

CIATEQ, A. C. Centro de Tecnología Avanzada
Dirección de Posgrado



*PREDICCIÓN DE PENETRACIÓN DE SOLDADURA GMAW CON
ALGORITMOS DE INTELIGENCIA ARTIFICIAL*

TESIS QUE PRESENTA

Ing. Bruno Díaz Silva
Asesoras: Dra. Maricruz Hernández Hernández
Dra. Carolina Reta Castro

Para obtener el grado de

Maestría en
Manufactura Avanzada

San Luis Potosí, San Luis Potosí
julio, 2021

CARTA DE LIBERACIÓN DEL ASESOR



San Luis Potosí, SLP, 18 de enero de 2021.

Mtro. Geovany González Carlos
Coordinador Académico de Posgrado
CIATEQ, A.C.

La abajo firmante, miembro del Comité Tutorial del Ing. Bruno Díaz Silva, una vez revisado su Proyecto Terminal de tesis, titulado "PREDICCIÓN DE PENETRACIÓN DE SOLDADURA GMAW CON ALGORITMOS DE INTELIGENCIA ARTIFICIAL" **autorizo** que el citado trabajo sea presentado por el alumno para su revisión, con el fin de alcanzar el grado de **Maestría en Manufactura Avanzada**.

Sin otro particular por el momento, agradezco la atención prestada.

A handwritten signature in blue ink, appearing to read 'Maricruz #', is positioned above a horizontal line.

Dra. Maricruz Hernández Hernández
Adscrita a COMIMSA
Asesora Académica





Pachuca, Hidalgo, 18 de enero de 2021.

Mtro. Geovany González Carlos
Coordinador Académico de Posgrado
CIATEQ, A.C.

La abajo firmante, miembro del Comité Tutorial del Ing. Bruno Díaz Silva, una vez revisado su Proyecto Terminal de tesis, titulado "PREDICCIÓN DE PENETRACIÓN DE SOLDADURA GMAW CON ALGORITMOS DE INTELIGENCIA ARTIFICIAL" autorizo que el citado trabajo sea presentado por el alumno para su revisión, con el fin de alcanzar el grado de **Maestría en Manufactura Avanzada**.

Sin otro particular por el momento, agradezco la atención prestada.

A handwritten signature in blue ink, appearing to read 'Carolina Reta Castro', is written over a horizontal line.

Dra. Carolina Reta Castro
Co-asesora Académica



CARTA DE LIBERACIÓN DEL REVISOR

Zapopan, Jalisco, 27 de Mayo del 2021.

Dra. María Guadalupe Navarro Rojero
Directora de Posgrado
CIATEQ, A.C.

Por medio de la presente me dirijo a usted en calidad de Revisor del proyecto terminal del (la) alumno (a) **Bruno Díaz Silva**, cuyo título es:

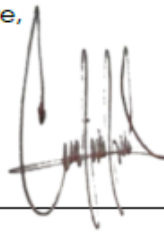
“PREDICCIÓN DE PENETRACIÓN DE SOLDADURA GMAW CON ALGORITMOS DE INTELIGENCIA ARTIFICIAL”

Después de haberlo leído, corregido e intercambiado información con el (la) alumno(a), y realizado los cambios que le fueron sugeridos, puede ser autorizada su impresión, a fin de que se inicien los trámites correspondientes para su defensa.

Sin otro particular por el momento, y en espera de que mis sugerencias sean tomadas en cuenta en beneficio del estudiante y la Institución, agradezco la atención prestada.

Atentamente,

Firma



Dr. Caín Pérez Wences

DEDICATORIA

A mi esposa Carolina por todo su apoyo, cariño y consejos durante este proceso.

A mis padres y hermano que a lo largo de mi carrera siempre han estado ahí para apoyarme.

A Fausto por brindarme siempre su amistad y soporte.

A la Dra. Maricruz y a la Dra. Carolina por su guía, enseñanza y paciencia.

AGRADECIMIENTOS

A la empresa [REDACTED] San Luis Potosí por el apoyo brindado para realizar este proyecto de investigación; a Manuel Vazquez y el equipo de ingeniería de Manufactura por su apoyo durante la realización de este proyecto; a todo el personal del posgrado en Manufactura Avanzada de CIATEQ por la paciencia, soporte y apoyo durante todo el proceso de mi formación; a mis asesoras la Dra. Maricruz Hernández y a la Dra. Carolina Reta por todo el compromiso y apoyo otorgado a lo largo de esta investigación; finalmente a mis compañeros y amigos que he conocido a lo largo de este posgrado y que han sido siempre abiertos para compartir el conocimiento la experiencia.

Bruno Díaz Silva

San Luis Potosí, SLP

Diciembre del 2020

* * *

RESUMEN

En el proceso de soldadura GMAW (Gas Metal Arc Welding), la dimensión de la penetración de soldadura está directamente relacionada con las variables de entrada, tales como: corriente base, corriente de salida, tiempo de impulso, voltaje, velocidad de alimentación de alambre, frecuencia y velocidad de soldadura. El problema que presenta la compañía es el desconocimiento de las variables que afectan el proceso de soldadura y la geometría del perfil transversal de la junta soldada. Esta falta de conocimiento afecta durante el desarrollo del producto: en la cantidad de chatarras de prueba generadas durante dicha fase y en la generación de tiempo muerto excesivo durante cada prueba. Esto resulta en el incremento de costos para las fases de desarrollo de producto e incluye los costos asociados por la generación de chatarra al realizar las pruebas destructivas cada vez que se realiza la medición del perfil transversal de soldadura.

En este trabajo de investigación se evalúa el desarrollo de once algoritmos de aprendizaje automático e inteligencia artificial (*Regresión lineal, Random Forest, Ibk M5 Rules, Multilayer Perceptron, Bagging, Random Subspace, Rep Tree, Gaussian Processes, SMOReg, LWL y Decision Table*) con la finalidad de predecir la penetración de soldadura en los rines de acero. El resultado de la investigación muestra que los algoritmos *SMOReg* y *Linear regression* obtuvieron coeficientes de correlación de 0.86 y 0.84 para la dilución de soldadura, además de obtener valores de 0.80 para las características de Penetración en disco en eje X y Penetración en aro. De acuerdo con los modelos de regresión generados, las variables que tienen mayor efecto en la penetración de soldadura son: Voltaje de salida, Corriente de salida y Velocidad de alimentación de alambre. Los modelos desarrollados permitieron establecer los parámetros de soldadura para reducir el tiempo y la chatarra generada en la fase de desarrollo; también proporcionan una solución para evaluar la calidad de la junta soldada sin destruir la pieza.

Palabras clave: Ingeniería y tecnología; Ingeniería de los ordenadores; Aprendizaje automático; GMAW; Dilución de soldadura; Penetración de soldadura; SMOReg, Regresión lineal.

ABSTRACT

In the GMAW (Gas Metal Arc Welding) welding process, the weld penetration dimension is directly related to the input variables, such as base current, output current, impulse time, voltage, wire feed speed, frequency, and welding speed. The company's problem is the unawareness of the variables that affect the welding process and the geometry of the welded joint's cross-sectional profile. This lack of knowledge affects product development in the amount of test scraps generated during this phase and in the generation of excessive downtime during each test. This results in increased costs for the product development phases, including scrap generation costs when performing destructive tests each time the weld cross-section measurement is performed.

This research work evaluates the development of eleven machine learning and artificial intelligence algorithms (Linear Regression, Random Forest, Ibk M5 Rules, Multilayer Perceptron, Bagging, Random Subspace, Rep Tree, Gaussian Processes, SMOReg, LWL, and Decision Table) in order to predict weld penetration on steel wheels. The result of the investigation shows that the SMOReg and Linear regression algorithms obtained correlation coefficients of 0.86 and 0.84 for the weld dilution, in addition to obtaining values of 0.80 for the characteristics of disc penetration on axis X and Rim Penetration. According to the generated regression models, the variables that have the most significant effect on weld penetration are: Output Voltage, Output Current, and Wire Feed Speed. The developed models make it possible to establish the welding parameters to reduce the time and scrap generated in the development phase; they also provide a solution to assess the quality of the welded joint without destroying the part.

Keywords: Technology and engineering; Computer engineering; Machine learning; GMAW; Welding dilution; Welding penetration; SMOReg, Linear regression.

ÍNDICE DE CONTENIDO

RESUMEN	vi
ABSTRACT	vii
ÍNDICE DE CONTENIDO	viii
ÍNDICE DE FIGURAS.....	xi
ÍNDICE DE TABLAS	xiii
GLOSARIO	xiv
1. INTRODUCCIÓN.....	1
1.1. ANTECEDENTES	1
1.2. DEFINICIÓN DEL PROBLEMA	2
1.3. JUSTIFICACIÓN	3
1.4. OBJETIVOS.....	5
1.4.1. Objetivo general.....	5
1.4.2. Objetivos específicos	5
1.5. HIPÓTESIS.....	6
2. MARCO TEÓRICO	7
2.1. PROCESO DE SOLDADURA GMAW	7
2.2. HISTORIA DEL PROCESO DE SOLDADURA.....	7
2.3. PRINCIPIOS BÁSICOS DEL PROCESO DE SOLDADURA	8
2.4 EQUIPO DE SOLDADURA GMAW.....	9
2.5 VARIABLES DEL PROCESO DE SOLDADURA	10
2.5.1 Corriente de soldadura.....	10
2.5.2 Polaridad.....	12
2.5.3 Voltaje de arco eléctrico	12
2.5.4 Longitud libre de electrodo de soldadura	13
2.5.5 Calor de entrada	14
2.5.6 Velocidad de avance	15
2.5.7 Velocidad de alimentación de alambre	15
2.5.8 Dilución de soldadura.....	16
2.5.9 Electrodo de soldadura	17
2.5.10 Metal base	17
2.5.11 Gases de soldadura	21
2.6 TRANSFERENCIA METÁLICA.....	24

2.7 PROCEDIMIENTO DE FABRICACIÓN.....	25
2.8 INSPECCIÓN DE PENETRACIÓN DE SOLDADURA	27
3. ANÁLISIS DE DATOS Y ALGORITMOS DE INTELIGENCIA ARTIFICIAL	31
3.1 DISEÑO DE EXPERIMENTOS.....	31
3.2 WEKA (WAIKATO ENVIROMMENT KNOWLEDGE ANALYZE).....	31
3.3 MODELOS DE REGRESIÓN EN WEKA	33
3.4 VALIDACIÓN DE MODELOS DE REGRESIÓN EN WEKA.....	43
3.5 MÉTRICAS DE EVALUACIÓN EN WEKA	43
3.6 ESTADO DEL ARTE	45
4. IMPLEMENTACIÓN DE ALGORITMOS	58
4.1 CONSTRUCCIÓN DE LA BASE DE DATOS	58
4.2 CÁLCULO DE CALOR DE ENTRADA.....	60
4.3 CÁLCULO DE DILUCIÓN DE SOLDADURA	61
4.4 ANÁLISIS DE LA BASE DE DATOS GLOBAL	64
4.4.1 Preprocesamiento de base de datos	65
4.4.2 Limpieza y filtrado de datos	67
4.4.3 Generación de modelos de regresión	69
4.5 ANÁLISIS DE LA BASE DE DATOS OPTIMIZADA	70
4.5.1 Preprocesamiento de base de datos optimizada.....	71
4.5.2 Limpieza y filtrado de datos de base optimizada.....	72
4.5.3 Generación de modelos de regresión a la base de datos optimizada ..	74
5. RESULTADOS	75
5.1 RESULTADO DE BASE DE DATOS GLOBAL.....	75
5.2 RESULTADOS DE BASE DE DATOS OPTIMIZADA.....	80
5.2.1 Modelo de dilución de soldadura	81
5.2.2 Modelo de penetración en disco en eje X.....	84
5.2.3 Modelo en penetración en aro	86
5.2.4 Análisis de las variables de soldadura de los modelos propuestos.....	88
5.2.5 Evaluación de algoritmos	88
5.3. DISCUSIÓN DE RESULTADOS.....	92
CONCLUSIONES	96
TRABAJO FUTURO	98
APORTACIÓN DE LA TESIS.....	99

APORTACIÓN SOCIAL DE LA TESIS.....	100
REFERENCIAS.....	101

ÍNDICE DE FIGURAS

Figura 1. Esquema de antorcha del proceso de soldadura GMAW	9
Figura 2. Componentes básicos de equipo de soldadura.....	10
Figura 3. Gráfica de correlación entre corriente eléctrica y velocidad de alimentación de alambre	11
Figura 4. Ecuación de calor de entrada de soldadura.....	14
Figura 5. Cálculo de dilución de soldadura conforme a AWS 3.0.....	16
Figura 6. Sistema de clasificación de electrodo GMAW	17
Figura 7. Transferencias metálicas básicas: (A) Globular (B) Spray (C) Corto Circuito (D) Pulsado.....	25
Figura 8. Componentes de fabricación de un rin.....	25
Figura 9. Proceso de fabricación de un rin de acero.....	26
Figura 10. Proceso de inspección de penetración de soldadura.....	27
Figura 11. Esquema de posición de cordones de soldadura.....	28
Figura 12. Esquema de cortes de soldadura.....	29
Figura 13. Cotas a dimensionar de perfil transversal de soldadura.....	30
Figura 14. Interfaz de clasificación de WEKA.....	32
Figura 15. Mapa de proceso de generación de base de datos.....	59
Figura 16. Mapa de proceso de soldadura.....	60
Figura 17. División de áreas de soldadura.....	62
Figura 18. Cálculo del área 1.....	62
Figura 19. Cálculo del área 2.....	63
Figura 20. Cálculo del área 3.....	64
Figura 21. Diagrama de flujo de evaluación de algoritmos.....	65
Figura 22. Descripción de la base de datos global.....	66
Figura 23. Tipos de valor en la base de datos	66
Figura 24. Visualización de datos NaN de la base de datos global.....	67
Figura 25. Descripción de base de datos posterior al filtrado.....	67
Figura 26. Visualización de los valores NaN posterior al filtrado.....	68
Figura 27. Resumen estadístico de base de datos optimizada.....	71

Figura 28. Visualización de los valores NaN antes del filtrado de la base optimizada..... 72

Figura 29. Visualización de los valores NaN posterior al filtrado de la base optimizada..... 72

Figura 30. Coeficiente de correlación en la base de datos global. 78

Figura 31. Gráfica de error medio absoluto en base de datos global..... 79

Figura 32. Gráfica de raíz cuadrada del error medio de la base de datos global. 79

Figura 33. Coeficiente de correlación de base de datos optimizada..... 80

Figura 34. Gráfico de dispersión de los valores reales vs valores predichos de dilución de soldadura..... 82

Figura 35. Gráfico de barras de los valores reales vs los valores predicho del modelo SMOReg para dilución de soldadura..... 83

Figura 36. Gráfico de barras de los valores reales vs los valores predicho del modelo SMOReg de penetración en disco en eje x. 85

Figura 37. Gráfico de dispersión de los valores reales vs los valores predicho de Pdx. 85

Figura 38. Gráfico de dispersión de los valores reales vs los valores predicho de penetración en aro..... 87

Figura 39. Gráfico de barras de los valores reales vs los valores predicho del modelo SMOReg de penetración en aro..... 87

Figura 40. Gráfica del Error Medio absoluto de la base optimizada..... 89

Figura 41. Gráfico de la Raíz Cuadrada del Error Medio de la base optimizada. .. 90

ÍNDICE DE TABLAS

Tabla 1 Tipos de acero según SAE.....	19
Tabla 2 Composición química de los aceros según SAE.....	20
Tabla 3 Propiedades mecánicas del acero SAE 1010.....	21
Tabla 4 Aplicaciones de mezcla de gas.....	23
Tabla 5 Abreviatura de penetración de soldadura.....	30
Tabla 6 Resumen de variables de entrada y salida de investigaciones en estado del arte.....	55
Tabla 6 Continuación de Tabla 6 de variables de entrada y salida de investigaciones en estado del arte.....	56
Tabla 7 Algoritmos o herramientas de análisis utilizados en cada investigación....	57
Tabla 8 Resumen estadístico de base de datos global.....	69
Tabla 9 Resumen estadístico de base de datos optimizada.....	73
Tabla 10 Abreviatura de los algoritmos.....	76
Tabla 11 Hiperparámetros utilizados en los algoritmos.....	77
Tabla 12 Abreviatura de variables de los modelos de soldadura obtenidos con su respectivo nombre.....	81
Tabla 13 Error porcentual entre valor estimado y valor real.....	91

GLOSARIO

Fa: Es la dimensión de la fusión en aro.

Fd: Es la dimensión de la fusión en disco.

G: Es la dimensión de la Garganta de soldadura.

GMAW: Gas Metal Arc Welding – Proceso de soldadura de arco eléctrico con atmósfera protegida

Pa: Es la dimensión de la penetración en aro.

Pdx: Es la dimensión de la penetración de soldadura en el disco con respecto al eje X.

Pdy: Es la dimensión de la penetración en disco en el eje

WPS: Welding Procedure Specification

ZAT: Es la zona que fue afectada térmicamente por el proceso de soldadura.

1. INTRODUCCIÓN

1.1. ANTECEDENTES

La industria 4.0 es un término utilizado en el mundo para reflejar el profundo cambio social que se está experimentando como parte de la implementación de las tecnologías emergentes en el sector industrial. A esta industria también se le conoce la cuarta revolución industrial; esta revolución tiene como tendencia la automatización y el intercambio de información relativa a la producción de manera sistemática y automática (Valera, y otros, 2017). Este intercambio de información se basa en la interconexión de cada una de las máquinas y sistemas con plataformas en la red, implementando diversas herramientas para la colección de datos, análisis de información y aplicaciones correctivas.

Una de las tecnologías y herramientas que más se están utilizando en la industria 4.0 es la inteligencia artificial, que es la ciencia computacional encargada de desarrollar modelos matemáticos capaces de analizar y estructurar la información para interpretarla correctamente (López Takeyas, 2015).

El coleccionar grandes cantidades de datos, analizar y detectar oportunidades en sistemas de información, automatizar toma de decisiones o identificar patrones e interdependencias para descubrir deficiencias en los procesos y predecir eventos futuros pueden ser logrados gracias a la aplicación de herramientas estadísticas de aprendizaje automático y redes neuronales (del Val Román, 2016). Los procesos de fabricación, como es el caso de los procesos de soldadura, han implementado las herramientas de adquisición de datos, aprendizaje automático y redes neuronales, con el propósito de predecir las dimensiones y condiciones de calidad en los procesos de soldadura (García Sánchez, 2009).

El proceso de soldadura GMAW ha sido parametrizado desde sus inicios a prueba y error, dependiendo del conocimiento del soldador para generar un cordón de soldadura de calidad.

La parametrización de este proceso actualmente se realiza de forma empírica, realizando pruebas para ajustar el proceso y evaluando diversas condiciones. Este procedimiento incrementa el tiempo de desarrollo además de generar chatarra por cada prueba realizada. Además, para realizar la medición de la penetración del cordón de soldadura se requiere realizar un corte en el cordón de soldadura, posteriormente realizar el revelado y finalmente realizar la medición del perfil transversal. Este procedimiento es actualmente utilizado en la mayoría de las empresas que manejan el proceso de soldadura GMAW.

En esta investigación se analizará la aplicación de técnicas de análisis de información y aprendizaje automático para generar modelos de regresión para predecir la penetración de soldadura. La investigación tiene como finalidad conocer las variables de soldadura que tienen mayor influencia en la geometría del perfil transversal, así como evaluar métodos alternativos para calificar la calidad de la junta soldada sin necesidad de destruir la pieza.

