

APLICABILIDAD DE LA INTELIGENCIA ARTIFICIAL PARA EL CONTROL DE CALIDAD EN EL PROCESO DE SOLDADURA POR FRICCIÓN-AGITACIÓN

Marta Ingelmo Gómez^a, Jorge Velasco Manrique^a, Javier Romo García^a, Esteban Cañibano Alvarez^{a, b}

^a Fundación Cidaut, dpto. Materiales, Producto, Proceso; 47151 Boecillo – Valladolid (España)

^b Universidad de Valladolid; 47002 Valladolid (España)

RESUMEN:

Esta investigación se centra en el modelado y la caracterización de los resultados del proceso de soldadura por fricción-agitación (FSW) mediante el procesamiento de las señales vibro-acústicas y de temperatura generadas durante su ejecución. Con este fin, se ha desarrollado un modelo predictivo basado en Máquinas de Vectores de Soporte (SVM) capaz de estimar la calidad de la soldadura con precisión para diferentes configuraciones de unión. Esta característica se fundamenta en una muestra de entrenamiento robusta correspondiente a dos configuraciones de unión, específicamente aluminio-aluminio y aluminio-acero inoxidable, bajo diferentes parámetros de proceso y caracterizadas a partir de las señales de emisiones acústicas y temperatura generadas durante su ejecución. La selección y comprensión de las variables de entrada para el modelo –parámetros del proceso y características generales de la unión– se realizó mediante un análisis con algoritmos del tipo árboles de decisión. Este análisis, junto con la optimización de los hiperparámetros de la SVM fue fundamental para el desarrollo del modelo. Los resultados obtenidos a partir de la comparación de los datos experimentales y los estimados por la SVM, demuestran la fiabilidad del enfoque propuesto, abriendo así un camino hacia el control en línea del proceso FSW a partir de las señales vibro-acústicas y de temperatura, como línea de continuidad para futuras investigaciones.

ABSTRACT:

This research focuses on the modelling of the friction stir welding (FSW) process using vibro-acoustic and temperature signals. To this end, a predictive model based on Support Vector Machines (SVM) was developed, capable of accurately estimating weld quality across diverse joint configurations. This capability is founded on a comprehensive training dataset of aluminium-aluminium and aluminium-stainless steel joints, which were characterised using concurrently recorded acoustic emission and temperature signals. The selection and understanding of the model's input variables - process parameters and general joint characteristics - was performed using an analysis with decision tree algorithms. This analysis, along with the optimisation of the SVM hyperparameters, was fundamental to the model's development. The results from the comparison between experimental data and those estimated by the SVM demonstrate the reliability of the proposed approach, thus opening a path towards on-line control of the FSW process based on vibro-acoustic and temperature data, as a direction for future research.

1. INTRODUCCIÓN

La aplicación de técnicas de inteligencia artificial para la monitorización y el control de robots en la soldadura industrial es un campo de investigación reciente y en continua evolución. Dado el papel cada vez más relevante de los procesos de soldadura en la producción industrial, la inteligencia artificial ha comenzado a aplicarse en todas las etapas de estos procesos (1). Paralelamente a esta tendencia, han surgido y se han consolidado nuevas técnicas de unión, como la soldadura por fricción-agitación, de aquí en adelante FSW por sus siglas en inglés.

En términos generales, las características inherentes del proceso FSW lo distinguen notablemente de los métodos de soldadura convencionales, ofreciendo una serie de ventajas que lo posicionan favorablemente para la investigación en monitorización y control. Entre estas ventajas se incluyen alta precisión, versatilidad y facilidad de automatización (2). No obstante, su aceptación en el ámbito industrial sigue siendo limitada. En este escenario, la aplicación de métodos de ensayo no destructivos, como las emisiones acústicas y la termografía, ofrecen una oportunidad para controlar y asegurar la calidad del proceso, contribuyendo con ello a la mejora en la productividad.

