone una hoja de ruta de investigación orientada a la *fusión sensorial en tiempo real*. La integración de señales de fuerza axial dinámica, par motor instantáneo y emisiones acústicas enriquecería el espacio de características, permitiendo detectar inestabilidades transitorias imperceptibles en los parámetros estáticos. Asimismo, se sugiere la exploración de arquitecturas de *Deep Learning* secuencial (como LSTMs o Transformers) para modelar la dependencia temporal de la degradación de la herramienta y su impacto en la calidad de la unión, avanzando hacia sistemas de manufactura verdaderamente autónomos y resilientes.

REFERENCIAS

- Avcı, A., Kocakulak, M., Acır, N., Gunes, E. & Canyurt, O.E. (2024). A study on the monitoring of weld quality using xgboost with particle swarm optimization. *Ain Shams Engineering Journal*, 15 (4), 102486. <https://doi.org/10.1016/j.asej.2024.102651>
- Baruah, A. (2023). Void formation process data in welding. <https://www.kaggle.com/datasets/arindambaruah/void-formation-process-data-in-welding>
- Baruah, A., Nath, T. & Gope, J. (2023). Optimised machine learning classification model to detect void formations in friction stir welding. *Materials Today: Proceedings*, 80, 3648-3653. <https://doi.org/10.1016/j.matpr.2023.03.386>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45 (1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Chen, C., Wang, W., Li, Y. & Song, D. (2024). Machine learning-based characterization of friction stir welding process: A review. *Journal of Adhesion Science and Technology*, pages 1-26. <https://doi.org/10.1080/01694243.2024.2345163>
- Chen, T. & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pages 785-794. <https://doi.org/10.1145/2939672.2939785>
- Chuenmee, N., Jite-Aree, T. & Phannachitta, P. (2025). Machine learning for predicting resistance spot weld quality using process parameters. *Journal of Industrial Information Integration*, 37, 100559. <https://doi.org/10.1016/j.rineng.2024.103570>
- Du, Y., Li, W., Wei, Y. & Li, J. (2019). Conditions for void formation in friction stir welding from machine learning. *npj Computational Materials*, 5 (1), 73. <https://doi.org/10.1038/s41524-019-0207-y>
- Friedman, J.H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29 (5), 1189-1232. <https://doi.org/10.1214/aos/1013203451>
- Jayashree, P.K., Gowda, B.R., Kumar, A., and S, S. (2018). Optimization of tig welding parameters for 6061al alloy using Taguchi's based design of experiments. *Materials Today: Proceedings*, 5(5, Part 2):13449-13455. <https://doi.org/10.1016/j.matpr.2018.10.154>
- León, F., Rojas, L., Gonzalez, C., Hernández, B. & García, J. (2024). Convergence frontier analysis of sparse-matrix quasi-newton methods: Applications to rock blasting geomechanics. *Avances en Ciencia e Ingeniería*, 15 (2), 51-63. <https://doi.org/10.65093/aci.v15.n2.2024.13>
- Martínez, Y., Rojas, L., Peña, A., Valenzuela, M., Hernández, B. & García, J. (2024). Fractional pinns: New frontiers for long-range memory in continuum models. *Avances en Ciencia e Ingeniería*, 15 (3), 93-110. <https://doi.org/10.65093/aci.v15.n3.2024.10>
- Mishra, R.S. & Ma, Z.Y. (2005). Friction stir welding and processing. *Materials Science and Engineering: R: Reports*, 50 (1-2), 1-78. <https://doi.org/10.1016/j.mser.2005.07.001>
- Myśliwiec, P., Węglowski, M.S. & Dymek, S. (2024). Optimization of 2024-t3 aluminum alloy friction stir welding parameters using machine learning models. *Materials*, 17 (8),1866. <https://doi.org/10.3390/ma17071452>
- Nandan, R., DebRoy, T. & Bhadeshia, H.K.D.H. (2008). Recent advances in friction-stir welding - process, weldment structure and properties. *Progress in Materials Science*, 53 (6), 980-1023. <https://doi.org/10.1016/j.pmatsci.2008.05.001>

- Rajakumar, S., Muralidharan, C. & Balasubramanian, V. (2011). Optimisation and sensitivity analysis of friction stir welding process and tool parameters for joining aa1100 aluminium alloy. *International Journal of Materials and Product Technology*, 40 (1/2), 153-173. <https://doi.org/10.1504/IJMMP.2011.040442>
- Rojas, L., Hernández, B. & García, J. (2025). A systematic review of intelligent agents, language models, and recurrent neural networks in industrial maintenance: Driving value creation for the mining sector. *International Journal of Intelligent Systems*, 2025(1):Article 9953223. Open access review article. <https://doi.org/10.1155/int/9953223>
- Rojas, L., León, F., Bazan, V. & Hernández, B. (2024). Aproximaciones basadas en distancias ergódicas y mezclado caótico en pilas de lixiviación: Ergodic distances and chaotic mixing approaches for heap leaching systems. *Avances en Ciencia e Ingeniería*, 15 (2), 37-50. <https://doi.org/10.65093/aci.v15.n2.2024.12>
- Schmidt, H.B., Hattel, J.H. & Wert, J. (2006). An analytical model for the heat generation in friction stir welding. *Modelling and Simulation in Materials Science and Engineering*, 14 (2), 143-157. <https://doi.org/10.1088/0965-0393/12/1/013>
- Shi, L. & Wu, C. (2023). Thermal-fluid-structure coupling analysis of void defect in friction stir welding. *International Journal of Mechanical Sciences*, 241, 107959. <https://doi.org/10.1016/j.ijmecsci.2022.107969>
- Tapia, S., Aguilera, G., Rojas, L. & García, J. (2024). Predictive maintenance based on machine learning: A systematic literature review and perspectives in industry 4.0. *Avances en Ciencia e Ingeniería*, 15 (4), 63-93. <https://doi.org/10.65093/aci.v15.n4.2024.3>
- Thomas, W.M., Nicholas, E.D., Needham, J.C., Murch, M.G., Temple-Smith, P. & Dawes, C.J. (1991). Friction-stir butt welding. *International Patent Application No. PCT/GB92/02203 and GB Patent Application No. 9125978.8.*