1.2. DEFINICIÓN DEL PROBLEMA

Como parte de los requisitos para la evaluación de calidad de la junta soldada, la empresa realiza una prueba destructiva de los rines de acero. El procedimiento consiste en el corte de la pieza; posteriormente se prepara el cuerpo de prueba (revelación metalográfica); y finalmente se realiza un dimensionamiento del perfil geométrico de soldadura.

Este procedimiento se realiza en cada cambio de turno y liberación de la línea para cada una de las áreas de ensamble, generando costos por destrucción de piezas (chatarras); además de costos por entrenamiento de personal calificado, costo por tiempo muerto de preparación y liberación de soldadura, compra y mantenimiento de equipo y herramientas para la realización del procedimiento.

Cuando el ingeniero de soldadura y desarrollo de producto desea desarrollar un nuevo producto, todo el proceso de determinación de parámetros de soldadura es realizado de forma empírica, debido a que la interacción de las múltiples

variables de soldadura dificultan determinar las de mayor influencia en el dimensional de la penetración de la soldadura. Cada prueba destructiva que es realizada para la producción de rines genera chatarra y tiempo muerto, resultando en costos para la compañía.

En este proyecto se profundizará en nuevas técnicas para evaluar la geometría de la junta soldada sin necesidad de realizar pruebas destructivas para reducir los costos de calidad de la compañía. Las variables del proceso de soldadura GMAW serán utilizadas como variables de entrada y con ayuda de las técnicas de análisis de información se obtendrán modelos de predicción de cada una de las características de penetración de soldadura. Uno de los problemas principales para el desarrollo de los modelos de predicción es la variación de las variables del proceso de soldadura. Los datos son registrados de forma manual, teniendo como variable el factor humano; además son colectados de diversas máquinas de soldadura, teniendo como factor relevante el desgaste de los componentes.

1.3. JUSTIFICACIÓN

La soldadura es una característica de seguridad para cualquier construcción soldada que debe asegurar la integridad de la estructura. La forma de asegurar la integridad y calidad de soldadura es con base a los diseños de la junta; para ello existen normas de soldadura de acuerdo con criterios específicos de cliente.

Durante el desarrollo del producto, el ingeniero de soldadura y procesos es el encargado de definir los parámetros de soldadura que serán validados por las pruebas conforme a los requisitos específicos del cliente. El ingeniero desarrolla diversas pruebas para determinar los parámetros idóneos para que el proceso de soldadura sea estable, además de cumplir la penetración necesaria para cumplir la vida del producto.

Cada prueba que realiza el ingeniero se lleva a cabo de forma empírica utilizando corridas de evaluación a prueba y error para determinar los parámetros idóneos. Cada corrida genera tiempo muerto para producción porque requiere detener la

línea de producción, además de que cada pieza no conforme generada durante la prueba se convierte en chatarra. Esto representa pérdidas económicas significativas para la compañía, además de elevar los costos de desarrollo del producto.

Aunado a las pérdidas económicas generadas por el proceso de evaluación y desarrollo, en la compañía se está actualmente en el auge de la innovación tecnológica. Las ramas de la ciencia que se están aplicando en todo tipo de industrias actualmente son la inteligencia artificial y el aprendizaje automático, como herramientas prometedoras e innovadoras que pueden aplicarse para el análisis y predicción de información en el ámbito manufacturero.

En planta diariamente se generan datos de información de las penetraciones de soldadura y condiciones de proceso (parámetros), estos últimos son almacenados como requisito del cliente para la empresa. Con esta información, una vez determinado el modelo óptimo de predicción de penetración de soldadura, puede aplicarse para analizar cada proceso de la Planta. También, se puede aplicar la metodología propuesta para predecir la penetración en cada uno de los productos de la compañía. Estos modelos ayudarán a conocer la influencia de las variables de entrada en la geometría de la junta soldada, reduciendo el tiempo muerto y la cantidad de chatarra durante las fases de desarrollo de producto. A través del análisis de estos modelos se puede conocer qué variables son las que tienen mayor afectación en la penetración en aro para los productos de la planta. Como parte de los ajustes que se realizan en el proceso de fabricación, el ajuste de los parámetros de entrada son uno de los principales valores que son ajustados en el proceso. Además, en este trabajo se estudiará la factibilidad de implementar herramientas alternas para la evaluación de la junta soldada sin necesidad de requerir la destrucción de la pieza, reduciendo por ende los costos de fabricación y evaluación de la calidad del producto.

El desarrollo de este proyecto no solo tendrá un impacto económico sustancial para la empresa, además tendrá la oportunidad de romper los paradigmas de solo

utilizar herramientas de estadística básica, permitiendo la aplicación de tecnología y herramientas de vanguardia para el análisis de información. Actualmente, en ninguna de las ■ plantas de ■ se están desarrollando proyectos de inteligencia artificial y aprendizaje automático aplicados a la predicción de penetración de soldadura. También, se innovará a nivel nacional, ya que actualmente no hay ninguna empresa en la rama automotriz trabajando en la implementación de tecnologías para evaluar la junta soldada sin necesidad de destruir la pieza utilizando herramientas como son el aprendizaje automático y la inteligencia artificial.

1.4. OBJETIVOS

1.4.1. Objetivo general

Desarrollar modelos matemáticos capaces de predecir la penetración de soldadura GMAW-P para la producción de un rin de la empresa ■, ubicada en San Luis Potosí, aplicando algoritmos de inteligencia artificial y aprendizaje automático.

1.4.2. Objetivos específicos

1. Desarrollar modelos matemáticos con base a las variables eléctricas de la soldadura para predecir la penetración en disco en eje X, penetración en aro y dilución de soldadura, aplicando algoritmos de inteligencia artificial y aprendizaje automático.
2. Evaluar los modelos de regresión generados en el objetivo 1 mediante métricas como coeficiente de correlación, error medio absoluto y raíz del error medio cuadrático con la finalidad de determinar el modelo de regresión con la correlación más alta entre los valores predichos y los valores reales.
3. Determinar cuáles son las variables de soldadura, de acuerdo a los modelos matemáticos obtenidos, que tienen mayor afectación en el dimensional de la penetración de soldadura.

1.5. HIPÓTESIS

Un modelo matemático obtenido mediante algoritmos de inteligencia artificial y aprendizaje automático que tiene como variables de entrada la velocidad de alambre, tensión de impulso, corriente base, frecuencia y tiempo de impulso es capaz de predecir las dimensiones de penetración del cordón de soldadura en un proceso GMAW-P con un coeficiente de correlación mayor a 0.80.

2. MARCO TEÓRICO

2.1. PROCESO DE SOLDADURA GMAW

La sociedad americana de soldadura (AWS) define al proceso de soldadura GMAW como un proceso de soldadura que utiliza un arco eléctrico entre un electrodo del material de aporte continuo y el área soldada, usando un gas de protección alimentado externamente, pero sin aplicación de presurización de acuerdo a la norma AWS 3.0 Términos y definiciones (American Welding Society, 2010).

Según Ramnarayan (2014), el proceso de soldadura GMAW es definido como un proceso donde un arco es establecido entre un electrodo de alambre continuo y un sustrato, alimentándose de un gas de protección externo. El proceso es adecuado para automatizar y se pueden utilizar diferentes tipos de gases de protección dependiendo de la aleación (Chattopadhyay, 2014).

2.2. HISTORIA DEL PROCESO DE SOLDADURA

Este proceso es ampliamente utilizado tanto en soldadura semiautomática, mecanizada y robótica, siendo sus aplicaciones en todos los ámbitos industriales. Aunque el proceso de soldadura se cree que viene desde el antiguo Egipto, el proceso GMAW es un descubrimiento y desarrollo relativamente reciente. Algunos autores como Olsen (2009), declaran padre de la soldadura a Sir Humphrey Davy, quien en 1801 demostró que un arco podría ser creado, mantenido y manipulado con un circuito eléctrico con una batería de alto voltaje. Sin embargo, fue hasta 1881 cuando Auguste de Meritens utilizó por primera vez un arco eléctrico para unir metales, logrando obtener una patente del método para derretir y unir metales con un arco de carbono, para soldar placas de plomo a baterías de almacenamiento (Olsen, 2009).

De 1800 a las primeras décadas de 1900, el proceso de soldadura por arco revestido fue mayormente utilizado; sin embargo, en 1935 se comenzaron a

desarrollar otros procesos como el arco sumergido y el proceso de soldadura de arco con electrodo no consumible de tungsteno (Olsen, 2009).

El nacimiento del proceso de soldadura GMAW varía cronológicamente dependiendo del autor, de acuerdo con Olsen(2009) , el proceso de soldadura GMAW fue desarrollado en 1948 acompañado de un gas de protección inerte, posteriormente se implementaría la mezcla de gases de protección activos para reducir los costos. Sin embargo, existen otros autores, como Hoffman (2014), que declaran que el proceso GMAW fue introducido en 1920 utilizando un alambre sólido como electrodo y con corriente directa.

Posterior al desarrollo del proceso de soldadura GMAW se han ido generando múltiples modificaciones y mejoras al proceso como la tecnología de control, la transferencia metálica y la cantidad de calor (Hoffman, 2014). Día con día se han ido implementando nuevas tecnologías que han mejorado la efectividad y eficiencia del proceso (American Welding Society, 2010), como será explicado en capítulos posteriores.

2.3. PRINCIPIOS BÁSICOS DEL PROCESO DE SOLDADURA

En el proceso de soldadura GMAW, el arco eléctrico que existe entre el electrodo consumible y material base genera un calor capaz de fundir las superficies de ambos metales. El metal fundido es transferido hacia el material base donde se genera una unión. El alambre de soldadura es alimentado a través de una punta de contacto generando un arco eléctrico. El gas de protección es el encargado de proteger el arco eléctrico y el charco de soldadura de cualquier contaminante (AWS D11 Committee on Welding Iron Casting, 1989).

El proceso de soldadura GMAW incorpora una alimentación automática de alambre consumible que es protegido por una atmósfera de protección. Este proceso contiene una antorcha de soldadura que está compuesta por una tobera de gas, una punta de contacto, una guía de alambre, un conductor de corriente y el conducto del electrodo y del gas de protección (ver Figura 1) (O'Brien, 1997).




Figura 1. Esquema de antorcha del proceso de soldadura GMAW (O'Brien, 1997)

2.4 EQUIPO DE SOLDADURA GMAW

Los elementos del equipo de soldadura dependerán del tipo de sistema implementado, es decir si es manual, mecanizado o robotizado. Los componentes básicos de cualquier equipo de soldadura se muestran en la Figura 2 y se mencionan a continuación (Galvery & Marlow, 2006):

- Fuente de poder de soldadura de voltaje constante.
- Alimentador de alambre de soldadura.
- Antorcha de soldadura con sus respectivos conductores.
- Cables de corriente eléctrica y terminales.
- Alambre de soldadura.
- Sistema de alimentación y regulación de gas de protección (Flujómetro, regulador, cilindro de gas y conexión de gas).

Algunos equipos, además de los componentes básicos, pueden contener un sistema de enfriamiento por agua, evacuadores de gases y humos, sistemas de fijación de antorcha y del material base (Galvery & Marlow, 2006).




Figura 2. Componentes básicos de equipo de soldadura (Galvery & Marlow, 2006).

2.5 VARIABLES DEL PROCESO DE SOLDADURA

En el proceso de soldadura de arco eléctrico con atmósfera protegida existen algunas variables que afectan la penetración, la geometría y la calidad de soldadura (García Sánchez, 2009), como:

- Corriente eléctrica.
- Polaridad.
- Voltaje de arco eléctrico (Longitud de arco).
- Velocidad de desplazamiento.
- Longitud libre del electrodo (*stick-out*).
- Calor de entrada.
- Velocidad de desplazamiento.
- Velocidad de alimentación de alambre.
- Gas de protección.
- Material base.

2.5.1 Corriente de soldadura

Cuando todas las demás variables son constantes, el amperaje de la soldadura varía con la velocidad de alimentación de alambre o tasa de alimentación en una relación no lineal. En la Figura 3 se aprecia un gráfico de la velocidad de

alimentación de alambre con respecto a la corriente eléctrica y al diámetro del electrodo (O'Brien, 1997).

En la compañía donde se implementó esta investigación se registra tanto la corriente base (parámetro de entrada) como la corriente de salida de cada una de las fuentes; los preparadores de soldadura son los encargados de ajustar dicho parámetro de acuerdo con las condiciones del proceso.

Para variar la corriente de salida, de acuerdo con el conocimiento empírico de la compañía, el preparador comúnmente ajusta la velocidad de alimentación de alambre para mejorar la penetración, así como la apariencia visual del cordón de soldadura.




Figura 3. Gráfica de correlación entre corriente eléctrica y velocidad de alimentación de alambre (O'Brien, 1997).

Al incrementar la corriente eléctrica se tienen como resultado un incremento en la profundidad y el ancho de penetración de la soldadura, e incremento en el tamaño de la cara de soldadura. Además, se obtiene un cambio de la transferencia metálica a modo spray. Dependiendo de la composición química del material base se tienen afectaciones en las propiedades mecánicas, ya que se

obtiene un mayor calor de entrada que es directamente proporcional a la corriente eléctrica (O'Brien, 1997).

2.5.2 Polaridad

La polaridad se define como la conexión eléctrica de la antorcha de soldadura en relación a las terminales de la fuente de poder de corriente directa. Cuando la antorcha es conectada a la terminal positiva se le conoce como *Direct Current Electrode Positive* (DCEP), también llamado polaridad inversa, y cuando la antorcha está conectada a la terminal negativa se conoce como *Direct Current Electrode Negative* (DCEN), conocida como polaridad directa (O'Brien, 1997).

En ██████ se utiliza polaridad inversa en los procesos de soldadura GMAW. Con esta condición se consigue un arco eléctrico estable, transferencia metálica suave, buena geometría de soldadura y buena penetración (O'Brien, 1997).

Cuando se utiliza la corriente alterna, el proceso puede ser inestable debido al ciclo de la onda. Esta inestabilidad se genera debido a la tendencia a extinguir el arco eléctrico cuando la corriente pasa por el punto cero (O'Brien, 1997).

2.5.3 Voltaje de arco eléctrico

En el proceso de soldadura GMAW, el voltaje del arco eléctrico es una variable crítica que debe ser controlada.

Cuando existe un modo de transferencia metálica en spray, con argón como gas de protección, si el arco es demasiado corto puede experimentar cortos circuitos debido a la fluctuación causada por la presión del aire en el arco eléctrico, produciendo porosidad por la absorción de nitrógeno (O'Brien, 1997). Si el arco eléctrico es demasiado largo, tiende a tener inestabilidad, afectando el perfil y la penetración de soldadura. Así como también, el voltaje del arco puede interrumpir el gas de protección (O'Brien, 1997).

Cuando las demás variables son constantes, el voltaje de arco está directamente relacionado con la longitud del arco (O'Brien, 1997).

El cambio de la longitud de arco afecta la transferencia metálica; al incrementar el arco eléctrico reduce la longitud de la extensión del electrodo; esto incrementará la corriente de soldadura. Al incrementar la longitud del arco eléctrico, el campo magnético generado por la corriente eléctrica generará un efecto de pinchado, resultando en el desprendimiento de la gota de soldadura (Phillips, 2016).

Las fuentes de soldadura Cloos (Schweißtechnik, 1994) tienen dos maneras de monitorear el voltaje. Una es como parámetro de entrada, donde el operador tiene la capacidad de variar el voltaje o tensión de impulso en el menú principal de la fuente de soldadura. La segunda manera es utilizando un voltímetro que monitorea el voltaje de salida de la fuente de soldadura. Usualmente el preparador cambia la longitud del arco al ajustar la distancia del alambre de soldadura al material base con la finalidad de mejorar la estabilidad del arco y por ende el acabado del cordón de soldadura.

2.5.4 Longitud libre de electrodo de soldadura

La norma de soldadura de la sociedad americana de soldadura (AWS 3.0 términos y definiciones) define a la longitud libre del electrodo como la longitud del electrodo extendido sin fundir posterior al final de la tobera de gas (American Welding Society, 2010).

De acuerdo con García, 2009 (García Sánchez, 2009), el stick-out es la distancia de la punta de contacto al extremo del electrodo. Las variables eléctricas se verán afectadas respecto a la longitud del stick-out. Cuando se incrementa esta longitud, la resistencia eléctrica del electrodo aumenta; esto genera calor y la energía del arco eléctrico disminuye. Al disminuir la energía del arco eléctrico se verá afectada la penetración y perfil transversal de soldadura.

Conforme a Hoffman, 2009 (Hoffman, 2014), la longitud libre del electrodo tiene efectos definitivos en la soldadura, por ejemplo, cuando se mantiene la velocidad de alimentación de alambre y el voltaje, y se incrementa la extensión libre, disminuye la corriente eléctrica por resistencia del material.

En [REDACTED], el preparador usualmente ajusta la distancia de electrodo libre a 17 mm para algunos productos. Esta práctica es de acuerdo con el conocimiento empírico y validándolo con el WPS del producto.

2.5.5 Calor de entrada

La energía de entrada se expresa como energía por unidad de longitud, la Ecuación (2.1) expresa el calor de entrada, el cual está definido en función del voltaje, corriente y velocidad de avance de soldadura. En la Figura 4 se puede apreciar la ecuación de la energía de entrada (Phillips, 2016).

El voltaje es un factor importante porque estabiliza el arco eléctrico. La eficiencia del arco se refiere al porcentaje total de calor producido con respecto al arco eléctrico en la soldadura. Esta variable es importante, ya que tendrá una incidencia directa en la distorsión y generación de esfuerzos residuales, además de las propiedades mecánicas del producto (Phillips, 2016).




Figura 4. Ecuación de calor de entrada de soldadura (Phillips, 2016).

$$HI = \frac{\mu \times v \times I}{\frac{60}{V}} \quad (2.1)$$

Donde μ =Factor de eficiencia del arco

v=Voltaje del arco

I=Corriente del arco

V=Velocidad de avance

2.5.6 Velocidad de avance

La velocidad de avance es la velocidad a la que va a ser desplazado el electrodo a través de la junta. Esta velocidad es inversamente proporcional al calor de entrada, por lo que a mayor velocidad se tienen un menor tamaño del cordón, además de una menor penetración (García Sánchez, 2009).

Por otro lado, cuando disminuye la velocidad de avance, hay mayor energía térmica por unidad de longitud trasferida al material base, obteniendo afectaciones de diferentes índoles al material (García Sánchez, 2009).

Para la compañía, la velocidad de soldadura es ajustada con un PLC (Controlador Lógico Programable) Allen Bradley (Vallejo, 2001) donde el preparador declara un parámetro de velocidad radial. Este parámetro define la velocidad del servomotor de la estación de giro de los rines.

2.5.7 Velocidad de alimentación de alambre

Se define como la velocidad por la cual se desplaza el electrodo a través de la pistola y alimenta el arco eléctrico. Esta velocidad está directamente relacionada al amperaje, mayor velocidad resulta en mayor amperaje eléctrico (García Sánchez, 2009).

La velocidad de alimentación de alambre tiene una relación lineal con el amperaje y normalmente se utiliza esta velocidad para los procedimientos de

calificación de soldadura. Esta velocidad influirá directamente en el ancho del cordón de soldadura y la penetración (García Sánchez, 2009).

Las fuentes de soldadura CLOOS (Schweißtechnik, 1994) tienen un parámetro llamado velocidad de alimentación de alambre, que puede ser ajustado por el preparador para mejorar la penetración de soldadura del producto.

2.5.8 Dilución de soldadura

Es el cambio en la composición química de un metal de filete de soldadura causado por la mezcla del metal base o metal de soldadura anterior en el cordón de soldadura (American Welding Society, 2010). Esta dilución se puede calcular conforme la Ecuación (2.2); dividiendo el material depositado en el material base respecto al material del refuerzo de la soldadura (ver Figura 5) (American Welding Society, 2010).

$$\%Dilución = \frac{A}{A+B} \times 100 \quad (2.2)$$




Figura 5. Cálculo de dilución de soldadura conforme a AWS 3.0 (American Welding Society, 2010).