Si bien la monitorización de procesos de soldadura mediante técnicas de emisión acústica (EA) o análisis de temperatura no es novedosa individualmente, su combinación sinérgica para aumentar la fiabilidad de los resultados constituye un enfoque menos explorado. Históricamente, la literatura científica registra el uso de EA para monitorizar procesos FSW desde principios de

la década del 2000 (3). De igual manera, la monitorización de la temperatura en FSW se ha aborda usando diversas metodologías, como termometría con termopares, simulaciones numéricas, medición inalámbrica y análisis mediante cámaras termográficas (4). Sin embargo, hasta donde se conoce, no hay evidencias claras de la implementación simultánea y combinada de ambas técnicas para la monitorización del proceso FSW.

Investigaciones previas, como las realizadas por Macías et al (5), abordan las señales de EA aplicadas a la monitorización del proceso FSW mediante la transformada Wavelet, obteniendo información sobre cambios bruscos al contacto herramienta-metal y concluyendo sobre la posibilidad de prever la calidad del proceso. Complementariamente, otros trabajos resaltan la importancia crucial de la temperatura, en particular la temperatura en el núcleo formado la zona de fusión y la zona afectada térmicamente, para determinar la calidad de este proceso.

A pesar de estos avances en la monitorización directa mediante EA y temperatura, un desafío persistente en la técnica de FSW es la definición óptima de los parámetros de proceso, dada su aplicabilidad a una amplia variedad de materiales. En este contexto, las técnicas de inteligencia artificial (IA) han emergido con uno de los principales métodos para resolver esta incógnita, mientras que las EA y la temperatura se emplean como mecanismos complementarios para validar la idoneidad de las configuraciones. Siguiendo esta línea, el trabajo realizado por Okuyucu et al. (6) fue pionero en la aplicación de IA para el modelado del proceso FSW, empleando velocidades de avance y rotación como entradas del modelo para predecir las propiedades mecánicas de la unión.

Posteriormente, un trabajo similar fue llevado a cabo por Verma et al. (7). En este caso el modelo resultante permite predecir la resistencia a la tracción que es capaz de soportar la unión a partir de los parámetros del proceso. Para ello, los autores se apoyan en un modelo de regresión con Proceso Gaussianos (GPR). Los resultados alcanzados demuestran una alta correlación entre los valores experimentales y los calculados por la inteligencia artificial.

Heidarzadeh et al. (8), por su parte, demostraron la eficacia de la lógica difusa para predecir tanto la resistencia a la tracción como la elongación en una unión soldada de cobre mediante fricción-agitación. Para ello consideraron como variables de entrada las velocidades de rotación y avance de la máquina y la fuerza axial.

Paralelo a esto, Song et al. (9) aplicaron redes neuronales en soldaduras disímiles de Al/Mg para modelar la relación entre las velocidades de avance y rotación de la máquina y la resistencia a tracción. En su estudio, los autores optimizaron el modelo mediante la implementación del algoritmo Grey Wolf Optimizer (GWO), lo que permitió predecir los parámetros óptimos del proceso.

Y la lista de trabajos relacionados continua. De hecho, existen investigaciones que predicen la aparición o no de defectos tipo “agujero de gusano” en la unión a partir de los parámetros del proceso (10,11) o imágenes de la superficie soldada (12). Sin embargo, todas ellas se central exclusivamente en el aluminio como material de estudio.

Del análisis anterior puede deducirse que son numerosos los trabajos que determinan la calidad de la unión soldada a partir de los parámetros predefinidos del proceso, basándose en la predicción de las propiedades mecánicas mediante IA. Sin embargo, ninguno considera los resultados de las técnicas no invasivas, como las EA y la termografía como entradas indirectas para entrenar modelos predictivos que, a su vez, ayuden a definir los parámetros que minimizan la aparición de defectos. Hasta el momento, ningún investigador ha explorado en profundidad la posibilidad de un modelo que, entrenado con parámetros del proceso (tanto óptimos como no óptimos), validados por métodos de ensayo no destructivos, sea capaz de predecir con fiabilidad la calidad de la unión soldada. El presente trabajo pretende abordar este vacío, ofreciendo una explicación detallada de la metodología y resultados obtenidos del procesamiento conjunto de las señales vibro-acústicas y de temperatura, así como de la implementación de un modelo de inteligencia artificial alimentado por estas.

La creación de un modelo de este tipo permitirá un enfoque innovador para la monitorización y el control de los parámetros del proceso FSW, a partir de mediciones obtenidas por métodos de inspección no destructivos. Esto, a su vez, impulsará la aceptación del proceso FSW en el ámbito industrial como un método de soldadura robusto y consistentemente libre de defectos.