2.5.9 Electrodo de soldadura

El electrodo es usualmente sólido y está compuesto de un metal base; algunos electrodos están recubiertos por una lámina de cobre para protegerlos de la corrosión. Además, se le añaden elementos de aleación al electrodo para mejorar las propiedades mecánicas (Galvery & Marlow, 2006).

Los diámetros de electrodos más comunes son de 0.020 a 0.50 pulgadas y se distribuyen en barriles y bobinas de diferentes pesos (Galvery & Marlow, 2006).

La AWS clasifica el electrodo ER70S-6 de acuerdo con la norma AWS 5.18. En la Figura 6 se presenta la nomenclatura de clasificación del electrodo de acuerdo con esta norma (Galvery & Marlow, 2006).

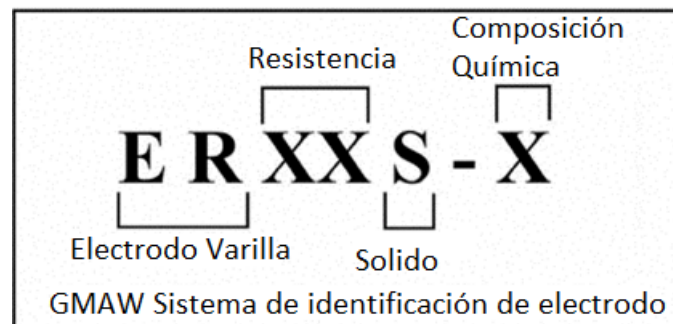


Figura 6. Sistema de clasificación de electrodo GMAW (Galvery & Marlow, 2006).

El electrodo ER70S-6 tiene altos niveles de desoxidación y es usado en ligera y moderada escala sin pre limpia. Este electrodo produce un arco eléctrico estable con bajos niveles de generación de perlas de soldadura. El electrodo normalmente es utilizado en diversas mezclas de gas con varias aplicaciones de transferencia de arco (corto, spray y pulsado) (Galvery & Marlow, 2006).

2.5.10 Metal base

Según Aza (2000), la última década se ha caracterizado por el incremento exponencial de la utilización del acero. El acero entre sus virtudes tiene una enorme

ventaja en sus propiedades mecánicas como es la ductilidad, dureza, resistencia, maleabilidad y tenacidad.

Según Aza (2000) afirma "La ductilidad es la capacidad del acero para deformarse sin llegar a la rotura. La dureza se define como la capacidad del acero a oponerse a la penetración de otro material. Analizando el caso de la resistencia, específicamente el de la resistencia a la tracción, esta es la fuerza máxima por unidad de área que puede soportar el acero al ser estirado. La maleabilidad es la capacidad que presenta el acero de soportar la deformación, sin romperse, al ser sometido a un esfuerzo de compresión. La tenacidad es la combinación de dos propiedades: ductilidad y resistencia. Un material tenaz será aquel que posee una buena ductilidad y resistencia al mismo tiempo" (Aza, 2000).

Los aceros pueden ser clasificados por su composición química conforme a las normas de clasificación como SAE y AISI (Aza, 2000). Según Aza (2000) este sistema de clasificación de aceros se basa en la composición química y se puede clasificar en los siguientes subgrupos:

- Aceros al carbono. Son aceros con contenido de carbono, además de otros elementos también llamados elementos residuales como són: Manganeso, Silicio, Fósforo y Azufre (Aza, 2000).
- Aceros aleados de baja aleación. Son aceros elementos residuales están presentes arriba de cantidades normales, o donde están presentes nuevos elementos aleantes, cuya cantidad total no sobrepasa un valor determinado (normalmente un 3,0 al 3,5%) (Aza, 2000).
- Aceros aleados de alta aleación. Son aceros que la cantidad total de elementos aleantes se encuentra en el mínimo de un 10 a 12% conforme el autor Aza (2000), quien afirma "En estas condiciones, no sólo la microestructura de los aceros correspondientes puede ser profundamente alterada, sino que igualmente los tratamientos térmicos comerciales sufren modificaciones, exigiendo técnicas, cuidados especiales y frecuentemente, múltiples operaciones".

- Aceros aleados de media aleación. Son aceros que se pueden clasificar entre los dos grupos anteriores (Aza, 2000).

En la Tabla 1 se presenta la clasificación de los aceros de acuerdo con AISI-SAE y UNS según Aza (2000). En la Tabla 2 aparecen los aceros y su composición química. El acero que será utilizado en esta investigación es el SAE 1010 con contenido de carbono de 0.08% a 0.13% (Aza, 2000).

Tabla 1 Tipos de acero según SAE.

Designación		Tipos de acero
AISI-SAE	UNS	
10XX	G10XXX	Aceros al Carbono comunes
11XX	G11XXX	Aceros maquinables, con alto S
12XX	G12XXX	Aceros maquinables, con alto P y S
13XX	G13XXX	Aceros al Manganeso, con 1.75 %Mn
15XX	G15XXX	Aceros al Manganeso, con Mn sobre 1%
40XX	G40XXX	Aceros al Molibdeno, con 0.25% Mo
41XX	G41XXX	Aceros al Cromo-Molibdeno, con 0.40 a 1.1% Cr y 0.08 a 0.35% Mo
43XX	G43XXX	Aceros al Ni-Cr-MO con 1.65 a 2% Ni, 0.4 a 0.9% Cr y 0.2 a 0.3% Mo
46XX	G46XXX	Aceros Ni-Mo, con 0.70 a 0.2% Ni y 0.15% a 0.3% Mo
47XX	G47XXX	Aceros Ni-Cr-Mo, con 1.05% Ni, 0.45% Cr y 0.2% Mo
48XX	G48XXX	Aceros Ni-Mo, con 3.25 a 3.25% Ni y 0.2 a 0.3% Mo
51XX	G51XXX	Aceros al Cromo, con 0.70 a 1.1% Cr
E51100	G51986	Aceros al Cromo (horno eléctrico) con 1.0% Cr
E52100	G52986	Aceros al Cromo (horno eléctrico) con 1.45% Cr
61XX	G61XXX	Aceros Cr-V con 0.6 a 0.85% Cr y 0.1 o 0.15% V mínimo
86XX	G86XXX	Aceros Ni-Cr-Mo, con 0.55% Ni, 0.5% Cr y 0.2% Mo
87XX	G87XXX	Aceros Ni-Cr-Mo, con 0.55% Ni, 0.5% Cr y 0.25% Mo
88XX	G88XXX	Aceros Ni-Cr-Mo, con 0.55% Ni, 0.5% Cr y 0.3 a 0.4 % Mo
9260	G92XXX	Aceros al Silicio con 1.8 a 2.2% Si

(Aza, 2000)

Tabla 2 Composición química de los aceros según SAE.

SAE	Límites de composición química, %				N° AISI
N°	C	Mn	P máx	S, máx	Correspondiente
1005	0.06 máx	0.45 máx	0.4	0.05	-
1006	0.08 máx	0.25-0.40	0.4	0.05	1006
1008	0.10 máx	0.30-0.50	0.4	0.05	1008
1010	0.08-0.13	0.30-0.60	0.4	0.05	1010
1012	0.10-0.15	0.30-0.60	0.4	0.05	1012
1013	0.11-0.16	0.50-0.80	0.4	0.05	-
1015	0.13-0.18	0.30-0.60	0.4	0.05	1015
1016	0.13-0.18	0.60-0.90	0.4	0.05	1016
1017	0.15-0.20	0.30-0.60	0.4	0.05	1017
1018	0.15-0.20	0.60-0.90	0.4	0.05	1018
1019	0.15-0.20	0.70-1.00	0.4	0.05	1019
1020	0.18-0.23	0.30-0.60	0.4	0.05	1020
1021	0.18-0.23	0.60-0.90	0.4	0.05	1021
1022	0.18-0.23	0.70-1.0	0.4	0.05	1022
1023	0.20-0.25	0.30-0.60	0.4	0.05	1023
1024	0.19-0.25	1.35-1.65	0.4	0.05	1024
1025	0.22-0.28	0.30-0.60	0.4	0.05	1025
1026	0.22-0.28	0.60-0.90	0.4	0.05	1026
1027	0.22-0.29	1.20-1.50	0.4	0.05	1027
1029	0.25-0.31	0.60-0.90	0.4	0.05	-
1030	0.28-0.34	0.60-0.90	0.4	0.05	1030

(Aza, 2000)

En la Tabla 3 se pueden apreciar las propiedades mecánicas del acero SAE 1010 de acuerdo con Azom (2016). Este acero es muy utilizado por su bajo porcentaje de carbono y tiene muy buena soldabilidad, además de tener un bajo costo.

Tabla 3 Propiedades mecánicas del acero SAE 1010.

Propiedades	Métrica	Imperial
Esfuerzo de tensión	365 Mpa	52900 psi
Esfuerzo de corte	305 Mpa	44200 psi
Módulo elástico	190-210 Gpa	27557 - 30458 ksi
Modulo volumen	140 Gpa	20300 ksi
Módulo de corte	80 Gpa	11600 ksi
Tasa de Poisson	0.27-0.30	0.27-0.30
Elongación	20%	20%
Reducción de área	40%	40%
Dureza, Brinell	105	105
Dureza Knoop	123	123
Dureza, Rockwell B	60	60
Dureza Vickers	108	108
Maquinabilidad (basado en acero AISI 1212 como 100 maquinabilidad)	55	55

(Azom, 2012)

2.5.11 Gases de soldadura

El gas de soldadura es un elemento crítico en el proceso de soldadura, ya que afecta la cantidad de energía aportada, la transferencia metálica, la penetración de soldadura, la velocidad de soldadura, la calidad de junta soldada y la probabilidad de generación de defectos y proyecciones (Reina, 2003).

En el proceso GMAW se utiliza principalmente un gas de protección inerte; esto significa que no reacciona en el arco eléctrico. Entre los gases más utilizados están el Argón, Helio y Neón (Reina, 2003).

El Argón es un gas de fácil ionización, por lo que la tensión del arco en el Argón es menor que la de un arco eléctrico en Helio, por ejemplo (Reina, 2003)

A continuación, se muestran algunas características de cada gas utilizado en el proceso de soldadura tanto activo como inerte (Reina, 2003):

- Argón. Es el de mayor utilización en aplicaciones de Aluminio, Cobre, Nitrógeno, Titanio y acero; además es un gas que disminuye la generación de defectos de soldadura y facilita la estabilidad del arco eléctrico (Reina, 2003).
- Argón + Oxígeno. El oxígeno ayuda en la capacidad de mojado de la soldadura, además de mejorar el perfil de soldadura y ancho de cara del cordón de soldadura, disminuye la generación de mordeduras, con un porcentaje menor al 5% no modifica su característica de inerte (Reina, 2003).
- Helio. Produce cordones más anchos y con menor penetración en comparación al Argón (Reina, 2003).
- CO₂. Gas activo que reacciona con el cordón; a elevada temperatura tiende a disociarse, es decir separarse el monóxido de carbono del oxígeno, generando una molécula de oxígeno activa que empobrece el acero. No se utiliza en aplicaciones con riesgo a oxidación como el Cromo o Molibdeno o en generación de Carburos de Cromo (Reina, 2003). El CO₂, de menor costo que el Argón, es utilizado para incrementar las penetraciones de soldadura por su elevada conductividad térmica; además de generar mayor tamaño de cordón de soldadura, produce arcos más energéticos, con respecto al Argón (Reina, 2003).
- CO₂ + Argón. Para soldar chapas de acero al carbono de baja aleación se utilizan mezclas de Argón con otros elementos. Esto consigue mejor visibilidad del baño de soldadura, arco más suave y con menor turbulencia, baño de fusión más frío, mejor aspecto del cordón de soldadura, menor generación de proyecciones y mayor facilidad de regulación (Oberger, Horton, Holbrook, & Ryffel, 2012).

En la Tabla 4 puede apreciar las aplicaciones en aceros al carbono e inoxidables con respecto a las mezclas de Argón con otros elementos. La numeración es respecto a la recomendación de la aplicación, donde 1 significa mayor recomendación y 3 menor recomendación (Oberger, Horton, Holbrook, & Ryffel, 2012).

- Hidrógeno. Es un gas activo de carácter reductor que favorece la eliminación de óxidos. Por su carácter fragilizante en aceros de naturaleza

ferrítica puede provocar fisuración en frío si se asocia a fuertes embriamientos y estructuras metalúrgicas. Este gas incrementa el aporte térmico y mejora el efecto de mojado del acero (Reina, 2003).

Tabla 4 Aplicaciones de mezcla de gas.

Aplicación	Mezcla de gas					
	Ar + O	Ar+ CO2 + O	Ar+ 2-4% CO2	Ar+ 6-10% CO3	Ar+ 13-20% CO4	Ar+ 25% CO5
Transferencia de corto circuito	1	1	1	1	2	3
Corto circuito de 18 a 11 calibres	-	-	-	-	1	1
Spray con problemas de superficie para aceros al carbono	-	-	-	-	1	2
Spray baja energía requerida para aceros al carbono	1	1	1	1	-	-
Spray, mejor impacto al esfuerzo, baja porosidad para aceros al carbono	-	-	-	-	1	-
Mejor para mezcla individual de aceros al carbono	-	-	-	-	1	-
Corto circuito en aceros inoxidables	-	-	1	-	-	-
Spray Aceros inoxidables	2	-	1	-	-	-
Mejor mezcla gas para inoxidables y Duplex	-	-	1	-	-	-

(Oberg, Horton, Holbrook, & Ryffel, 2012)

2.6 TRANSFERENCIA METÁLICA

El arco eléctrico en el proceso de soldadura genera suficiente calor y energía para fundir el material de aporte y dirigirlo a charco de soldadura; a este proceso se le conoce como transferencia metálica. Existen diversos tipos de transferencia metálica, los cuales se presentan a continuación.

- Transferencia globular. El extremo del electrodo se funde a través de gotas gruesas de un diámetro de hasta tres veces mayor que el electrodo (Reina, 2003). Al desprenderse la gota de soldadura oscilará de un lado hacia otro. Esta transferencia es muy difícil, el arco se vuelve inestable y logra poca penetración además de producir muchas proyecciones (Reina, 2003).
- Transferencia spray. Esta transferencia genera gotas muy finas, un arco estable y una pulverización del metal de forma ininterrumpida y similar mostrada en la Figura 8. El arco se caracteriza por tener un cono de proyección muy luminosa y zumbido característico. Esta transferencia se genera con una tensión de arco relativamente alta y con polaridad inversa (Reina, 2003).

La transferencia spray genera una muy buena penetración y un baño de fusión relativamente grande y fluido (Reina, 2003).

- Transferencia corto circuito. El extremo del electrodo se funde formando una gota que se va incrementando hasta que toca el material base; en este momento, se produce un corto circuito que aumenta la intensidad y las fuerzas axiales rompen el cuello de la gota. Esta transferencia se genera con tensiones bajas, polaridad inversa, densidad de corriente baja y gas de protección CO₂, principalmente (Reina, 2003).
- Transferencia pulsada. El arco se genera con equipos generadores de frecuencia de 50 -100 Hz combinando corrientes cuyas condiciones generan un pico de corriente y una base para calentar y enfriar al material. Cada pulsación provoca una proyección de una gota del diámetro del electrodo (Reina, 2003).

En la Figura 7 se describen procesos básicos de transferencias metálicas (Linnert, 1994).




Figura 7. Transferencias metálicas básicas: (A) Globular (B) Spray (C) Corto Circuito (D) Pulsado (Linnert, 1994).

2.7 PROCEDIMIENTO DE FABRICACIÓN

Para la fabricación de rines de acero, el proceso inicia con el procesado de los componentes. Un rin de acero está compuesto por dos componentes principales: el aro y el disco (ver Figura 8).




Figura 8. Componentes de fabricación de un rin.

Recuperado de <http://wheelmachinery.com/profile/wheel-manufacturing/199771/0>

Cada uno de los componentes es fabricado independientemente; primeramente, el disco es fabricado a partir de una placa de acero que será conformada por diversas prensas y procesos de estampados de acuerdo al diseño.

El proceso de fabricación del aro es desarrollado como lo muestra la Figura 9. Una bobina de acero es desenrollada y cortada en secciones; posteriormente se realiza un proceso de doblado y con ayuda de una máquina de soldadura a tope (*butt weld*) se realiza la unión y formado del aro; después se realiza el formado de la geometría del aro por un proceso de laminado. Finalmente, se realiza el ensamble del aro con el disco en una prensa de ensamble, donde el disco tiene un diámetro de ensamble mayor al del aro, generando una interferencia para su ensamble. Una vez ensamblado se suelda el producto, para ello se utiliza un sistema de soldadura robotizado o automatizado donde se soldan los cordones de soldadura requeridos conforme al diseño del producto.

En la Figura 9 se presenta el proceso de fabricación de un rin de acero.




Figura 9. Proceso de fabricación de un rin de acero.

Recuperado de <http://www.watanabe1886.com/en/product.html>.

En este trabajo se utilizaron una prensa de ensamble de 25 toneladas para el ensamble de los rines, así como 5 fuentes de soldadura de la marca Cloos de 600 amperes. Cada fuente fue la encargada de realizar un cordón de soldadura de 256 mm de longitud en los 360 grados del rin.

2.8 INSPECCIÓN DE PENETRACIÓN DE SOLDADURA

El procedimiento de corte y evaluación metalográfica del producto se realiza siguiendo el mapa de proceso descrito en la Figura 10.

En el procedimiento de inspección de penetración, primeramente, el inspector de calidad deberá separar la pieza o rin a evaluar; este rin deberá ser identificado adecuadamente.

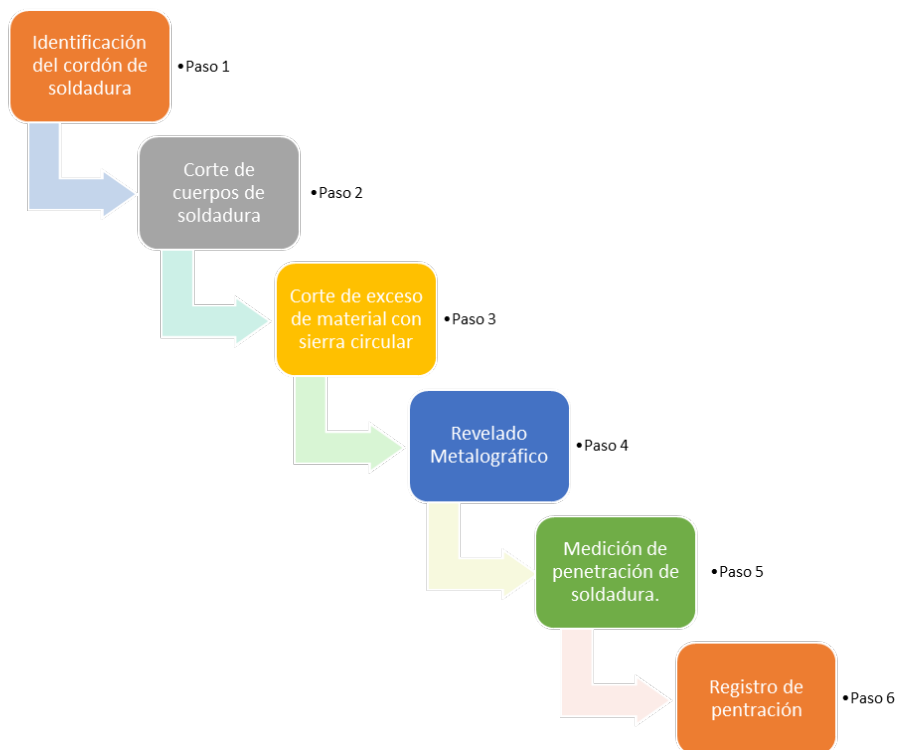


Figura 10. Proceso de inspección de penetración de soldadura.

Fuente: Elaboración propia.

Posteriormente, el inspector deberá marcar los 5 cordones de soldadura. En la Figura 11 se puede observar un esquema de la posición de los cordones de soldadura en color rojo; cada cordón de soldadura mide 256 mm de longitud; en total el rin tiene 5 cordones de soldadura en los 360°. El inspector identifica cada cordón con la finalidad de tener identificada de que máquina de soldadura fue soldado, ya que el área de soldadura tiene dos líneas de ensamble con 5 máquinas de soldadura, donde cada una de ellas suelda un cordón, generando 1 rin ensamblado y soldado por cada línea.




Figura 11. Esquema de posición de cordones de soldadura.

Recuperado de <http://getdrawings.com/rims-drawing>.

Una vez identificado cada cordón, el inspector deberá realizar a la sección de cada cordón un corte de 20 a 30 mm con la máquina de corte de plasma, obteniendo una pieza del cordón de soldadura como se observa en la Figura 12. Posteriormente, con la ayuda de una sierra circular o de cinta, el inspector deberá remover una sección del cuerpo de inspección (aproximadamente 7 mm); esto es para remover el material fundido por el plasma.




Figura 12. Esquema de cortes de soldadura.

Fuente: Elaboración propia.

Una vez obtenida la muestra, se lija el espécimen del lado de la sección removida y se procede a pulir con una rueda 3M Scotch-Brite Roloc para dejar un acabado espejo adecuado para el ataque metalográfico.

Posteriormente, se realiza la revelación de la penetración. Para ello el inspector somete el cuerpo a revelar en una solución Becker Nítrico durante 45 segundos, enseguida el inspector lavará la pieza con agua destilada y secará con aire comprimido. Este proceso se realiza para cada una de las muestras.

Una vez obtenidas las muestras, el inspector procederá a realizar la medición de penetración de soldadura. Para ello, con la ayuda de un comparador óptico o proyector de perfil marca Mitutoyo, el inspector realizará las mediciones de las cotas: Penetración en disco en eje X y eje Y, Penetración en aro, Garganta, Fusión en disco, Fusión en aro, abertura y espesor del elemento más delgado, como se observa en la Figura 13. En la Tabla 5 se describe el significado de cada una de las características de la Figura 11. Una vez medida cada cota deberá registrarlo para tener el histórico de liberación.



Figura 13. Cotas a dimensionar de perfil transversal de soldadura.

Fuente: Elaboración propia.

Tabla 5 Abreviatura de penetración de soldadura

Abreviatura	Cota
Smin	Espesor mínimo
Pa	Penetración en el Aro
Pdx	Penetración de disco en eje X
Pdy	Penetración de disco en eje Y
Fa	Fusión en el aro
Fd	Fusión en el disco
G	Garganta de soldadura
a	Abertura

Elaboración propia

3. ANÁLISIS DE DATOS Y ALGORITMOS DE INTELIGENCIA ARTIFICIAL

3.1 DISEÑO DE EXPERIMENTOS

El diseño de experimentos se puede definir como un arreglo de las unidades experimentales utilizadas para controlar el error experimental que al mismo tiempo acomoda los tratamientos. Existen diversos tipos de diseños aplicados para controlar el error experimental y observar la tendencia natural (Kuehl, 2001).

En el DOE se objetiva la máxima información, precisión y exactitud en los resultados utilizando de la manera más eficiente los recursos existentes (Kuehl, 2001).

El diseño de experimentos te ayuda a investigar los efectos de las variables de entrada (factores) sobre una variable de salida (respuesta) (Kuehl, 2001).

3.2 WEKA (WAIKATO ENVIROMMENT KNOWLEDGE ANALYZE)

El software WEKA es una seria extensa de colección de algoritmos de minería de datos gratuitos implementados en Java, desarrollado por la universidad de Waikato. WEKA ofrece una serie de herramientas para la transformación de datos, tareas de clasificación, regresión, clustering, asociación y visualización (Morate, s.f.). La interfaz principal ofrece cuatro funciones principales: *Explorer*, *Experimenter*, *Knowledge Flow*, *Workbench* y *Simple CL* (Morate, s.f.).

En esta tesis se utilizó la interfaz *Explorer*, la cual, de manera gráfica, permite procesar, clasificar, asociar y visualizar los datos de una manera sencilla (Morate, s.f.). Esta interfaz está dividida en 6 pestañas: *Preprocess*, *Classify*, *Cluster*, *Associate*, *Select Attributes* y *Visualize*.

A través de distintas herramientas clasificadas en las pestañas previamente descritas, WEKA permite aplicar:

- algoritmos de filtrado, como son la discretización, normalización y combinación;

- algoritmos de clasificación y regresión a los datasets (ver Figura 16);
- algoritmos de *clustering* o agrupación de datos con base en varios criterios;
- reglas de asociación entre los datos.

En la Figura 14 se presenta la interfaz *Classify*, la cual permite aplicar distintos algoritmos de clasificación y regresión a la información.

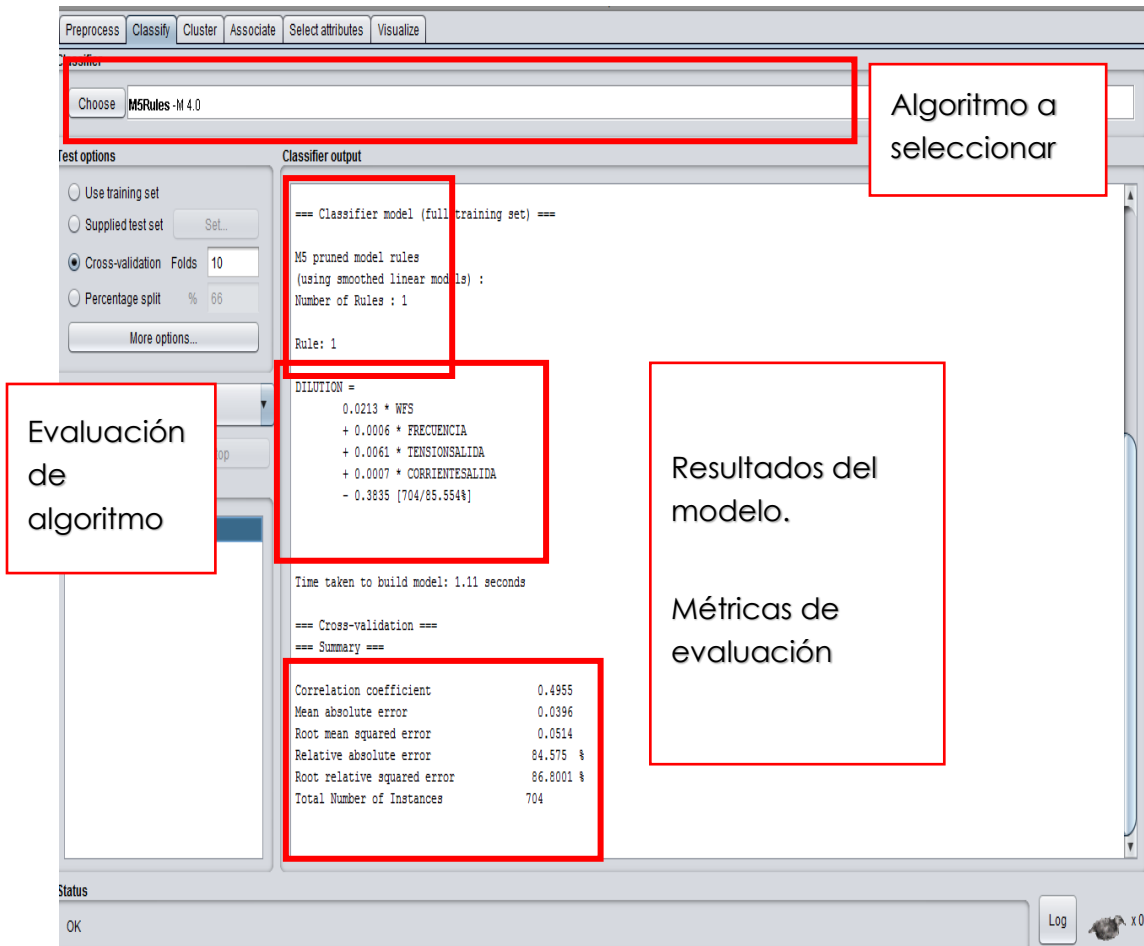


Figura 14. Interfaz de clasificación de WEKA

3.3 MODELOS DE REGRESIÓN EN WEKA

La interfaz *Classify* presenta una biblioteca muy extensa de algoritmos de minería de datos y clasificación, divididos en las siguientes categorías:

- *Bayes*. Modelos basados en el aprendizaje de Bayes. Son aquellos modelos que intentan encontrar entre todas las hipótesis la más probable. Este modelo asume que las variables predictoras son independientes entre sí. El modelo es desarrollado calculando la probabilidad posterior de que ocurra un evento, con respecto a la probabilidad de los eventos anteriores (Navas Moreno, 2016).
- *Funciones*. Corresponden a modelos matemáticos como son las redes neuronales y regresión lineal. Cuando se tiene como salida un atributo numérico o clase y todas las entradas son valores tipo numérico, la regresión lineal es un método estadístico a considerar. La idea es expresar la salida del modelo con una combinación lineal de los atributos con sus respectivos pesos. Los pesos son calculados a partir de los datos de entrenamiento (Navas Moreno, 2016).
- *Lazy*. Son modelos de comparación de algoritmos donde se comparan los datos con el resto de los conjuntos definiendo cierta distancia. Uno de los algoritmos más comunes es KNN (o K vecinos más cercanos). En este tipo de algoritmos se busca encontrar la distancia Euclidiana más cercana entre los valores de prueba y los valores predichos (Navas Moreno, 2016).
- *Meta*. Son meta algoritmos donde se combinan dos o más tipos de aprendizaje (Navas Moreno, 2016).
- *Trees*. Son algoritmos basados en arboles de decisiones. Estos se construyen utilizando decisiones en cada una de sus ramas. Existen diversos tipos de algoritmos como son: Random Forest, Decision Tree, Rep Tree, entre otros (Navas Moreno, 2016).

Los algoritmos empleados en este trabajo fueron los siguientes:

- *Linear regression*. Es un algoritmo en función matemática de regresión lineal. La función está determinada por la combinación de variables de entrada con sus respectivos pesos, cada peso es calculado conforme los datos de

entrenamiento. Este tipo de algoritmos son utilizados principalmente cuando hay valores numéricos (Witten & Frank, 2005) (Tusnel, 2011).

- El modelo de regresión lineal utiliza la ecuación 3.1 para describir la relación entre la variable aleatoria Y , también conocida como variable de respuesta. Y las variables explicativas no estocásticas o regresores. Además de que cada variable estocástica tienen parámetros fijos desconocidos y una variable aleatoria inobservable como lo muestra la ecuación (Witten & Frank, 2005) (Tusnel, 2011).

$$Y = \beta_0 X_0 + \beta_1 X_1 + \dots + \beta_{p-1} X_{p-1} + \varepsilon \quad (3.1)$$

Donde :

$\beta_0 X_0 \dots \dots \beta_{p-1} X_{p-1} = \text{Parámetros fijos desconocidos}$

$X_0 = \text{Variables explicativas no estocásticas o regresores}$

$\varepsilon = \text{Variable aleatoria inobservable}$

Este modelo de regresión se puede configurar en el software WEKA utilizando diferentes condiciones. Utiliza el criterio de Akaike para la selección de modelos. Se puede activar la Matriz de descomposición QR para encontrar los coeficientes del modelo. Se puede configurar el parámetro Ridge para reducir de forma proporcional el valor de todos los coeficientes del modelo y reducir la varianza. Se configura el método de selección de atributos para el modelo de regresión. Cuando no es seleccionado, el software utiliza el método M5 para selección de atributos de forma predeterminada, además de poder configurar la eliminación de atributos colineales (Witten & Frank, 2005).

- *SMOreg*. Es un algoritmo de optimización secuencia mínimo de aprendizaje supervisado basado en regresión numérica con apoyo de máquinas de soporte vectorial. Las máquinas de soporte vectorial tienen un conjunto de vectores de entrada conforme la ecuación 3.2. Además, tienen un conjunto de vectores conforme la ecuación 3.3 que representan las etiquetas o clases

de objetos para los algoritmos de clasificación (Witten & Frank, 2005) (Flores de la Torre, 2014).

$$X = \{X_i | X_i = (X_{i1}, X_{i2}, \dots, X_{in})\} \quad 3.2$$

Donde:

$X =$ Conjunto de datos de entrada

$$Y = \{y_i \in \{+1, -1\}\} \quad 3.3$$

Donde:

$y_i =$ Conjunto de vectores (clases)

Estos algoritmos pueden ser aplicados en diversos problemas. La clasificación lineal consiste en generar un hiperplano que separe los datos. El objetivo es encontrar este hiperplano óptimo que maximice el margen o la distancia entre el objeto de cada clase más cercano al hiperplano (Witten & Frank, 2005) (Flores de la Torre, 2014).

Los vectores de soporte se pueden definir como las observaciones que están más cerca del hiperplano. Cuando el conjunto de valores no es linealmente separables, se utiliza funciones kernel para transformar los vectores de entrada en vectores de mayor dimensión. Existen kernels lineales, polinomiales, Radial basis Function, entre otros (Witten & Frank, 2005) (Flores de la Torre, 2014).

- *Decision Table*. Es un algoritmo basado en la teoría de la decisión, donde intervienen algunos elementos en el proceso de decisión (Witten & Frank, 2005) (Vitoriano, 2007).

$E = \{E_1, \dots, E_m\}$: conjunto de estados de la naturaleza o posibles escenarios. 3.4

$A = \{A_1, \dots, A_m\}$: conjunto de posibles alternativas o decisiones. 3.5

X_{ij} : Consecuencia de tomar la decisión A_1 y se de el estado E_1 .

En algunos problemas, la probabilidad también interviene de acuerdo a cada estado. Si estas probabilidades son conocidas o han sido estimadas antes de tomar la decisión se dice que es un proceso de decisión de bajo riesgo, mientras si son desconocidas son decisión bajo incertidumbre (Witten & Frank, 2005) (Vitoriano, 2007).

Se construye una tabla de decisión simple mayormente utilizada para clasificación. Con el parámetro EvaluationMeasure se determina la métrica utilizada para evaluar el rendimiento del algoritmo. Se puede configurar el método de búsqueda utilizado para encontrar la mejor combinación de atributos. Con el parámetro crossVal se configura el número de pliegues para una validación cruzada (Witten & Frank, 2005).

- *Multilayer Perceptron*. El Perceptron multicapa es una neurona procesadora con sus componentes de entrada, sumador, activador y salida. En este llegan señales de entrada X_i , $i=1,2,\dots,n$ cada uno lleva un peso asociado w_i .

La función de suma, efectúa una suma ponderada de las entradas con sus respectivos pesos y la función de activación emplea una función de escalón de umbral. Si la suma es mayor o igual a un valor de umbral dará una salida. Básicamente, los valores de entrada del perceptron formarán su vector de entrada X , la dimensión de este vector es igual al número de neuronas de la capa de entrada cada uno de estos valores será multiplicados por sus respectivos pesos. La dimensión del vector de salida es igual al número de neuronas de la capa de salida. La salida de la red se compara con un vector de salida y las diferencias obtenidas se utilizan para ajustar los pesos.

Existen diversas reglas de reajuste, una de ellas, es la Regla Delta de Widrow y Hoff que indica que el nuevo peso W_1 es igual al peso anterior W_0 más una

cantidad proporcional a la diferencia entre la salida deseada t y la salida real (ver ecuación 3.5) (Witten & Frank, 2005) (Rosano Lara, 1996).

$$W_1 = W_0 + \eta (t - y) \quad 3.6$$

$$W_1 = \textit{Peso nuevo}$$

$$W_0 = \textit{Peso anterior}$$

$$\eta = \textit{Constante de proporcionalidad}$$

$$t = \textit{salida deseada}$$

$$y = \textit{salida real}$$

Antes de realizar el entrenamiento del perceptron, los pesos son definidos normalmente de forma aleatoria. Los patrones de entrenamiento se realizaran durante N número de veces hasta que los peso ya no se modifiquen. A esto se le llama que la red ha convergido, donde normalmente se pueden denotar dos conclusiones: Ha aprendido con éxito o es incapaz de aprender todas las respuestas correctas (Rosano Lara, 1996).

En WEKA, se construye con una red neuronal de retroalimentación para aplicar algoritmos de clasificación o regresión; se pueden ajustar el número de capas ocultas, pesos, tasa de aprendizaje, momento, tiempo de entrenamiento. Además, el software WEKA tiene una interfaz gráfica para la configuración de la red (Witten & Frank, 2005).

- *Random Forest.* Un arbol de decisión es una técnica de aprendizaje automático supervisado, comunmente utilizado para hacer prediccciones. Puede ser utilizado para casos categóricos o numéricos. Inicia con un nodo raíz, posteriormente hay nodos hoja o predicciones. Los bosques aleatorios o Random forest combinan los arboles de decisiones para predecir una clase o atributo numérico tomando el promedio de los casos de regresión de cada árbol de decisión. Los arboles de decisiones forman un conjunto aleatorio de características y un conjunto aleatorio de variables para

entrenamiento. Cada uno de los árboles de decisión trata de combinar los valores para aprender la relación de las entradas y salidas, y lograr la predicción (Witten & Frank, 2005) (Singh, 2019). Se puede representar formalmente al algoritmo Random Forest como una colección de árboles clasificadores estructurados (Berk, 2016).

$$\{f(x, V_k), k = 1, \dots, n\} \quad 3.6$$

Donde:

x = vector p de variables entrada utilizado para asignar clases.

k = es el índice del árbol de decisión.

V_k = Vector aleatorio estructurado por k – esimo árbol .

El algoritmo Random forest también es conocido como una combinación de árboles predictores de manera que cada árbol depende de los valores de un vector aleatorio muestreado de forma independiente y con la misma distribución para todos los árboles. Este algoritmo se puede configurar de los hiperparámetros de diversas maneras de acuerdo a la aplicación. En el caso de WEKA , con el parámetro seed se puede configurar el número aleatorio para la semilla del clasificador, el parámetro numExecutionSlots sirve para configurar el número de ranuras de ejecución para construir el conjunto, printClassifiers sirve para mostrar el clasificador individual de salida, muy útil cuando es requerido la función de clasificación. Se puede configurar el clasificador base del árbol con el parámetro classifier. El parámetro maxDepth nos permite determinar la profundidad máxima del árbol (Witten & Frank, 2005) (Breiman, 2001).

- *Gaussian Process*. Son modelos donde el concepto de distribución sobre la función es central. Este algoritmo está cercanamente relacionado con la regresión lineal Bayesiana y las máquinas de soporte vectorial, pero puede ser interpretado por una red neuronal Bayesiana con una sola capa y un número infinito de unidades. Este algoritmo normalmente utilizado para

problemas de regresión sin modificaciones en los hiperparámetros, se puede seleccionar adecuadamente el nivel de ruido. Se puede configurar para aplicar filtros de normalización/estandarización y que tenga un mejor resultado en la correlación de los valores. Los valores perdidos son remplazados automáticamente por la media global de los datos (Witten & Frank, 2005).