2. MATERIALES Y MÉTODOS

A grandes rasgos, la metodología adoptada para alcanzar el propósito expuesto se articuló en torno a cuatro etapas principales: la realización de los ensayos experimentales, el procesamiento de las señales de EA, el análisis de los datos de temperatura y la implementación del modelo de inteligencia artificial. En este marco, el procesamiento de las señales de EA siguió el método descrito por Macías et al (5), por lo que se remite a dicho trabajo para una descripción exhaustiva. De manera análoga, para extraer información relevante de las señales de temperatura, se adoptó la metodología desarrollada por Lu et al (4). Dicho esto, la metodología incluye otros aspectos que se detallan en la siguiente sección. Entre ellos se incluyen la puesta a punto de la instalación experimental, la selección de los parámetros de proceso para la realización de los ensayos, la validación de estos parámetros basada en la información extraída de las señales de EA y temperatura, y la elección y entrenamiento del modelo de inteligencia artificial.

2.1. CONFIGURACIÓN EXPERIMENTAL

Para el desarrollo de la investigación se utilizaron tanto placas de aluminio AA6082T6 y AA5754 H111, con dimensiones de 600mm largo, 120mm de ancho y 3mm de espesor; como placas de acero inoxidable SS304L con características dimensionales idénticas, salvo por el espesor que fue 1.2mm. La selección de estos materiales responde a la tendencia de la industria de la automoción y, en particular del sector de los vehículos industriales, ambos con una relevancia destacada en el sector metalúrgico, hacia el uso de este tipo de materiales.

En la Figura 1 se muestra la configuración experimental utilizada para la ejecución de los ensayos.




Figura 1. Instalación experimental

En vista de la imagen, el proceso de soldadura se realizó empleando una máquina CNC con control simultáneo de desplazamiento y fuerza. Las probetas fueron fijadas a la bancada de la máquina con el auxilio de mordazas, y la dirección de soldadura fue la longitudinal. En concreto, se investigaron las siguientes configuraciones de unión:

- AA6082T6 y AA5754 H111 en configuración a solape
- AA5754 H111 y SS304L a solape, con la aleación de aluminio posicionada en la parte superior.

Para definir los límites de operación de los parámetros del proceso, se realizó un estudio variando sistemáticamente la velocidad de rotación, la velocidad de avance y la fuerza de consigna para cada configuración de unión. Cada experimento se repitió dos veces bajo idénticas condiciones para minimizar el error. La Tabla 1 detalla los límites inferior y superior considerados para las variables en cada configuración.

Tabla 1. Parámetros de la soldadura por fricción-agitación por configuración

Parámetro	AA6082T6 - AA5754 H111			AA5754 H111 - SS304L		
	Nivel Inferior	Nivel Central	Nivel Superior	Nivel Inferior	Nivel Central	Nivel Superior
Velocidad de rotación, rpm	1000	-	3500	-	1800	-
Avance, mm/min	600	-	3000	150	-	300
Fuerza kN	4.7	-	7.3	2.7	-	5.5

Todos los experimentos se realizaron utilizando la misma geometría de herramienta, en concreto una cuya longitud del pin es 3.5mm. En lo que respecta a la adquisición de las señales de EA y temperatura, las primeras se recogieron en las direcciones Z y X, tal como se aprecia en la Figura 1. Para ello, se emplearon como sensores dos acelerómetros piezoeléctricos colocados en el extremo de la probeta y un micrófono ubicado en el propio cabezal. Los acelerómetros se posicionaron perpendicularmente a la superficie superior de la placa situada en la parte más alta, y se fijaron a ella mediante un acoplamiento roscado. El micrófono, por su parte, se montó en el cabezal mediante un brazo articulado. Para el control de la temperatura, se utilizó una cámara térmica infrarroja, que también fue fijada al cabezal con otro brazo articulado.

2.2. PROCESAMIENTO DE LAS SEÑALES DE EMISIÓN ACÚSTICA

Una tarea crítica en el procesamiento de señales de EA es la selección de un rango de frecuencias adecuado que proporcione información relevante sobre el proceso. En este sentido, el primer paso fue identificar los rangos de frecuencia inherentes tanto al entorno como al ruido generado por el movimiento de la máquina, para excluirlas del análisis.