- *REP Tree*. Es uno de los algoritmos de arboles de decisiones más utilizado en aprendizaje automático. De un grupo de valores para entrenamiento, se forma un árbol de decisión considerando la entropía y la división de información así como la reducción de ganancia o varianza (Jing, Zhao, Zhang, & Ruan, 2019).

Primero, el algoritmo selecciona el nodo raíz para empezar el entrenamiento. Posteriormente, se seleccionan las características correspondientes y se clasifican las muestras. Si las muestras pertenecen a la misma clase, entonces el nodo se convierte en un nodo hoja. Si no es de la misma clase, se selecciona nuevas características para clasificar la muestra. Se realiza un proceso de poda del árbol de decisión principalmente para eliminar la complejidad en las muestras y sobreajuste. Para ello se debe calcular la entropía de la información (ver ecuación 3.7) y la ganancia de información (ver ecuación 3.8) (Jing, Zhao, Zhang, & Ruan, 2019).

$$\text{Entropía } (t) = - \sum_{c=1}^c p\left(\frac{c}{t}\right) \log_2 p\left(\frac{c}{t}\right) \quad 3.7$$

Donde:

c = número total de categorías

$p\left(\frac{c}{t}\right)$ = Frecuencia de ocurrencia de una clase c en un nodo t

La ganancia de la información es cuando disminuye la entropía de la información (Jing, Zhao, Zhang, & Ruan, 2019).

$$E_k - \sum_{k=1}^k \frac{n_k}{n} \text{Entropía} \quad 3.8$$

$$\text{InfoGain} = \text{Entropía}(t_0) - E_k$$

Donde:

$K = \text{nodos hijos}$

$\text{Entropía}(t_0)$: indica la entropía de información del nodo padre.

$\text{Entropía}(t_k)$: indica la entropía de información del nodo hijo.

$t_0 = \text{nodo padre}$

$t_k = \text{nodo hijo}$

$n = \text{número de ejemplos del nodo padre.}$

$n_k = \text{número de ejemplos del nodo hijo}$

En el software WEKA se puede configurar diversos hiperparámetros como son: seed para configurar la semilla para aleatorizar la información, con la variable minNum se selecciona el peso mínimo total de las instancias por cada hoja del árbol. Además se puede determinar el número de pliegues en una aplicación por validación cruzada (Witten & Frank, 2005).

- *M5 Rules*. El algoritmo M5 Rules está basado en el algoritmo M5 que es una técnica de aprendizaje automático, que desarrolla un modelo tipo árbol. Este modelo representa la información de forma estructurada y además genera un ajuste lineal para las clases. Este algoritmo es similar al de un árbol de decisión convencional pero difiere en utilizar funciones lineales en las hojas en lugar de etiquetas para las clases (Goyal, 2014).

El algoritmo M5 construye el árbol dividiendo los datos en función de los valores de los atributos predictivos, por ello al incrementar el tamaño del árbol también se incrementan los requisitos computacionales para el análisis.

El algoritmo M5 elige atributos que minimizan la variación dentro del subconjunto. La variabilidad de estos datos es medido por la reducción desviación estandar de los valores que llegan al nodo desde la raíz hasta la rama. La división de valores es detenida cuando los valores de todas las instancias que llegan al nodo varían levemente o quedan pocas instancias.

La reducción de la desviación estandar (SDR) es calculada conforme la ecuación 3.9 (Goyal, 2014).

$$SDR = sd(T) - \sum_i \frac{|T_i|}{|T|} \times sd(T_i) \quad 3.9$$

Donde:

T = grupo de datos que alcanzan el nodo.

T_i = grupo de datos de salida del nodo.

sd = desviación estandar

Este algoritmo tiene funciones de regresión lineal en sus hojas, en el cual puede predecir atributos numéricos continuos. Este algoritmo genera modelos representados como árboles donde cada una de sus ramas es una regresión lineal, permitiendo evaluar decisiones con base en cada rama y determinar el error en cada decisión (Witten & Frank, 2005).

- *LWL*. El algoritmo *LWL* (Locally Weighted Learning) Aprendizaje ponderado localmente se divide normalmente en cuatro categorías que son de aprendizaje basados en distancias, centroides y modelos locales ponderados o modelos globales ponderados. El algoritmo basado en distancia clasifica los datos calculando la distancia entre ellos (Valores de prueba y valores de entrenamiento) y son almacenados internamente (Hernández Luquín & Escalante, 2020). Estos algoritmos utilizan una regresión lineal para ajustar el subconjunto de instancias de entrenamiento que se encuentran en el vecindario de instancias de pruebas. Las instancias de

entrenamiento en el vecindario son ponderadas de acuerdo a la inversa de la distancia de las instancias de prueba con menor peso. La predicción es realizada a partir de la regresión lineal tomando los valores de atributo de la instancias de prueba como valores de entrada (Li & Jiang, 2006).}

En el software WEKA se puede configurar el clasificador o regresor como puede ser Naives Bayes o regresión lineal. En este algoritmo se puede configurar el numero de lotes BatchSize que se utilizara para la predicción. En caso de utilizar KNN como modelo de clasificación se configura el parámetro nearestNeighbourSearchAlgorithm donde se configura el numero de vecinos cercanos para determinar el ancho de la función de peso. El parámetro weightingKernel determina la función de ponderación donde 0=lineal, 1 =Epanechnikov, 2 =Tricube, 3 = Inverso, 4 = Gaussiano, 5 = Constante. En caso de no seleccionar la función por default seleccionara el parámetro lineal (Witten & Frank, 2005).

- *Random Subspace* y *bagging* son meta algoritmos de ensamble. Bagging es una técnica de aprendizaje de ensamble. Este algoritmo es un acronimo derivado de Bootstrap AGGregatING. Cada miembro del ensamble es construido de un grupo de datos en ensamble diferente. Los modelos son combinados por un promedio uniforme. Este algoritmo tiende a trabajar correctamente en modelos lineales (Sammut & Webb, Bagging, 2017). El algoritmo Random Subspace es una técnica de aprendizaje de ensamble. El principio es incrementar la diversidad entre los miembros de ensamble por la restricción de clasificadores para trabajar en un subconjuntos del espacio completo de funciones. Cada clasificador aprende con un subconjunto de tamaño elegido aleatoriamente (Sammut & Webb, Random subspace method, 2017).

3.4 VALIDACIÓN DE MODELOS DE REGRESIÓN EN WEKA

Existen diversas maneras de validar los modelos con WEKA, dependiendo del número de muestras, tamaño de población y tipo de datos se procede a elegir la validación más adecuada. WEKA maneja dos tipos principales de validación:

- Por división de población, es decir, se elige un tamaño de muestra para los datos de entrenamiento y la otra parte para para evaluar el algoritmo (Navas Moreno, 2016).
- Por validación cruzada. Esta técnica se utiliza dividiendo la base de datos en un mismo número de datos, es decir, la base de datos es particionada en N cantidades; N-1 son las particiones que serán utilizadas como datos de entrenamientos y la partición N se utilizará como datos de validación (Witten & Frank, 2005).

En este trabajo se utilizan dos técnicas de validación, la primera es dividiendo la base de datos aleatoriamente en un 66% para datos de entrenamiento y un 34% para datos de validación. La segunda técnica es realizando una validación cruzada con 11 pliegues para cada uno de los algoritmos (Witten & Frank, 2005).

3.5 MÉTRICAS DE EVALUACIÓN EN WEKA

Como resultado de la evaluación de los algoritmos de predicción, WEKA maneja tres métricas de evaluación:

- El **error medio absoluto**, expresado en la Ecuación (3.1), es el promedio de la magnitud de los errores individuales sin tomar en consideración su signo. El error medio cuadrático tiende a exagerar los efectos de los puntos fuera de serie, pero el error absoluto no tiene dicho efecto. Para su cálculo, se toma cada uno de los valores estimados (P_n) y se resta por los valores reales (a), se obtiene el valor absoluto de cada resta y posteriormente se suman todos los valores y se divide entre el tamaño del grupo de de datos (Witten & Frank, 2005).

$$MAE = \frac{|p_1 - a_1| + \dots + |p_n - a_n|}{n} \quad (3.1)$$

$$p = \text{Datos estimados}$$

$$a = \text{Valores reales}$$

$$n = \text{Tamaño de grupo de datos}$$

- La **raíz cuadrada del error medio**, expresada en la Ecuación (3.2), es una de las métricas más utilizadas. La raíz cuadrada es utilizada para dar las mismas dimensiones del valor predicho. Es una medida de desempeño donde calcula la diferencia del valor predicho versus valor real y posteriormente la eleva al cuadrado (Witten & Frank, 2005). Cada una de estas diferencias será sumada y dividida entre el número de muestras. Finalmente, se obtendrá la raíz cuadrada de este resultado (Witten & Frank, 2005).

$$RSME = \sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}} \quad (3.2)$$

$$p = \text{Datos estimados}$$

$$a = \text{Valores reales}$$

$$n = \text{Tamaño de grupo de datos}$$

- El **coeficiente de correlación**, expresado en la Ecuación (3.3), es la medida estadística entre la muestra real y la muestra predicha. Tiene un rango de -1 a 1 donde entre más próximo a 1 significa que tienen una correlación perfecta, y cuando tiene a cero no tiene correlación. Para su cálculo se requiere dividir S_{PA} entre raíz del producto S_p y S_A . En cada cálculo se toma el valor real y valor estimado, se resta la media del grupo correspondiente, posteriormente se eleva al cuadrado y se realiza la sumatoria (Witten & Frank, 2005).

$$CC = \frac{S_{PA}}{\sqrt{S_p S_A}}, \text{ donde } S_{PA} = \frac{\sum_i (p_i - \bar{p})(a_i - \bar{a})}{n-1}, \quad (3.3)$$

$$S_p = \frac{\sum_i (p_i - \bar{p})^2}{n-1}, \text{ y } S_A = \frac{\sum_i (a_i - \bar{a})^2}{n-1},$$

$$\bar{p} = \text{valor estimados (media)}$$

p = valor estimados (individual)

\bar{a} = valor real (media)

a = Valores reales (individual)

n = Tamaño de grupo de datos

3.6 ESTADO DEL ARTE

Todo proceso de producción requiere continuar evolucionando con el fin de optimizar la eficiencia y eficacia del proceso. A pesar de que ha mejorado en uso de nueva tecnología como modulación de onda, transferencia metálica, hibridación con otros procesos, se requieren implementar nuevos métodos o ciencias aplicadas para mejorar la factibilidad en la industria.

Existen algunos trabajos de investigación acerca de la aplicación de inteligencia artificial a los procesos de soldadura. En Abhulimen (2014) aplicaron una red neuronal para determinar los parámetros de un proceso GTAW en tuberías de acero, prediciendo el esfuerzo de cedencia y de tensión con una media cuadrada de 34.2 volts para el rendimiento general; los errores relativos fueron de 18% y 0.02% para los esfuerzos de 22 MPa y 0.09 MPa, respectivamente. El trabajo muestra una predicción exitosa de la red neuronal para las propiedades mecánicas de la junta soldada. En esta investigación, el modelo generado representa las propiedades mecánicas de la tubería de acero, a diferencia de este trabajo que el modelo describirá la geometría del perfil transversal de la soldadura (Abhulimen & Achebo, 2014).

Ngo (2019) desarrollaron un método para predecir la fuente de calor y temperatura en el proceso de soldadura GMAW. En el método se emplean cuatro temperaturas experimentales e inversamente se estiman la fuente de calor y el campo de calor bajo diferentes condiciones como: corriente (148 – 160 A), voltaje (19.5-20 V), velocidad de soldadura (3.5-5.0 mm/s), tiempo de soldadura (47-67 segundos) y calor inverso (13.51-14.85 W/mm³). Con las predicciones logradas se pueden determinar las deformaciones de soldadura, los esfuerzos residuales, y las

penetraciones de soldadura. Este proyecto se centra en el modelo de predicción inverso vs la temperatura observada (Ngo, Wang, Huang, & Than, 2019).

Los parámetros de soldadura son críticos como se explicó en la Sección 2.1. Izzatul (2012) explica en su investigación los efectos de los parámetros en el proceso de soldadura GMAW y cómo afectan dichos factores la penetración de soldadura, microestructura y dureza. En la investigación se determinó que al incrementar los valores de amperaje se incrementa significativamente la penetración. De acuerdo con el trabajo de investigación, la penetración se ve afectada directamente por las características del voltaje de arco y velocidad de avance. En este trabajo se logró una buena penetración con valores de velocidad de 60 cm/min con un voltaje de 26 volts y 210 amperes. Además, se determinó que el tamaño de los límites de grano es afectado dependiendo de los parámetros de soldadura. Esta investigación logra correlacionar los parámetros de soldadura (variables eléctricas) con algunas propiedades físicas de la soldadura. Algunos de los parámetros de entrada definidos son iguales a los aplicados en esta investigación; sin embargo, en este trabajo no se aplica ningún algoritmo de minería de datos o inteligencia artificial para realizar los modelos de correlación entre las variables de entrada y salida (Ibrahim, Mohamat, Amir, & Ghalib, 2012).

Ramos-Jaime (2013) estudiaron los efectos de los parámetros de proceso en soldadura robótica GMAW para estimar el área de la soldadura. En su investigación generan un modelo para entender la relación entre los parámetros del proceso y el área transversal de soldadura, empleando una Función Radial Básica (RBF, en inglés) de una red neuronal para predecir la condición óptima de la sección transversal. El modelo generado obtiene un error de predicción de 20%. En esta investigación, los autores aplican herramientas analíticas como diseño factorial, redes neuronales, K-means y algoritmos genéticos con la finalidad de calcular el área transversal del proceso de soldadura. La diferencia de este trabajo contra el presente es que el autor utiliza funciones para predecir la sección transversal de una junta a tope; en cambio, en esta investigación se aplican para una junta en

traslape con soldadura de filete, además de utilizar parámetros para una soldadura GMAW pulsada (Ramos-Jaime, López-Juárez, & Pérez, 2013).

Otros autores como Oh (2019) han realizado estudios acerca del desarrollo de algoritmos inteligentes para el control de los parámetros de soldadura en juntas a tope. El modelo desarrollado es una red neuronal para el estudio de los parámetros de soldadura y predecir el área de soldadura (Oh , y otros, 2019).

Manikya (2008) utilizan un algoritmo de retropropagación para predecir la geometría de soldadura en un proceso GMAW utilizando como variables de entrada el espesor del material base, la frecuencia de pulsado, la velocidad de alimentación de alambre, la velocidad de avance y la corriente pico, y como variables de salida la profundidad de soldadura y la convexidad. El modelo generado obtiene un coeficiente de correlación del 0.99 respecto al experimento realizado. La investigación de este trabajo tiene un fundamento similar a las variables de entrada del estudio del autor, utilizando como métrica de evaluación el coeficiente de correlación. La diferencia está en el número de variables de entrada y salida, ya que, en la investigación de este trabajo, además de predecir la profundidad de soldadura, se predecirá la pierna de soldadura (penetración en disco en eje x), la profundidad de soldadura (penetración en aro) y la dilución de soldadura (Manikya, 2008).

Además del algoritmo de retropropagación anteriormente revisado, existen otros algoritmos implementados. Por ejemplo, TLBO (Teaching-Learning Based Optimization, por sus siglas en inglés) desarrollado por Bhagwan (2018) en el cual los parámetros de soldadura juegan un papel determinante para la calidad de la unión soldada. La investigación se enfoca en la optimización de los parámetros en el proceso MIG (Metal Inert Gas) en un acero AISI 1018. Los autores consideran como parámetros de entrada la corriente, el espesor, el voltaje y la velocidad de alimentación de alambre. Mediante el uso de un arreglo ortogonal Taguchi y un diseño de experimentos, se realizó la comparativa de medición entre los resultados experimentales y la predicción del algoritmo obteniendo una desviación estándar

de 0.022 mm para el refuerzo de soldadura y una desviación de 0.186 mm para la penetración de soldadura (Bhagwan, Awale, Bhusare, & Nirantar, 2018).

Los autores determinan el modelo que cuenta con variables de respuesta como el refuerzo de soldadura, la penetración y ancho de cara. En el trabajo desarrollado se observó que al incrementar la corriente se incrementa significativamente la penetración, y al disminuir el voltaje disminuye el refuerzo de soldadura y ancho de la cara de soldadura (Bhagwan, Awale, Bhusare, & Nirantar, 2018).

El método Taguchi ha sido ampliamente utilizado para diversas aplicaciones. Una de ellas es la investigación respecto a la optimización paramétrica del proceso MIG en un acero inoxidable austenítico 316 L basado en el método Taguchi (Nabendu, Pradip, & Goutam, 2016). En esta investigación realizan inspección visual y radiografías para detectar defectos en las superficies de soldadura utilizando como parámetros de entrada la corriente eléctrica, el flujo de gas, la distancia punta pieza, y como variables de salida el esfuerzo de cedencia, el esfuerzo de tensión y el porcentaje de elongación. En la investigación se encontró que la corriente es la variable de mayor significancia respecto al flujo de gas y al stick out para el esfuerzo de la junta. Los autores también determinaron la combinación de parámetros para el proceso ideal para reducir la cantidad de defectos superficiales, con una corriente de 100 A, un flujo de gas de 20 l/min y una distancia de 15mm. De acuerdo con el análisis de varianza, en la corriente se obtuvo un porcentaje de contribución de 59.58% en las propiedades mecánicas.

Hakan (2007) presentan una técnica basada en redes neuronales y contemplan los parámetros de mezcla de gas y propiedades mecánicas como esfuerzo de impacto, esfuerzo de tensión, elongación y dureza. Con el modelo de Red Neuronal Artificial (ANN, en inglés) obtenido se pueden calcular las propiedades mecánicas como es: el esfuerzo de tensión, elongación, dureza y resistencia al impacto, obteniendo un porcentaje de error medio cuadrático para el esfuerzo de tensión de 0.22%, esfuerzo de impacto 1.94%, elongación 3.43% y dureza 1.81%. Este trabajo difiere de la presente investigación, ya que los parámetros a predecir son las

propiedades mecánicas; sin embargo, en esta investigación los parámetros a predecir son las variables dimensionales del perfil transversal de la soldadura (Hakan, 2007).

Sukhomay (2008) desarrollan un modelo de red neuronal artificial para la predicción del esfuerzo de la junta soldada en un proceso GMAW – P. Los autores utilizan una metodología de superficie de respuesta en la experimentación y la ANN para predecir el último esfuerzo de tensión (UTS, por sus siglas en inglés). Los parámetros de entrada declarados son voltaje de impulso, voltaje base, tiempo de impulso, frecuencia de impulso, velocidad de alimentación de alambre y velocidad de avance, y como variable de salida, el UTS. Además, al realizar un análisis entre la predicción con la ANN y el análisis de regresión múltiple se obtuvo que la red neuronal tiene menor error de predicción respecto al modelo de regresión (Sukhomay, Surjya, & Arun, 2008).

Con los modelos de redes neuronales y análisis de regresión múltiple, se logró obtener un error de predicción de aproximadamente 8% para el esfuerzo último de tensión. Este trabajo realizó una comparación de modelos matemáticos para predecir las propiedades mecánicas. En contraste, esta investigación se enfoca en obtener modelos de predicción para las variables dimensionales del perfil transversal de la soldadura.

El uso de herramientas de análisis como diseño de experimentos, redes neuronales y algoritmos evolutivos son cada día más utilizados; un ejemplo de ello es la investigación realizada por Benyounis (2008) donde realizan una revisión bibliográfica de algunos métodos de modelación matemática, como son: diseño factorial, regresión lineal, metodología de superficies de respuesta, diseño Taguchi, redes neuronales, entre otras, para la predicción de propiedades mecánicas y dimensionales en procesos de soldadura. Este trabajo es únicamente teórico, no cuenta con análisis experimental (Benyounis & Olabi, 2008).