Como técnica para ello, se empleó la transformada Wavelet (Discrete Wavelet Transform, DWT), en concreto las Daubechies wavelets de orden 5. Este enfoque permitió descomponer las señales en diferentes escalas, facilitando con ello la distinción entre las bandas de frecuencia que son inútiles (ruido) y las que brindan información sobre el proceso.

En términos generales, la transformada wavelet se inicia con el paso de la señal de EA a través a través de una serie de filtros de paso-bajo, que captura información sobre las tendencias generales, y paso-alto, enfocados a identificar picos transitorios. Cada vez que la señal pasa a través de uno de estos filtros, la resultante se sub-muestrea por un factor de 2. Esto permite la descomposición de la señal, que puede expresarse matemáticamente como se muestra en (1) y (2):

$$y_{high}[k] = \sum_n x[n] \cdot g[2k - n] \quad (1)$$

$$y_{low}[k] = \sum_n x[n] \cdot h[2k - n] \quad (2)$$

Donde $y_{high}[k]$ y $y_{low}[k]$ son las entradas de los filtros de paso-alto y paso-bajo, respectivamente, tras el sub-muestreo por un factor de 2.

De la aplicación de la DWT se obtienen las señales D1-D5, que se corresponden con las bandas de frecuencia [250, 500 kHz], [125, 250 kHz], [62.50, 125 kHz], [31.25, 62.50 kHz] y [15.63, 31.25 kHz], respectivamente. A partir de estos resultados, se calcula la energía contenida en cada banda como la suma de los cuadrados de sus valores aplicando la siguiente expresión matemática (3):

$$E_{Dn} = \sum_k |D_n(k)|^2 \quad (3)$$

Con la ayuda de la técnica explicada anteriormente, se llevó a cabo una clasificación de las uniones soldadas como defectuosas y no defectuosas. Esta clasificación se realizó a partir de la identificación de ciertos tipos de eventos, en base al análisis de los cambios en la distribución de energía a lo largo de las bandas wavelet. Hecho esto, para extraer información relevante sobre los parámetros de proceso seleccionados, se comparó la distribución de energía en las distintas bandas para diferentes parámetros entre configuraciones de unión idénticas. Las inferencias derivadas de este análisis se utilizaron para generar datos del proceso sintéticos. Este enfoque permitió expandir significativamente el conjunto de datos de entrenamiento, con el objetivo de proporcionar una base más sólida para el modelo de inteligencia artificial.

2.3. PROCESAMIENTO DE LA TEMPERATURA SUPERFICIAL DE LA UNIÓN

A continuación se muestra la metodología empleada para verificar que las uniones previamente clasificadas, a partir de las señales EA como defectuosas o no defectuosas, coinciden con la etiqueta asignada. Para ello, se partió de la señal de temperatura registrada por la cámara (véase Figura 2).



Figura 2. Temperatura registrada por la cámara durante la ejecución del proceso

Como paso inicial, se ajustó la salida de la cámara alineando sus lecturas con las mediciones de un termopar ubicado en una zona específica de la probeta. Este procedimiento permitió el ajuste fino del equipo, garantizando que sus lecturas reflejaban con exactitud las temperaturas reales. Posteriormente, se empleó como método la correlación de la temperatura superficial registrada con la temperatura del núcleo para validar la clasificación de las uniones. Para ello se desarrolló tomando como base un modelo de simulación similar al propuesto por Lu et al (13), al cual se hace referencia para una explicación más detallada. El proceso continuó introduciendo en el modelo la geometría de la herramienta y las propiedades características de los materiales estudiados en la investigación. Ajustado este, se procedió a calcular los datos de temperatura en el núcleo a partir de datos de temperatura superficial en 35 puntos específicos de la unión para cada experimento.

Con el objetivo de discernir entre uniones defectuosas y no defectuosas, se compararon las temperaturas calculadas por el modelo con el rango de temperatura de soldadura correspondiente a los materiales estudiados. Como criterio para considerar si la unión era defectuosa o no, se estableció que la temperatura en el núcleo debía encontrarse dentro de ese rango para considerarse válida. Esta hipótesis permitió generar un resultado con el que validar las etiquetas asignadas previamente a las uniones basándose en las señales de EA.