El uso de algoritmos genéticos no se centra únicamente en aplicaciones de proceso GMAW. Existen investigaciones en otros procesos como Electron Beam Welding (Soldadura de haz de electrones), donde Vidyut (200) desarrollan un modelo de optimización para un proceso de soldadura EBW en placas de acero inoxidable austenítico. La investigación fue realizada para establecer el área mínima de soldadura y así satisfacer las condiciones de penetraciones de soldadura máxima. El algoritmo genético fue capaz de alcanzar una óptima solución global, cumpliendo las condiciones previamente mencionadas. Los autores toman como variables de entrada el voltaje de aceleración, corriente del láser y velocidad de soldadura y como variables de salida la altura, ancho de la cara de soldadura y la penetración de soldadura. Con el algoritmo genético, los autores determinan que con los valores de 90kV, 8.78 mA y 75.99 cm/min se logran obtener las condiciones óptimas de 0.48 mm la cara de soldadura, 1.87mm el ancho de soldadura y 5.02mm la penetración de soldadura. Este trabajo difiere de este estudio principalmente por el tipo de proceso que se está utilizando, además de las variables de entrada y salida (Dey, y otros, 2009).

Además de las redes neuronales y algoritmos genéticos, existen otros métodos o herramientas que se utilizan para realizar análisis de predicciones. Ganjigatti (2007) realizan un análisis de regresión global y un análisis de regresión cluster-wise para determinar la relación de las entradas y salidas en un proceso de soldadura MIG. En este trabajo se determinan como variables de entrada la velocidad de avance, el voltaje, la velocidad de alimentación de alambre, el flujo de gas, la distancia punta pieza y el ángulo de antorcha, y como valores de respuesta la altura, el ancho de cara y la penetración de la soldadura. El valor máximo de desviación fue de 28.275% y el valor menor de desviación fue de -2.347%. De acuerdo con la investigación, el análisis cluster-wise tiene mejores resultados de la predicción respecto al análisis global; esto se debe a que el análisis cluster-wise tiene mayor precisión en los sistemas dinámicos (Ganjigatti, Dilip, & Choudhury, 2007).

Existen procedimientos convencionales para la determinación de parámetros de entrada de los procesos de soldadura. En la investigación de Palani (2008)

determinan un estudio para predecir las condiciones de una buena soldadura con base en el cálculo de la corriente media, tiempo de impulso y frecuencia. Uno de los resultados es que los parámetros de pulsado (corriente de pulsado y tiempo de impulso) son variables que juegan un rol dominante en las propiedades de la soldadura. Los autores toman como criterios primarios algunas variables como desprendimiento de la gota de soldadura, la tasa del electrodo fundido y la estabilidad del arco para la selección de los parámetros de una soldadura de arco eléctrico con atmósfera protegida pulsada. Esta investigación es únicamente teórica, no tiene condiciones de experimentación a diferencia del estudio desarrollado en esta investigación (Palani & Murungan, 2006).

Saedi (2018) desarrollan un modelo de red neuronal para predecir el comportamiento de las conexiones de soldadura en ángulo en fuego. En la investigación se realizan 47 pruebas experimentales y se verifican usando un modelo de elemento finito para el entrenamiento y prueba de la ANN. El modelo desarrollado puede predecir el momento de rotación y la temperatura de una unión semi rígida con una alta precisión. En este modelo se determina como variable de entrada la temperatura y como valor de salida la rotación. Los autores obtienen un coeficiente de R^2 de 0.99 como resultado del modelo desarrollado, lo que significa una alta precisión del modelo. En esta investigación, los autores se enfocan en desarrollar un modelo capaz de predecir el comportamiento de una soldadura y su momento de rotación de la junta soldada (Saedi Daryan & Yahyai, 2017).

Por otro lado, Abhulimen (2014) desarrolla un estudio experimental para predecir la penetración de la soldadura de filete de un lado, realizando un monitoreo de la abertura o separación entre las juntas, denotando como principal variable la variación de las juntas. En este trabajo, los autores se enfocan en predecir la penetración de soldadura tomando en consideración la abertura de la junta soldada. En la presente investigación no se toma dicha abertura, ya que esta tiene mínima variabilidad por el tipo de proceso y ensamble que se utiliza (Abhulimen & Achebo, 2014).

Algunos autores han trabajado en la predicción de penetración para el proceso SAW o soldadura por arco sumergido. Alam (2011) desarrollan un diseño de experimentos de factorial completo de dos niveles. El experimento es realizado en una placa de acero de 12mm de espesor. El objetivo de la investigación es predecir la penetración y analizar el comportamiento de las variables de soldadura en la penetración. Conforme a los resultados de la investigación, el alto voltaje, la corriente eléctrica y la velocidad de alimentación de alambre incrementan significativamente la penetración de la soldadura. Sin embargo, al incrementar la velocidad de desplazamiento de la soldadura, la distancia de la pieza al plato, la penetración decrece. En la investigación se logró un modelo adecuado con un nivel de confianza de 95% (Alam & Khan , 2011).

Tham (2017) realizan estudios de la geometría de la junta soldada con electrodos cortos de arco sumergido en posición 1G desarrollando una correlación entre la geometría de la junta soldada y los parámetros del proceso de soldadura, aplicando ecuaciones de línea de tendencia para predecir la junta. Con esta investigación, el autor logró obtener una desviación de 1mm únicamente utilizando las líneas de tendencia y calculando la desviación media absoluta. La diferencia de esta investigación con la presente es que no aplica ningún algoritmo de aprendizaje automático e inteligencia artificial para predecir la geometría de la junta soldada (Tham, Mohamad, Faruqi, & Saedon, 2017).

Abdullah (2012) desarrollan un estudio comparativo entre un análisis estadístico por diseño de experimentos y la aplicación de un modelo de redes neuronales artificiales distribuidas en paralelo, donde las variables de salida son la geometría y la profundidad de la zona térmicamente afectada. De acuerdo con los resultados de la investigación, el error de predicción para el ancho de la cara de soldadura es mayor, en comparación con el error de predicción para la penetración. El porcentaje de error medio para la penetración de soldadura es menor al 1%. El autor además de predecir la geometría de la junta soldada toma en consideración como variable de salida la zona térmicamente afectada. En la presente investigación no se considera la ZAT (por sus siglas en inglés) ya que los parámetros

de entrada y salida fueron calificados y ya está considerada las condiciones mínimas y máximas de zona térmicamente afectada (Al-Faruk, Hasib, Ahmed, & Das, 2010).

Sing (2015)] realizan un estudio de optimización de parámetros de soldadura SAW evaluando la calidad de la soldadura con base en los parámetros de soldadura y la polaridad. En este trabajo se utilizan como variables de entrada la velocidad de alimentación de alambre, el voltaje, la velocidad de avance y distancia punta-pieza, y como variables de salida el refuerzo de soldadura, el tamaño de la penetración de soldadura, la dilución y el factor de refuerzo. De acuerdo con los resultados, la polaridad tiene un profundo efecto en la geometría de la soldadura, además de que en polaridad inversa la soldadura es más suave respecto a polaridad directa (Sing, Garg, & Shukla, 2015).

Katherasan (2012) desarrollan un estudio de optimización de parámetros, determinando como variables de entrada: voltaje, velocidad de alimentación de alambre, velocidad de avance y ángulo de antorcha, y como valores de salida: refuerzo, ancho de soldadura y profundidad de penetración. Esta investigación es desarrollada con la aplicación de algoritmos genéticos y el algoritmo metaheurístico de optimización global llamado Annealing Simulated algorithm en un proceso de soldadura FCAW. El modelo matemático fue desarrollado obteniendo un error cuadrático de 87.7% para el ancho de soldadura, 80.7% para el refuerzo de soldadura y 86.3% para la penetración de soldadura. En esta investigación, el autor toma como una de sus variables de entrada el ángulo de la antorcha. Esta variable en la presente investigación se declara como una constante ya que esta variable permanece constante durante todos los procesos por las condiciones y geometrías de la máquina, además el proceso de soldadura que investigan los autores utiliza un electrodo tubular a diferencia del proceso objeto de este estudio que utiliza un electrodo sólido (Katherasan, 2012).

Balamurugan (2013) realizan una investigación para optimizar los parámetros del proceso de soldadura por fricción en un acero 904L super-austenítico aplicando redes neuronales y optimización por enjambre de partículas. Los autores desarrollan un arreglo ortogonal Taguchi y determinan como variables de entrada la velocidad de rotación, la presión de fricción, el ajuste de presión y la longitud de quemado, para determinar el esfuerzo de la junta soldada. Los autores utilizaron pruebas de esfuerzo de tensión y cedencia para determinar las fracturas en las superficies y analizarlas. En esta investigación se determinó que con los valores de entrada de 1,827.27 rpm de velocidad, 78.252 MPa de presión de fricción, 173.53 de presión y 4,4118 de longitud de quemado, se logró obtener una soldadura en un tiempo de 43.17 segundos con las siguientes óptimas condiciones: LPDZ en 0.516 mm, RPDZ en 0.609 mm y esfuerzo de tensión de 685.17 MPa (Balamurugan, Abhilash, Sathiya, & Naveen Sait, 2014).

En la Tabla 6 se presenta el resumen de los artículos revisados en el estado del arte, donde se colocaron en las columnas las variables de entrada y variables de salida de cada investigación, así como el proceso utilizado. En la Tabla 7 se presentan los algoritmos utilizados en cada investigación.

Como se puede apreciar en la Tabla 6, la mayoría de las investigaciones fueron realizadas para el proceso de soldadura GMAW utilizando como variables de entrada el voltaje, amperaje, velocidad de soldadura y velocidad de alimentación de alambre y como variables de salida la penetración de soldadura y refuerzo de soldadura.

Tabla 6 Resumen de variables de entrada y salida de investigaciones en estado del arte

Referencia	Proceso	Variables de entrada										Variables de salida																								
		Voltaie de salida	Espesor	Amperaje de salida	Voltaie Imoulsio	Tiembimpulso	WFS	Velocidad de avance de soldadura	Diámetro de electrodo	Frecuencia	Flujo de gas	Tiempo de soldadura	Calor inverso	Angulo de soldadura	Tiño de gas	Corriente pulsado	Stick Out	Esfuerzo de cedencia	Esfuerzo de tensión	Esfuerzo residual	Temperatura en soldadura	Resistencia al impacto	Elongación	Microestructura	Zona termicamente afectada	Dureza	Tiempo de soldadura	Convexidad	Refuerzo de soldadura	Tamaño de grano	Dilución	Gap	Penetración de soldadura			
(Ngo, Wang, Huang, & Than, 2019)	GMAW									x	x								x	x																
(Ibrahim, Mohamat, Amir, & Ghalib, 2012)	GMAW	x		x			x																x		x							x			x	
(Ramos-Jaime, López-Juárez, & Pérez, 2013)	GMAW-P	x				x	x																												x	
(Oh , y otros, 2019)	GMAW	x		x			x					x				x																			x	
(Manikya, 2008)	GMAW					x			x							x																			x	
(Bhagwan, Awale, Bhusare, & Nirantar, 2018)	MIG	x	x	x		x																										x			x	
(Nabendu, Pradip, & Goutam, 2016)	MIG	x								x						x	x	x							x											
(Hakan, 2007)	GMAW												x					x				x	x			x										
(Sukhomay , Surjya, & Arun, 2008)	GMAW	x			x	x	x		x										x																	
(Benyounis & Olabi, 2008)	GMAW																																			
(Ganjigatti, Dilip, & Choudhury, 2007)	MIG	x				x	x		x				x			x																x			x	

Fuente: Elaboración propia.

Tabla 7 Continuación de Tabla 6 de variables de entrada y salida de investigaciones en estado del arte

Referencia	Proceso	Variables de entrada										Variables de salida																												
		Voltaje de salida	Espesor	Amperaje de salida	Voltaje Impulso	Tiempo Impulso	WFS	Velocidad de avance de soldadura	Diámetro de electrodo	Frecuencia	Flujo de gas	Tiempo de soldadura	Calor inverso	Anulo de soldadura	Tipo de gas	Corriente pulsado	Stick Out	Esfuerzo de cedencia	Esfuerzo de tensión	Esfuerzo residual	Temperatura en soldadura	Resistencia al impacto	Elongación	Microestructura	Zona termicamente afectada	Dureza	Tiempo de soldadura	Convexidad	Refuerzo de soldadura	Tamaño de grano	Dilución	Gap	Penetración de soldadura							
(Palani & Murungan, 2006)	GMAW-P																																							
(Abhulimen & Achebo, 2014)	MAG	x		x			x	x						x			x																		x	x				
(Alam & Khan, 2011)	SAW	x					x	x									x																				x			
(Tham, Mohamad, Faruqi, & Saedon, 2017)	SAW	x		x				x									x																					x		
(Al-Faruk, Hasib, Ahmed, & Das, 2010)	GMAW	x		x			x	x	x															x															x	
(Sing, Garg, & Shukla, 2015)	SAW	x					x	x									x																						x	
(Katherasan, 2012)	FCAW	x					x	x									x																							x

Fuente: Elaboración propia.

En este trabajo de investigación se utilizaron como variables de entrada la velocidad de alimentación de alambre, frecuencia, corriente base, tiempo de impulso, tensión de impulso, voltaje de salida, corriente de salida, velocidad de soldadura y calor de entrada. Las variables de salida utilizadas fueron la dilución de soldadura, penetración en disco en el eje X y penetración en aro.

Tabla 8 Algoritmos o herramientas de análisis utilizados en cada investigación.

Referencia	Algoritmo
26	Elemento Finito y técnicas de optimización
27	Correlación Pearson
28	Función Radial Básica DOE Algoritmos genéticos
29	Inteligencia artificial
30	Algoritmo IA retropropagación
31	Algoritmo TLBO (Teaching-Learning Based Optimization) DOE Taguchi
32	DOE Taguchi
33	Red Neuronal Artificial
34	ANN y Regresión múltiple.
35	Revisión Literaria enfoque estadístico
36	Algoritmos genéticos
37	Cluster wise-regression Analyze
38	Revisión Literaria
40	Binarización, Análisis de imagen
41	Diseño de experimentos
42	Regresión lineal simple
43	Redes Neuronales
44	Diseño de experimentos
45	Algoritmos genéticos y Algoritmos de recocido simulado
46	Redes Neuronales y optimización por enjambre de partículas

Fuente: Elaboración propia.

4. IMPLEMENTACIÓN DE ALGORITMOS

La investigación se divide en cuatro secciones fundamentales, las cuales se presentan a continuación.

1. Recopilación de información y construcción de base de datos general. Se colectó la información del proceso de soldadura para el rin a evaluar durante un periodo de dos años.
2. Preprocesamiento de información. Se aplicaron diversos filtros para depurar la base de datos previo a la evaluación de los algoritmos.
3. Aplicación de algoritmos. Teniendo la base de datos preparada, se prosiguió a analizar evaluando con el software WEKA y Python. El entorno de programación Python fue utilizado para el preprocesamiento, limpieza y graficado de los modelos y el software WEKA fue utilizado para la implementación de los algoritmos de regresión. En el caso de WEKA se realizó la evaluación de once algoritmos con dos técnicas de implementación: división de base de datos en entrenamiento-evaluación y evaluación cruzada. Finalmente se realizó el análisis comparativo entre los modelos desarrollados.

4.1 CONSTRUCCIÓN DE LA BASE DE DATOS

De acuerdo con el procedimiento de corte e inspección de penetración de soldadura presentada en el Capítulo 2 Sección 8, el inspector de soldadura realiza una inspección de cada cordón de soldadura de cada rin producido durante cada liberación, cambio de herramienta e intervención mayor. El procedimiento de colección de datos y generación de registros se presenta en la Figura 15.

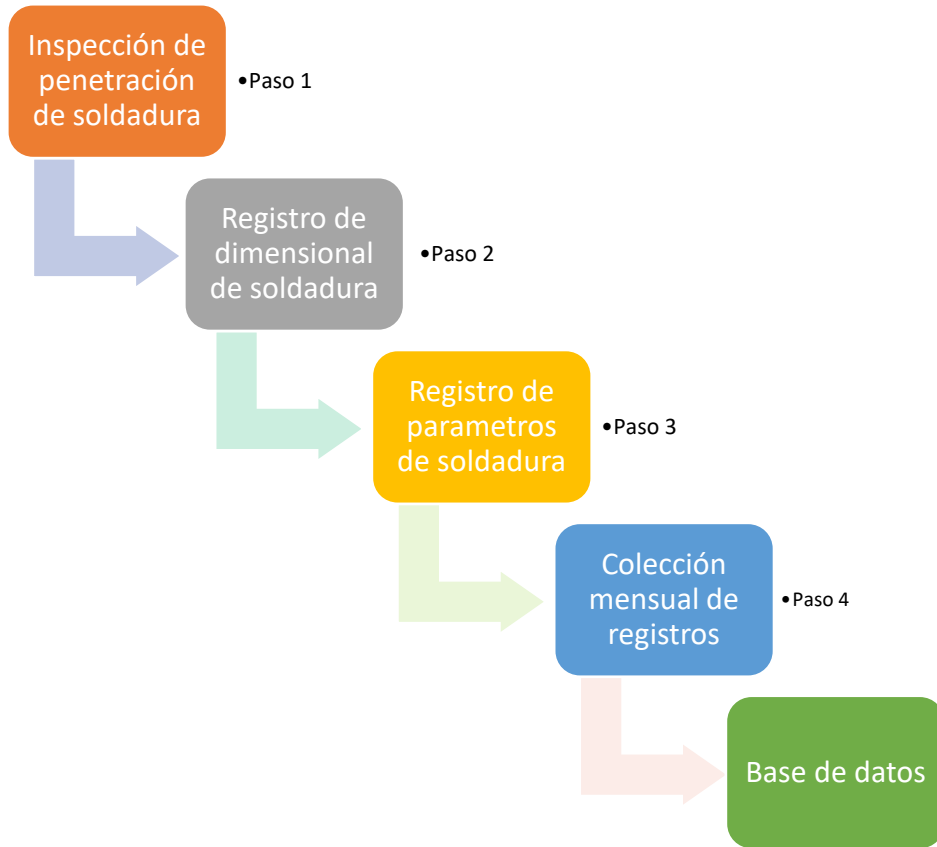


Figura 15. Mapa de proceso de generación de base de datos.

Fuente: Elaboración propia.

En el primer paso, el inspector realiza la inspección de penetración; posteriormente, registra el dimensional de la penetración en un registro de producción. Una vez que el inspector valida que el producto cumple el especificado, debe registrar los parámetros de soldadura que fueron utilizados para generar el proceso de soldadura. En la Figura 16 se presenta el mapa del proceso de soldadura, donde los parámetros de soldadura son los que ajusta el preparador y registra, y la salida del proceso es el dimensional del perfil transversal del rin obtenido durante la inspección de penetración.



Figura 16. Mapa de proceso de soldadura.

Fuente: Elaboración propia.

Los registros de penetración de soldadura y de parámetros de soldadura son colectados y archivados; los registros son guardados normalmente por 15 años más la vida del producto. Estos registros son los que serán utilizados para el análisis de información en esta tesis; para ello se recolectaron los registros del 2018 y 2019 de inspección de penetración de soldadura, generando una base de datos de 708 instancias con 17 columnas.

Las columnas describen los siguientes atributos de las instancias:

- Parámetros de entrada: velocidad de alimentación de alambre, frecuencia, corriente base, tiempo de impulso, tensión de impulso, voltaje de salida, corriente de salida, velocidad de soldadura y calor de entrada.
- Parámetros de salida: penetración en disco eje X, penetración en disco en eje Y, penetración en aro, fusión en aro, fusión en disco, garganta de soldadura y dilución de soldadura.

4.2 CÁLCULO DE CALOR DE ENTRADA

Para el cálculo de calor de entrada, se utilizó la norma AWS B2.1 – B2.1 M – Specification for Welding Procedure and Performance Qualification en la Sección 4.14.8 Electrical Characteristics (American Welding Society;, 2014), donde la norma

divide las fórmulas para dos tipos de fuentes: de onda controlada y de onda no controlada.

Dado que las fuentes Cloos de 600 amperes utilizan un proceso GMAW – Pulsado se aplicará la Ecuación (4.1) para calcular el calor entrada.

$$\text{Calor de entrada} \left(\frac{j}{mm} \right) = \frac{\text{Potencia} \left(\frac{I}{s} = W \right) \times \text{Tiempo de arco eléctrico(s)}}{\text{Longitud del cordón de soldadura (mm)}} \quad (4.1)$$

El calor de entrada se calcula multiplicando la corriente de salida de la fuente y el voltaje de salida. El tiempo de soldadura o tiempo de arco es un parámetro que se tiene registrado en los registros de inspección; este parámetro es directamente proporcional a la velocidad de soldadura. Finalmente, para el caso de la longitud del cordón de soldadura se tomó como una constante los 255.67 mm del cordón de soldadura.

4.3 CÁLCULO DE DILUCIÓN DE SOLDADURA

De acuerdo con el Capítulo 2 Sección 2.5.8 la dilución de soldadura es el cambio en la composición química de un metal de filete de soldadura causado por la mezcla del metal base o metal de soldadura anterior en el cordón de soldadura (American Welding Society, 2010). Este parámetro nos ayuda a determinar el porcentaje de material que fue fundido respecto al material depositado.

Para el cálculo de dilución de soldadura, ya que la junta es tipo filete, se tuvo que realizar un seccionado de áreas para determinar la dilución lo más próximo posible. Este procedimiento de seccionar el área del filete lo realizan en el trabajo de Hao (2018), donde se segmenta en áreas el material depositado y material que ha penetrado y posteriormente se dividen las áreas del material depositado entre el área total (Hao, Dong, Li, & Li, 2018).

En la Figura 17 se muestra el área total transversal del cordón de soldadura del material depositado. Dicha área se dividió en tres secciones, A1 es la sección de color verde y A3 es la sección de color azul; estas secciones son las que están

consideradas como el material de soldadura que penetró y fundió el material base. El área A2 de color amarillo es área triangular del filete de soldadura.




Figura 17. División de áreas de soldadura.

Fuente: Elaboración propia.

Para calcular A1 (ver Figura 18), primeramente, se tuvo que realizar la medición de 30 piezas con la ayuda de un comparador óptico digital (Contreras & Meneses, 2015). Posteriormente, se realizó el cálculo conforme la Ecuación (3.1), multiplicando las cotas dimensionales de Penetración en aro (P_a) y Fusión en Aro (F_a); con estas cotas se realizó un cálculo del área de rectángulo (área $A1 = F_a \times P_a$) y a dicha área se le multiplicó por un factor de 0.80 para tener una aproximación al área total. Este es un valor aproximado ya que no se puede realizar las mediciones de las áreas reales porque únicamente se archivan los registros de producción (como se mencionó en el Capítulo 4 Sección 1).

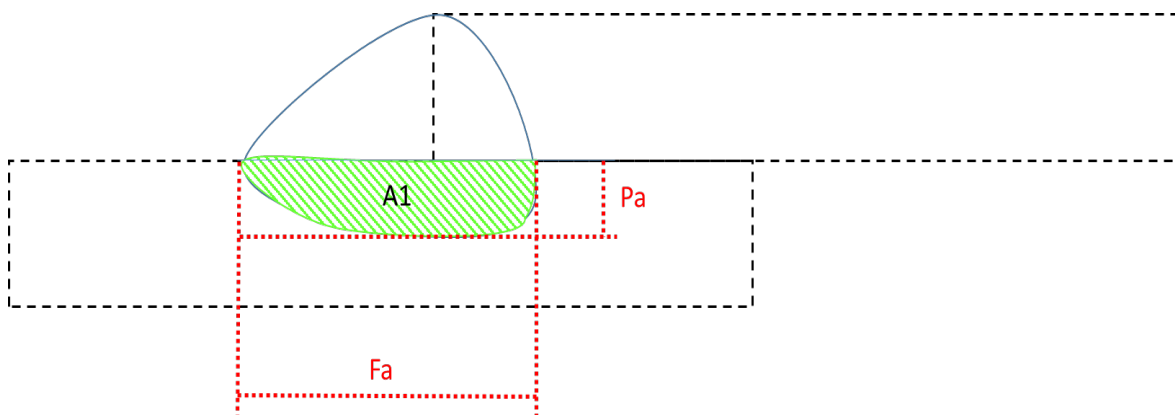


Figura 18. Cálculo del área 1.

Fuente: Elaboración propia.

$$A1 = \frac{Pa}{Fa} \times 0.80 \quad (3.1)$$

Para el cálculo de A2, primeramente, se calculó la base del triángulo (ver Figura 19). Conforme la Ecuación (3.2), se restó a la cota Fa la distancia de Pdx; posteriormente se realizó la multiplicación de dicha base por la altura Pdy y finalmente se dividió entre dos para obtener el área del triángulo.

Tanto las áreas A2 como A3 tienen una sección que podemos considerar como el refuerzo del triángulo, dicha área no fue considerada en los cálculos realizados.

Para el cálculo de A3, conforme a la Ecuación (3.3), se realiza una multiplicación entre las cotas Pdx y Pdy y posteriormente una división entre dos (Ver Figura 20).




Figura 19. Cálculo del área 2.

Fuente: Elaboración propia.

$$A2 = \frac{(Fa - Pdx) \cdot Pdy}{2} \quad (3.2)$$

Finalmente, el cálculo de la dilución se realiza como se muestra en el conjunto de Ecuaciones (3.4).

$$A3 = \frac{Pdy \cdot Pdx}{2} \quad (3.3)$$




Figura 20. Cálculo del área 3.

Fuente: Elaboración propia.

$$A_p = A_3 + A_1$$

$$A_r = A_2$$

$$Dilución = \frac{A_r}{(A_p + A_r)} \quad (3.4)$$

4.4 ANÁLISIS DE LA BASE DE DATOS GLOBAL

Como parte del análisis inicial se tomó la base de datos explicada en la Sección 3.1 y se utilizó el software WEKA versión 3.8.3 .

En la Figura 21 se presenta el diagrama de flujo para la evaluación del algoritmo aplicado en las tres características. Primero se realiza la limpieza de información de la base de datos, posteriormente se realiza el filtrado de los datos y finalmente se realiza la aplicación de los algoritmos de regresión con cada una de las características.

De cada algoritmo se obtendrán las tres métricas de evaluación y cada resultado se plasmará en una base de datos para su análisis posterior.

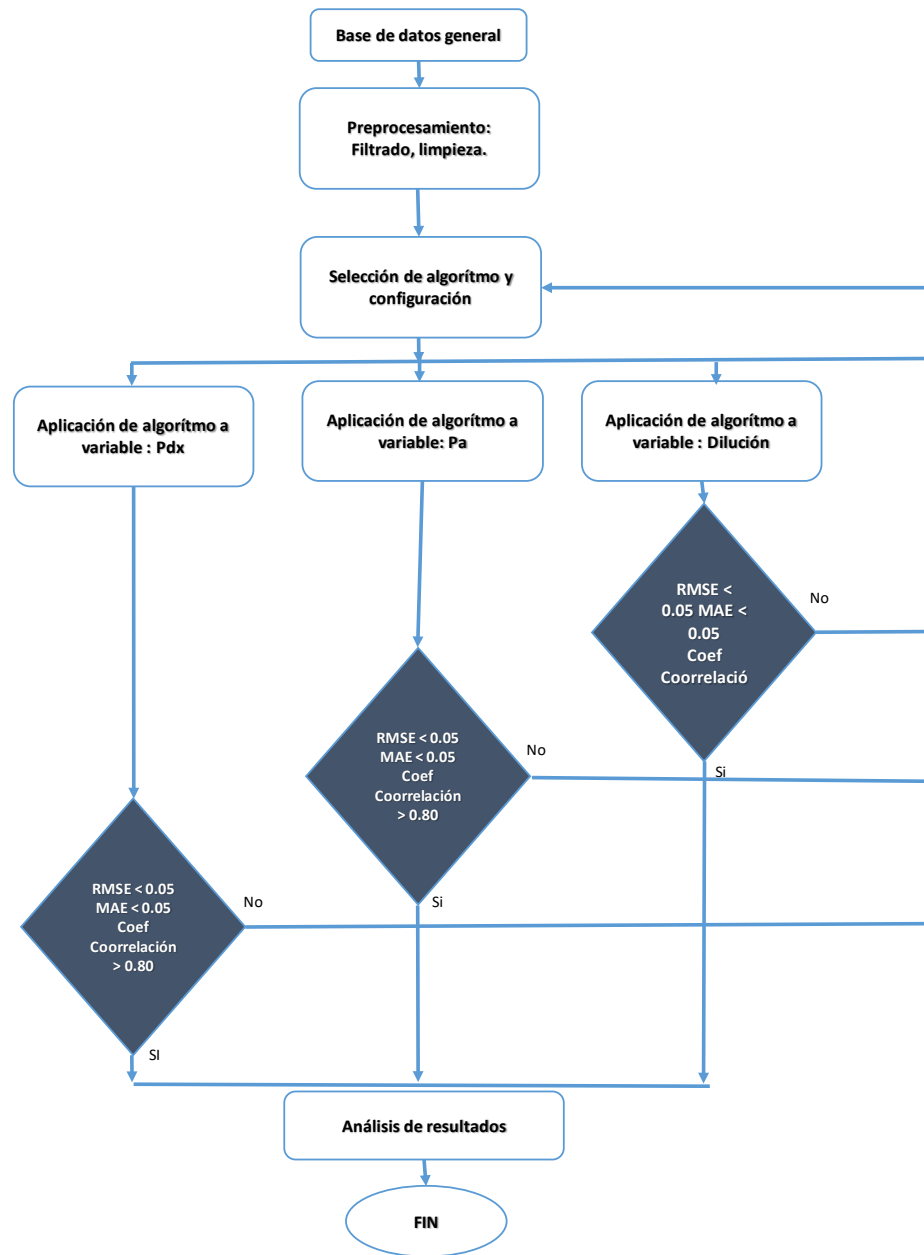


Figura 21. Diagrama de flujo de evaluación de algoritmos.

Fuente: Elaboración propia.

4.4.1 Preprocesamiento de base de datos

La base de datos contenía algunas filas con espacios vacíos y números 0, por lo que no puede ser cargada directamente en WEKA. Por ello fue realizado un preprocesamiento con Python (ver Figura 22). Se realizó un programa para cargar

la base de datos y con la librería Pandas se realizó la descripción del grupo de datos.

	WFS	Frecuencia	CorrienteB	...	G	Fd	D
count	715.000000	711.000000	711.000000	...	709.000000	708.000000	708.000000
mean	13.062973	254.358650	96.504923	...	6.041956	6.037306	0.419133
std	1.074616	32.077054	9.754142	...	0.673971	0.642890	0.066899
min	0.000000	0.000000	0.000000	...	0.000000	0.000000	0.000000
25%	13.000000	240.000000	95.000000	...	5.800000	5.785500	0.378290
50%	13.100000	260.000000	100.000000	...	6.110400	6.107000	0.409425
75%	13.300000	275.000000	100.000000	...	6.368000	6.367400	0.455800
max	14.300000	298.000000	110.000000	...	9.741600	9.741600	0.643323

Figura 22. Descripción de la base de datos global.

En la Figura 22 se puede observar un resumen estadístico básico que realiza la librería de la base de datos excluyendo los valores NaN o vacíos. En todas las columnas el valor mínimo es cero; estos espacios sin valores o vacíos generan variación cuando se apliquen los modelos de regresión, además de generar problemas en el análisis estadístico de la base de datos.

Con la ayuda del comando INFO, se puede observar en la Figura 23 que la base de datos contiene valores vacíos.

#	Column	Non-Null Count	Dtype
0	WFS	715 non-null	float64
1	Frecuencia	711 non-null	float64
2	CorrienteB	711 non-null	float64
3	TiempoImpo	712 non-null	float64
4	TensionImp	712 non-null	float64
5	TensionS	710 non-null	float64
6	CorrienteS	710 non-null	float64
7	Velocidad	709 non-null	float64
8	CalorEntrada	709 non-null	float64
9	Pdx	709 non-null	float64
10	Pdy	708 non-null	float64
11	Pa	708 non-null	float64
12	Fa	708 non-null	float64
13	G	709 non-null	float64
14	Fd	708 non-null	float64
15	D	708 non-null	float64

Figura 23. Tipos de valor en la base de datos

Usando la librería Missing Number (MSNO) se pueden visualizar los valores vacíos de nuestra base de datos (ver Figura 24) (Blogur, 2018).




Figura 24. Visualización de datos NaN de la base de datos global.

4.4.2 Limpieza y filtrado de datos

Para eliminar los valores NaN y los valores 0 de la base de datos se realizó la aplicación de dos comandos de la librería pandas. Primeramente, se aplicó el comando Replace para reemplazar los valores en las filas que contengan el número cero por un valor no numérico (NaN). Después, se utilizó el comando DropNaN para eliminar los valores no numéricos de la base de datos.

Posteriormente, se utilizaron los comandos Describe e INFO para revisar si se realizó la remoción de los valores no numéricos (ver Figura 25). Se graficó nuevamente el mapa de los valores NaN para revisar que ya no existiera ninguno en la base de datos (ver Figura 26).

	WFS	Frecuencia	CorrienteB	...	G	Fd	D
count	708.000000	708.000000	708.000000	...	708.000000	708.000000	708.000000
mean	13.153285	256.340395	97.193503	...	6.086351	6.073167	0.422082
std	0.394546	24.029713	5.405285	...	0.442133	0.454492	0.059473
min	11.400000	200.000000	65.000000	...	4.515000	4.515000	0.288101
25%	13.000000	240.000000	95.000000	...	5.805675	5.797200	0.380278
50%	13.100000	260.000000	100.000000	...	6.113800	6.112100	0.410733

Figura 25. Descripción de base de datos posterior al filtrado.




Figura 26. Visualización de los valores NaN posterior al filtrado.

Una vez realizado este proceso de filtrado se guardó la nueva base de datos en un archivo ARFF (Formato de archivo de relación de atributo) para analizarlo con WEKA (Morate, s.f.).

Antes de aplicar los algoritmos de regresión se aplicó un filtro de atributo no supervisado con WEKA llamado NumericCleaner. Este filtro se utiliza para determinar los límites mínimos y máximos en nuestra base de datos y eliminar los valores que estén fuera de dichos límites.

Los límites definidos para la aplicación del filtro específico fue conforme el procedimiento calificado de soldadura WPS (Welding Procedure Specification) (AWS D11 Committee on Welding Iron Casting, 1989).

En la Tabla 8 se muestran cada uno de los atributos de entrada y salida de la base de datos, el número de instancias (704 en total), los valores máximos y mínimos, así como datos estadísticos de cada atributo; este concentrado es realizado de manera posterior al filtrado de la información.

Tabla 9 Resumen estadístico de base de datos global.

Ítem	Nombre de atributo	Tipo	Número de instancias	Valor Mínimo	Valor Máximo	Media	Desviación estándar
1	Velocidad de alimentación de alambre	Entrada	704	11.4	14.3	13.153	0.395
2	Frecuencia	Entrada	704	200	298	256.301	24.067
3	Corriente Base	Entrada	704	65	110	97.199	5.411
4	Tiempo de impulso	Entrada	704	1.9	3.1	2.09	0.064
5	Tensión de impulso	Entrada	704	27.2	39.5	34.02	0.932
6	Tensión de salida	Entrada	704	22.6	33	27.42	0.858
7	Corriente de salida	Entrada	704	205	390	293.979	17.39
9	Velocidad	Entrada	704	78.29	89.80	83.65	2.94
10	Calor de entrada	Entrada	704	382.11	790.81	579.0	42.62
11	Pdx	Salida	704	1.03	3.98	2.08	0.52
12	Pdy	Salida	704	4.57	10.27	6.56	0.34
13	Pa	Salida	704	1.17	3.02	1.57	0.25
14	Fa	Salida	704	5.59	10.69	7.32	0.44
15	G	Salida	704	4.51	9.74	6.08	0.44
16	FD	Salida	704	4.51	9.74	6.07	0.44
17	Dilución	Salida	704	0.28	0.64	0.42	0.06

Fuente: Elaboración propia.

4.4.3 Generación de modelos de regresión

Una vez concluida la etapa de preprocesamiento y limpieza de la base de datos, se procede a aplicar algoritmos de regresión, conforme se presentó la Figura 21. Para evaluar el desempeño de los algoritmos se emplearon las siguientes métricas de evaluación: RSME, el MSA y el coeficiente de correlación.

La aplicación de los algoritmos únicamente fue para las cotas penetración en disco en eje X, penetración en aro y dilución, por ser las de mayor prioridad y variación para el proceso.

Para cada atributo de entrada fueron aplicados 11 algoritmos que fueron los que tuvieron un mayor coeficiente de correlación. Estos algoritmos se evaluaron utilizando dos técnicas de división de datos para las etapas entrenamiento y validación. En la primera se utilizó validación cruzada con 11 pliegues y en la segunda se dividió la base de datos en 66% para datos de entrenamiento y 34% para datos validación.

Los algoritmos aplicados para el análisis de datos fueron los siguientes:

- *Linear regression*
- *Multilayer Perceptron*
- *Bagging*
- *Random subspace*
- *M5 Rules*
- *Random Forest*
- *Rep Tree*
- *Gaussian Processes*
- *SMO reg*
- *LWL*
- *Decision Table*

4.5 ANÁLISIS DE LA BASE DE DATOS OPTIMIZADA

En el Capítulo 4 Sección 4 se pudo observar que al aplicar el preprocesado, limpieza de datos y aplicación de algoritmos de regresión de la biblioteca de WEKA para la predicción de los tres atributos: penetración en aro, penetración en disco en eje X y dilución, los valores obtenidos de coeficiente de correlación nunca fueron mayores a 0.55 en ninguno de los 11 algoritmos implementados. Por ello, fue decido analizar nuevamente la base de datos.

Uno de los puntos explicados en el Capítulo 4 Sección 1 fue que la base de datos global estaba construida por los datos de 10 máquinas de soldadura, cada máquina es ajustada por el personal calificado y los parámetros son de acuerdo con el procedimiento de soldadura.

Uno de los puntos importantes a relevar es el ajuste de stick-out, que como fue explicado en el Capítulo 2 Sección 2.5.4 el stick-out o longitud de electrodo libre

afecta a la penetración de soldadura por la resistividad del material. Este ajuste puede no ser el mismo para las 10 máquinas de soldadura, lo que genera variación en la base de datos y, por ende, menor correlación en los modelos de regresión.

Por ello, se decidió utilizar únicamente todas las instancias de la máquina de soldadura número 1, de la línea de ensamble número 1. Con esto se asegura que el ajuste de longitud libre de electrodo será constante y tendrá menor variación los datos.

4.5.1 Preprocesamiento de base de datos optimizada

Al igual que en la base de datos global, se realizó el preprocesamiento con la base de datos optimizada utilizando Python y la librería Pandas. En la Figura 27 se puede observar el resumen estadístico de la base de datos, algunos atributos contienen 82 instancias y otros 80, esto quiere decir que hay valores no numéricos en la base de datos.