2.4. MODELO DE INTELIGENCIA ARTIFICIAL

Para abordar la previsión de la calidad, la investigación se apoya en un modelo de IA, que a partir de los parámetros de proceso puede predecir la calidad final de la unión. En concreto, para el

desarrollo de la investigación se seleccionó una Máquina de Vectores de Soporte (SVM), vistos los buenos resultados obtenidos con problemas similares en investigaciones previas (4,7,12,14).

En esencia, el modelo seleccionado se basa en encontrar una frontera de decisión, llamada hiperplano, que separe los diferentes datos en clases, en el caso del presente trabajo: uniones defectuosas y no defectuosas. Tal frontera se define de manera que se maximice el margen de separación entre los puntos de datos más cercanos de cada clase. Este problema se resuelve utilizando técnicas de programación cuadrática.

Si bien el principio de funcionamiento es simple, en la práctica los datos rara vez son separables de manera lineal. A menudo existe solapamiento entre las clases, además de puntos que únicamente generan ruido en la clasificación. Para enfrentar este desafío, se experimentó con algoritmos del tipo “árboles de decisión”, “bosques aleatorios” y “gradient boosting”, con el objetivo de identificar aquellos parámetros del proceso y características de los casos analizados que más influyen en la determinación de si las uniones son defectuosas o no. Una vez conocida esta información, se experimentó con varias topologías de SVM, variando el tipo de hiperplano que separa los datos en clases y ajustando la configuración de hiperparámetros. El objetivo era seleccionar la opción que aportara el menor error en la predicción de la calidad de la unión.

En total, 57 configuraciones diferentes de parámetros del proceso por cada tipo de unión, junto con su respectiva salida (unión “OK” o “NOK”), fueron empleados para el ajuste y entrenamiento del modelo; mientras que otras 16 para validar su desempeño.

Tras examinar el comportamiento de las diferentes configuraciones, mediante indicadores de rendimiento, se seleccionó aquella que presentó los mejores resultados. Posteriormente, 8 datos de prueba adicionales fueron introducidos al modelo final para evaluar su capacidad de predecir la calidad de las uniones. Con los resultados obtenidos, se procedió al cálculo de las métricas de desempeño.

3. RESULTADOS

Esta sección presenta los principales resultados que demuestran el potencial de la inteligencia artificial para evaluar la calidad de las uniones en el proceso FSW, basándose en los parámetros del propio proceso.

3.1. CARACTERIZACIÓN DE LAS UNIONES A PARTIR DE LAS SEÑALES DE EA Y TEMPERATURA

En líneas generales, la clasificación de las uniones en defectuosas y no a partir de las señales de EA y temperatura desempeña un papel determinante en la obtención del modelo de IA.




Figura 3: (a) Señal temporal de EA (izquierda) y salida instantánea de la cámara térmica (derecha); (b) resultado del proceso FSW

La Figura 3.a muestra el gráfico de la señal de EA y la salida de la cámara térmica, capturada en el momento en que la herramienta está en el punto medio de la unión completa, correspondiente al experimento con velocidad de rotación igual a 450 rpm, velocidad de avance 40 mm/min y fuerza 5 kN. La Figura 3.b, por su parte, ilustra la unión soldada resultante de emplear los parámetros mencionados y que dio lugar a las señales de EA y temperatura mostradas.

Mientras que la eliminación del ruido constituyó el primer paso del procesamiento de las señales acústicas, que se realizó como se indicó en la sección previa; para la salida de la cámara térmica lo primero fue extraer las mediciones de temperatura siguiendo el método descrito previamente. Como resultado de ello, se obtuvieron por un lado series de señales temporales para distintas bandas de frecuencias, en concreto las definidas en la sección anterior, y valores puntuales de temperatura correspondientes a las ubicaciones especificadas. En la Figura 4 se muestran los gráficos obtenidos como resultado de la aplicación de la DWT a la señal de EA mostrada en la Figura 3.a.




Figura 4. Transformada wavelet de las bandas de frecuencia seleccionadas

Este proceso se repitió con cada uno de los experimentos realizados. Para clasificar las uniones como defectuosas o no defectuosas, se analizaron primero los datos mostrados en la Figura 4, calculando la energía contenida en cada banda de frecuencia, tal como se indica en la sección 2.2. Como resultado de ello, se obtuvieron una serie de gráficos que se consolidaron en una única representación, tal como se muestra en la Figura 5 para tres experimentos distintos para una mejor visualización.




Figura 5. Comparativa de la energía contenida en cada banda para tres experimentos

Los experimentos se clasificaron a partir de la comparación de estos datos. Para reforzar la confianza en estos resultados, se procedió a introducir los datos de temperatura superficial registrados al modelo de simulación (sección 2.3). Mediante este proceso se calculó la temperatura en el núcleo de la soldadura en los puntos de interés. La consistencia y validez de las clasificaciones asignadas se confirmó al verificar si la temperatura obtenida se encontraba o no dentro del rango de temperatura de soldadura del material, tal como se describe en el apartado 2.3.

En total, y tras una doble verificación con métodos de inspección distintos, se confirmó que, para la configuración AA6082T6 - AA5754 H111, 22 de las 52 uniones ejecutadas estaban libres de defectos. En el caso de la configuración AA5754 H111 - SS304L, 3 de 10 uniones resultaron sin defectos.

3.2. SELECCIÓN DE LAS VARIABLES DE ENTRADA AL MODELO

La SVM requiere fijar una frontera de decisión óptima antes de que pueda ser empleada para el objetivo establecido. Para ello, es importante analizar los parámetros de proceso y características de las configuraciones estudiadas que permiten calcular el hiperplano que maximiza la distancia entre los puntos pertenecientes a las distintas categorías: unión defectuosa y no defectuosa.

Los árboles de decisión y algoritmos similares, como los “bosques aleatorios” y el “gradient boosting”, constituyen un método eficaz para identificar que subconjuntos de datos son los que ejercen una mayor influencia sobre la clase resultante. Para ello, dichos algoritmos buscan los subconjuntos de datos que son más homogéneos en función de la clase a la que pertenecen. En la Figura 6 se muestra los parámetros de proceso y las características de material más relevantes en la calidad de la unión para la configuración AA6082T6 - AA5754 H111 según los algoritmos mencionados.




Figura 6. Evaluación de las entradas más significativas para el modelo

Como puede apreciarse, el parámetro de proceso que más influye sobre la calidad de la unión es la velocidad de rotación de la herramienta. Por contra, en lo que respecta a las características de los casos estudiados, existen discrepancias en los resultados. Mientras que el árbol de decisión identifica como variables secundarias más relevantes el límite elástico del material y el espesor a soldar, el análisis con el método "bosque aleatorio" señala que las segundas variables más influyentes son la velocidad de avance y, nuevamente, el espesor del material. Por su parte, el "gradient boosting" destaca como factores determinantes el límite elástico y el ángulo de la herramienta.

Considerando estos resultados y la repetición de ciertas variables en los distintos análisis, se decidió seleccionar la velocidad de rotación de la máquina, el límite elástico del material y el espesor a soldar para el entrenamiento de la SVM.

Con base en esto, se amplió la muestra de entrenamiento mediante la generación de datos sintéticos. Esto se realizó a partir de las inferencias derivadas del análisis de las señales de EA. Como resultado, se generaron 19 nuevos conjuntos de datos, basándose en los patrones observados en las 62 uniones distintas que se extrajeron de los ensayos realizados. Del total de la muestra, que incluye tanto datos reales como sintéticos, el 70% (57) se emplearon para el

entrenamiento de la SVM y el 30% restante (24) para la validación y prueba final del modelo de inteligencia artificial.

3.3. ENTRENAMIENTO DE LA SVM

El entrenamiento de la Máquina de Vectores de Soporte se llevó a cabo de manera supervisada y empleando un método de búsqueda en cuadrícula para el ajuste de los hiperparámetros. En concreto, los experimentos fueron llevados a cabo utilizando un C (parámetro de regularización) en el rango de [0, 10] y los kernel lineal, RBF y polinomial.

En la Figura 7 se observa el resultado del proceso de ajuste para un C igual a 1.0 y un kernel del tipo lineal, con las entradas definidas en la sección 3.2. En ella puede apreciarse que los hiperparámetros considerados conducen a una separación casi perfecta de los datos. Además, y debido a la simplicidad de la función de separación, el tiempo de procesamiento resulta mínimo.




Figura 7. Frontera de decisión de la SVM seleccionada

La Tabla 1 presenta el análisis comparativo de los resultados obtenidos para cada una de las combinaciones evaluadas. Tal como se muestra en ella, se analizaron 9 topologías diferentes de SVM, resultantes de combinar 3 valores posibles de C con 3 tipos diferentes de kernel. Los resultados de la evaluación demuestran que la SVM lineal con C igual 1.0 ofrece el compromiso óptimo entre precisión en las predicciones y tiempo de cálculo del modelo. Teniendo esto en cuenta, se eligió dicha topología para el desarrollo y la validación del modelo, utilizando para este propósito los 8 datos de prueba adicionales no empleados hasta el momento.

Tabla 2. Análisis comparativo entre varias topologías de SVM

Kernel	C	Precisión	Tiempo medio de cálculo (ms)
Lineal	0.1	77.2%	0.046
	1.0	77.3%	0.045
	10	77.2%	0.046
RBF	0.1	72.7%	0.046
	1.0	72.7%	0.045
	10	72.7%	0.055
Polinomial (grado 3)	0.1	72.7%	tiempo real
	1.0	72.7%	tiempo real
	10	68.2%	0.045

Los resultados obtenidos demuestran que con la topología seleccionada se puede alcanzar un nivel de precisión superior al 75% en la predicción, a partir del procesamiento offline de señales de EA y temperatura. Es importante destacar que el uso de un kernel más complejo puede traer como consecuencia un aumento significativo del tiempo de cálculo, generando retrasos en la toma de decisiones. Este aspecto supone un inconveniente si el modelo se emplea para la monitorización y control en tiempo real del proceso FSW.

Volviendo la vista a la Figura 7, se destaca un error de estimación mínimo en la calidad de las uniones. Este resultado corrobora la capacidad de las Máquinas de Vectores de Soporte para modelar de manera precisa el proceso FSW y, por tanto, ser empleadas en futuras investigaciones centradas en el control de la soldadura a partir de las mediciones de las señales de EA y temperatura generadas durante su ejecución.

4. CONCLUSIONES

En términos generales, el estudio realizado demuestra la viabilidad de aplicar técnicas de inteligencia artificial para el control de la calidad en el proceso FSW. El fundamento de esta aproximación reside en un nuevo modelo, basado en Máquina de Vectores de Soporte que, a partir de los parámetros del proceso y de características generales de la unión, es capaz de predecir la calidad de la soldadura. Dicho modelo se fundamenta en un conjunto de uniones caracterizadas a partir de las señales de EA y temperatura generadas durante su ejecución, que son la base de su propuesta de valor.

Los resultados alcanzados confirman la capacidad de este método para anticipar defectos en diferentes configuraciones de unión, específicamente en uniones aluminio-aluminio y aluminio-acero inoxidable, alcanzando una tasa de acierto superior al 75%. Esta precisión se apoya, en parte, en una serie de parámetros concretos que, mediante el análisis con algoritmos del tipo árboles de decisión, se han identificado que influyen de manera significativa en la predicción de la calidad y que son la velocidad de rotación de la máquina, el límite elástico del material y el espesor a soldar. Por otro lado, el entrenamiento basado en el procesamiento de las señales de EA en rangos de frecuencia específicos, junto con el análisis de las señales de temperatura mediante simulación, refuerza la utilidad de esta información para la detección temprana de defectos.

En definitiva, la presente investigación no solo establece un nuevo enfoque no destructivo para modelar el proceso FSW y predecir la calidad sin inferir en la operación, sino que también sienta las bases para la monitorización y el control en línea del proceso. Esta perspectiva se apoya en el potencial del análisis conjunto y en tiempo real de las señales de EA y temperatura, abriendo así un camino prometedor hacia la adopción industrial generalizada de la FSW como una técnica de soldadura consistentemente libre de defectos.

AGRADECIMIENTOS

Esta investigación está soportada por el proyecto STWIN, GA 101112504. Proyecto financiado por la Comisión Europea dentro del Programa *Research Fund for Coal & Steel* (RFCS).

REFERENCIAS

1. Eren B, Demir MH, Mistikoglu S. Recent developments in computer vision and artificial intelligence aided intelligent robotic welding applications. *Int J Adv Manuf Technol* [Internet]. 2023 Jun 3;126(11–12):4763–809. Available from: <https://link.springer.com/10.1007/s00170-023-11456-4>
2. Akinlabi ET, Mahamood RM. Introduction to Friction Welding, Friction Stir Welding and Friction Stir Processing BT - Solid-State Welding: Friction and Friction Stir Welding Processes. In: Akinlabi ET, Mahamood RM, editors. Cham: Springer International Publishing; 2020. p. 1–12. Available from: https://doi.org/10.1007/978-3-030-37015-2_1
3. Chen C, Kovacevic R, Jandgric D. Wavelet transform analysis of acoustic emission in monitoring friction stir welding of 6061 aluminum. *Int J Mach Tools Manuf* [Internet]. 2003 Oct;43(13):1383–90. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0890695503001305>
4. Lu X, Sun Z, Luan Y, Teng L, Liang SY. Temperature monitoring system of friction stir welding based on digital twin. *Int J Comput Integr Manuf* [Internet]. 2024 Aug 2;37(8):987–1002. Available from: <https://www.tandfonline.com/doi/full/10.1080/0951192X.2023.2278113>
5. Macías EJ, Roca AS, Fals HC, Fernández JB, Muro JCSD. Emisión Acústica y Redes Neuronales para Modelado y Caracterización del Proceso de Soldadura por Fricción Agitación. *Rev Iberoam Automática e Informática Ind RIAI* [Internet]. 2013 Oct;10(4):434–40. Available from: <https://polipapers.upv.es/index.php/RIAI/article/view/9501>
6. Okuyucu H, Kurt A, Arcaklioglu E. Artificial neural network application to the friction stir welding of aluminum plates. *Mater Des* [Internet]. 2007 Jan;28(1):78–84. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0261306905001597>
7. Verma S, Gupta M, Misra JP. Performance evaluation of friction stir welding using machine learning approaches.

MethodsX [Internet]. 2018;5(September):1048–58. Available from: <https://doi.org/10.1016/j.mex.2018.09.002>

8. Heidarzadeh A, Testik ÖM, Gülerüz G, Barenji RV. Development of a fuzzy logic based model to elucidate the effect of FSW parameters on the ultimate tensile strength and elongation of pure copper joints. *J Manuf Process* [Internet]. 2020 May;53:250–9. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1526612520301006>
9. Song Q, Wang H, Ji S, Ma Z, Jiang W, Chen M. Improving joint quality of hybrid friction stir welded Al/Mg dissimilar alloys by RBFNN-GWO system. *J Manuf Process* [Internet]. 2020 Nov;59:750–9. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1526612520307052>
10. Boldsaikhan E, Corwin EM, Logar AM, Arbogast WJ. The use of neural network and discrete Fourier transform for real-time evaluation of friction stir welding. *Appl Soft Comput* [Internet]. 2011 Dec;11(8):4839–46. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1568494611002559>
11. Du Y, Mukherjee T, DebRoy T. Conditions for void formation in friction stir welding from machine learning. *npj Comput Mater* [Internet]. 2019;5(1):1–8. Available from: <http://dx.doi.org/10.1038/s41524-019-0207-y>
12. Sudhagar S, Sakthivel M, Ganeshkumar P. Monitoring of friction stir welding based on vision system coupled with Machine learning algorithm. *Meas J Int Meas Confed* [Internet]. 2019;144(2019):135–43. Available from: <https://doi.org/10.1016/j.measurement.2019.05.018>
13. Lu X, Qiao J, Qian J, Sun S, Liang SY. Welding Parameters Optimization in Plunging and Dwelling Phase of FSW Medium Thickness 2219 Aluminum Alloy [Internet]. 2021. Available from: <https://www.researchsquare.com/article/rs-1131926/v1>
14. Das B, Pal S, Bag S. Torque based defect detection and weld quality modelling in friction stir welding process. *J Manuf Process* [Internet]. 2017;27:8–17. Available from: <http://dx.doi.org/10.1016/j.jmapro.2017.03.012>