	WFS	Frecuencia	Ibase	...	G	FD	D
count	82.000000	81.000000	81.000000	...	80.000000	80.000000	80.000000
mean	13.178902	254.54321	97.160494	...	6.129710	6.123800	0.500168
std	0.374766	28.24449	4.804833	...	0.422953	0.424252	0.063399
min	12.050000	205.00000	90.000000	...	5.206000	5.206000	0.371931
25%	13.000000	240.00000	95.000000	...	5.809725	5.809725	0.462361
50%	13.100000	263.00000	95.000000	...	6.185550	6.169550	0.498502
75%	13.200000	270.00000	100.000000	...	6.427350	6.427350	0.532527
max	13.900000	295.00000	110.000000	...	7.098000	7.098000	0.654458

Figura 27. Resumen estadístico de base de datos optimizada.

En la Figura 28 se puede visualizar el gráfico de barras con los valores NaN de la base de datos; este gráfico fue realizado con la librería MSNO de Python.




Figura 28. Visualización de los valores NaN antes del filtrado de la base optimizada.

4.5.2 Limpieza y filtrado de datos de base optimizada

Al igual que en la base de datos global, para remover los valores NaN de la base de datos se utilizó la librería Pandas de Python para remplazar los valores cero por valores NaN y posteriormente se utilizó el comando dropNaN de Pandas para eliminar los valores de nuestra base de datos.

En la Figura 29 se puede observar la gráfica de barras de la base de datos posterior al filtrado.




Figura 29. Visualización de los valores NaN posterior al filtrado de la base optimizada.

Antes de aplicar los algoritmos de regresión, se aplicó un filtro de atributo no supervisado con WEKA llamado NumericCleaner. Este filtro se utiliza para

determinar los límites mínimos y máximos en la base de datos y eliminar los valores que estén fuera de dichos límites.

Los límites definidos para la aplicación del filtro específico fue conforme el procedimiento calificado de soldadura WPS (Welding Procedure Specification).

En la Tabla 9 se muestran cada uno de los atributos de entrada y salida de la base de datos (17 en total), el número de instancias (80 en total), los valores máximos y mínimos, así como datos estadísticos de cada atributo; este concentrado es realizado de manera posterior al filtrado de la información.

Tabla 10 Resumen estadístico de base de datos optimizada.

Ítem	Nombre de atributo	Tipo	Número de instancias	Valor Mínimo	Valor Máximo	Media	Desviación estándar
1	Wire Feed Speed	Entrada	80	12.05	13.9	13.17	0.371
2	Frecuencia	Entrada	80	205	295	254.1	28.138
3	Corriente Base	Entrada	80	90	110	97.188	4.829
4	Tiempo de impulso	Entrada	80	1.9	2.1	2.073	0.043
5	Tensión de impulso	Entrada	80	31.5	36	33.843	0.941
6	Tensión de salida	Entrada	80	22.5	28.7	26.935	1.016
7	Corriente de salida	Entrada	80	265	338	298.487	16.336
9	Velocidad	Entrada	80	78.294	89.808	83.922	3.01
10	Calor de entrada	Entrada	80	462.905	679.245	575.64	44.909
11	Pdx	Salida	80	1.247	3.52	2.139	0.532
12	Pdy	Salida	80	4.99	7.12	6.603	0.329
13	Pa	Salida	80	1.21	2.539	1.737	0.302
14	Fa	Salida	80	6.01	8.112	7.302	0.444
15	G	Salida	80	5.206	7.098	6.13	0.423
16	FD	Salida	80	5.206	7.098	6.13	0.423
17	Dilución	Salida	80	0.372	0.654	0.5	0.063

Fuente: Elaboración propia.

4.5.3 Generación de modelos de regresión a la base de datos optimizada

Se realizó la aplicación de los algoritmos a la base de datos optimizada conforme fue explicado en la Sección 4.4.3. Para cada atributo de entrada fueron aplicados 11 algoritmos que fueron los que tuvieron un mayor coeficiente de correlación. Estos algoritmos se evaluaron utilizando dos técnicas de división de datos para las etapas entrenamiento y validación. En la primera se utilizó validación cruzada con 11 pliegues y en la segunda se dividió la base de datos en 66% para datos de entrenamiento y 34% para datos validación.

5. RESULTADOS

En este capítulo se explican los resultados de la generación de modelos de regresión aplicando los 11 algoritmos con las dos técnicas de validación, empleando tres métricas de evaluación: coeficiente de correlación, raíz cuadrada del error medio y error medio absoluto.

5.1 RESULTADO DE BASE DE DATOS GLOBAL

Los algoritmos fueron abreviados en las gráficas para tener un formato más legible. En la Tabla 10 se muestra el algoritmo con su abreviatura correspondiente.

Tabla 11 Abreviatura de los algoritmos.

ALGORITMO	ABREVIATURA
Bagging -C	B-C
Decision table -C	DT-C
Gaussian processes -C	GP-C
Linear Regression -C	LR-C
LWL -C	LWL-C
M5 Rules – C	M5-C
Multilayer Perceptron -C	MP-C
Random Forest –C	RF-C
Random Subspace -C	RS-C
REP Tree -C	RT-C
SMOreg –C	SM-C
Bagging –P	B-P
Decision table -P	DT-P
Gaussian processes –P	GP-P
Linear Regression -P	LR-P
LWL –P	LWL-P
M5 Rules –P	M5-P
Multilayer Perceptron -P	MP-P
Random Forest –P	RF-P
Random Subspace –P	RS-P
REP Tree –P	RT-P
SMOreg –P	SM-P

Fuente: Elaboración propia.

En la Tabla 11 se observan los hiperparámetros utilizados para cada uno de los algoritmos, en la mayoría se utilizaron los predeterminados por el software WEKA en las dos técnicas de evaluación (Validación cruzada y división de base de datos).

Tabla 12 Hiperparámetros utilizados en los algoritmos.

ALGORITMO	HIPERPARÁMETROS	ALGORITMO	HIPERPARÁMETROS
Bagging	BagSizePercent = 100 Classifier REPTree (numFolds = 2, seed =1) BatchSize=100	Multilayer Perceptron	GUI=False hiddenLayers=a LearningRate=0.3 momentum=0.2 normalizeNumericClass=True numDecimalPlaces=2 Seed=0
Decision table	Batchsize= 100 numdecimal = 2 CrossVal = 1 Medida Evaluación RMSE Search = BestFirs	Random Forest	maxDepth = 0 numDecimal Places= 2 num ExecutionSlots=1 numIterations=100 OutputOutBagComplexityStadistics =True printClassifiers = True seed=1
Gaussian processes	FilterType = Normalize training data Kernel= PolyKernel noise = 1.0 numDecimalPLace=2 Seed=1	Random Subspace	Batchsize= 100 numdecimal = 2 seed=1 subSpaceSize=0.5 numIterations=10 Classifier=REPTree
Linear Regression	EliminateColinearAttributes = True AttributeSelectionMethod = M5 method numDecimalPlaces = 4 OutputAdditionalStats=True Ridge = 1.0E-8	REP Tree	InitialCOunt=0 maxdepth=-1 minNum=2.0 minVarianceProp = 0.001 noPruning = False =numDecimalPlaces =2 numFolds =11 seed=1
LWL	KNN = -1 classifier = DecisionStump nearestNeighboutSearchAlgorithm = Linear NNSearch weightingKernel =0 numDecimalPlaces = 2	SMOreg	c =1.0 filterType = none Kernel = Polykernel (CatchSize=25007, exponent = 1.0) numDecimalPlaces=2 regOptimizer = RegSMOimproved(epsilo=1.0E-12, epsiloParameter=0.001, seed = 1, tolerance= 0.001)
M5 Rules	buildRegressionTree = True minNumInstances = 4.0 unpruned = False		

Fuente: Elaboración propia.

En la Figura 30 se puede observar la gráfica de líneas del coeficiente de correlación de las tres características de penetración de soldadura. En el caso de la dilución

de soldadura y penetración de disco en el eje X, los algoritmos de Random Subspace y Bagging fueron los que obtuvieron los coeficientes de correlación más alto. En el caso de la penetración en aro, el algoritmo M5 Rules obtuvo un coeficiente de correlación de 0.35. Asimismo, se percibe que los algoritmos no lograron un valor mayor a 0.60 en el coeficiente de correlación.




Figura 30. Coeficiente de correlación en la base de datos global.

Se puede apreciar que los datos utilizados de la base de datos global no obtuvieron un coeficiente de correlación alto con ningún algoritmo.

En la Figura 31 se muestra el error medio absoluto de los 11 algoritmos de la base de datos global con las dos técnicas de validación, el algoritmo Multilayer Perceptron fue el que obtuvo el error más alto, mientras que los algoritmos Bagging y Random Subspace fueron los que obtuvieron los valores más bajos.




Figura 31. Gráfica de error medio absoluto en base de datos global.

Finalmente, en la Figura 32 se puede observar la gráfica de la raíz cuadrada del error medio de la base de datos global, donde se observa condiciones similares a la Figura 31, donde Random Forest -P es el que obtuvo el mayor error.

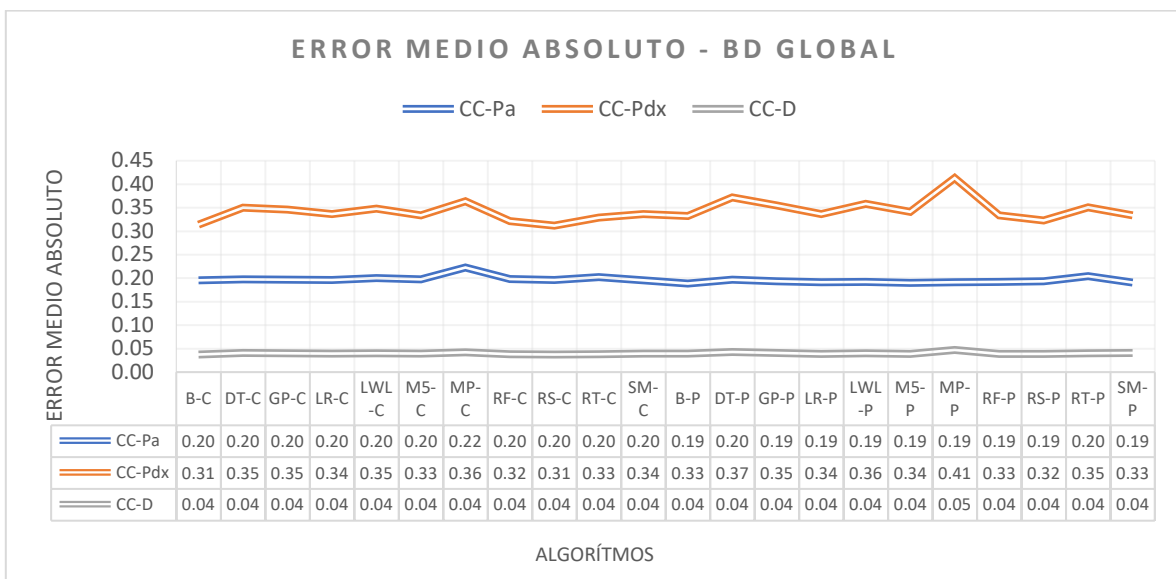


Figura 32. Gráfica de raíz cuadrada del error medio de la base de datos global.

5.2 RESULTADOS DE BASE DE DATOS OPTIMIZADA

La Figura 33 se muestra la gráfica de correlación de los 11 algoritmos en las dos condiciones de evaluación. Como se observa, el algoritmo SMOreg con validación cruzada fue el que obtuvo el mayor coeficiente de correlación con un 0.86 para la dilución de soldadura, 0.81 para la penetración de disco en el eje X y 0.78 en penetración en aro.

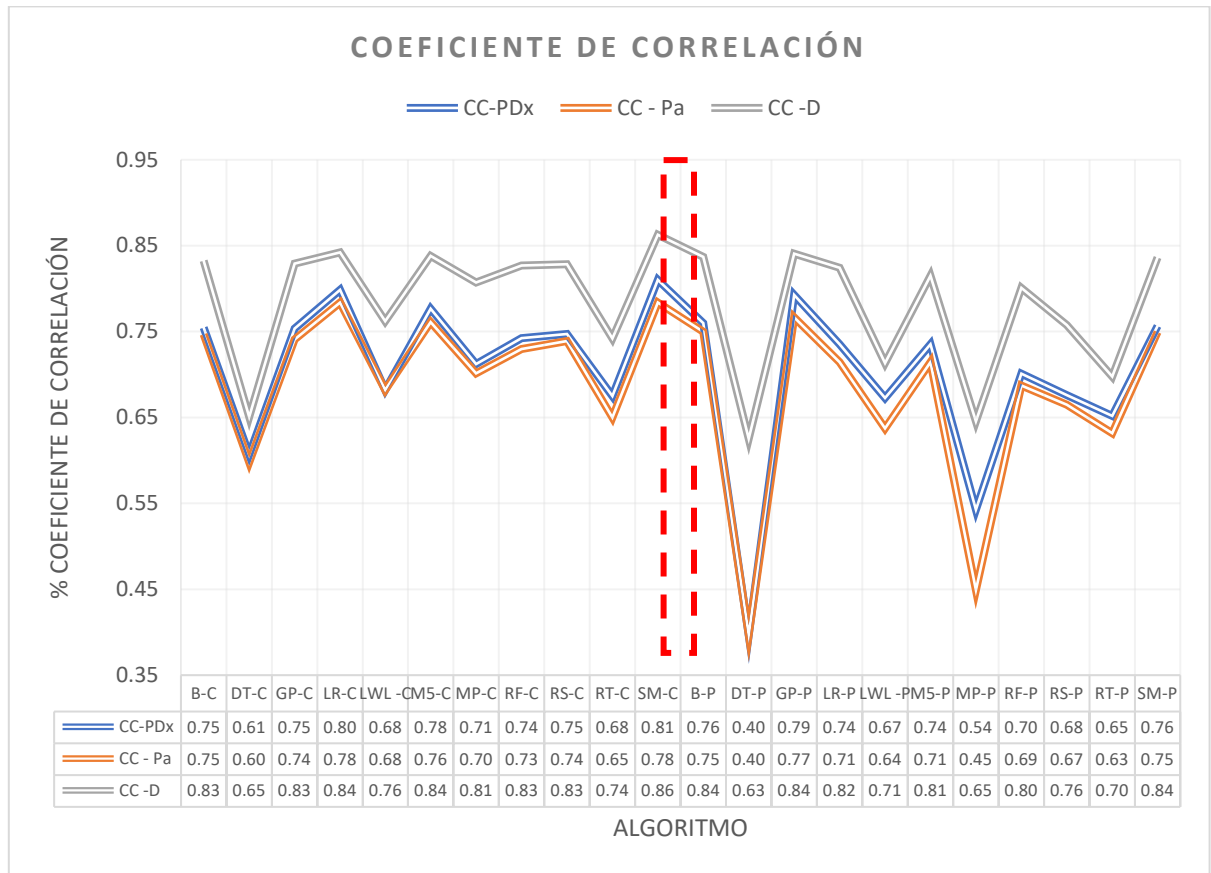


Figura 33. Coeficiente de correlación de base de datos optimizada.

Se puede observar que, al optimizar la base de datos, el coeficiente de correlación se incrementa de 0.56 a 0.86.

5.2.1 Modelo de dilución de soldadura

En la Ecuación (5.1) se observa el modelo de regresión de dilución de soldadura obtenido con el algoritmo SMOreg y en la Tabla 12 se presentan los nombres de las variables utilizadas en la ecuación con sus respectivas abreviaturas.

$$Dilución = 0.0171WFS + 0.0006F + 0.0035Ib - 0.1223tp + 0.0124Tp + 0.167Ts + 0.0167 Is - 0.0523v - 0.0074Hi - 1.1805 \quad (5.1)$$

Tabla 13 Abreviatura de variables de los modelos de soldadura obtenidos con su respectivo nombre.

ABREVIATURA	NOMBRE
WFS	Wire Feed Speed (Velocidad de alimentación de alambre)
F	Frecuencia
Ib	Corriente Base
tp	Tiempo de impulso
Tp	Tensión de impulso
Ts	Tensión de salida
Is	Corriente de salida
v	Velocidad de avance de soldadura
Hi	Calor de entrada

Fuente: Elaboración propia

En el modelo de la Ecuación (5.1) se aprecia que las variables que tienen mayor influencia en la característica de dilución de soldadura son: velocidad de alimentación de alambre, tensión de salida y corriente de salida. La velocidad de

alimentación de alambre está directamente relacionada con la cantidad de corriente eléctrica; al incrementar la corriente de salida y el voltaje de salida, el calor de entrada incrementa y por ende la penetración de soldadura. Conforme la Sección 4.2, la velocidad afecta significativamente al aporte calórico de soldadura y penetración. Al incrementar la velocidad, disminuye significativamente la dilución de soldadura.

El algoritmo SMOreg está soportado por máquinas de soporte vectorial. Este algoritmo fue desarrollado inicialmente para problemas de clasificación binaria, pero se realizó una extensión adaptando la regresión (Witten & Frank, 2005). El SMOreg trabaja en encontrar la línea que mejor se ajusta minimizando el error en la función (Witten & Frank, 2005).

Comúnmente, se normaliza o estandariza la información antes de aplicar el algoritmo. En este proyecto no fue utilizada ninguna de estas dos operaciones, ya que, al normalizar los datos, el coeficiente de correlación disminuía afectando considerablemente el resultado del algoritmo. En la Figura 34 se puede observar el gráfico de dispersión de los valores reales contra los valores predichos para la dilución de soldadura.




Figura 34. Gráfico de dispersión de los valores reales vs valores predichos de dilución de soldadura.

En la configuración del algoritmo se aplicó un parámetro de complejidad (Complexity parameter) de 0.1, donde el software configura que tan flexible es el proceso. El tipo de kernel aplicado es Poly kernel con los parámetros establecidos por default. Se utilizó un exponente de 1 que significa que está utilizando un kernel lineal que separa la información a través de una función de línea recta.

Para la configuración del optimizador se selecciono el parámetro RegSMOimproved donde se configuro un epsilon de 0.001, seed = 1 y una tolerancia en el optimizador de 0.001.

En la Figura 35 se puede observar la gráfica de barras de los valores predichos por el modelo generado con el algoritmo SMOreg para la variable predicción de soldadura en el eje X versus los valores reales. Se puede apreciar en la figura que para la dilución de soldadura los valores son muy próximos.



Figura 35. Gráfico de barras de los valores reales vs los valores predicho del modelo SMOreg para dilución de soldadura

5.2.2 Modelo de penetración en disco en eje X

El modelo de regresión obtenido por el algoritmo SMOreg para la penetración en disco en el eje X se puede observar en la Ecuación (5.2). En la Tabla 5.1 se pueden consultar las abreviaturas de las variables utilizadas.

$$Pdx = 0.0299WFS + 0.0084F + 0.0353Ib - 0.1326tp + 0.1284Tp + 0.354Ts + 0.0508Is - 0.1434v - 0.0174Hi - 10.573 \quad (5.2)$$

Las variables que tienen mayor influencia en la característica de penetración en disco en el eje X del modelo de la Ecuación (5.2) son: tensión de salida, corriente de salida, tiempo de impulso y tensión de impulso. La variable que tiene mayor influencia negativa es la velocidad de soldadura. Como se observa en el modelo, las características tensión de salida, corriente de salida y velocidad de soldadura coinciden con la fórmula de calor de entrada. Además, se observa que al incrementar la tensión de pulsado, se logra un incremento en la penetración en disco en eje X.

En la Figura 36 se muestra un gráfico de barras de los valores predichos vs reales. En la Figura 37 se observa el gráfico de dispersión entre los valores reales de penetración en disco en el eje x y los valores predichos por el modelo.




Figura 36. Gráfico de barras de los valores reales vs los valores predicho del modelo SMOreg de penetración en disco en eje x.

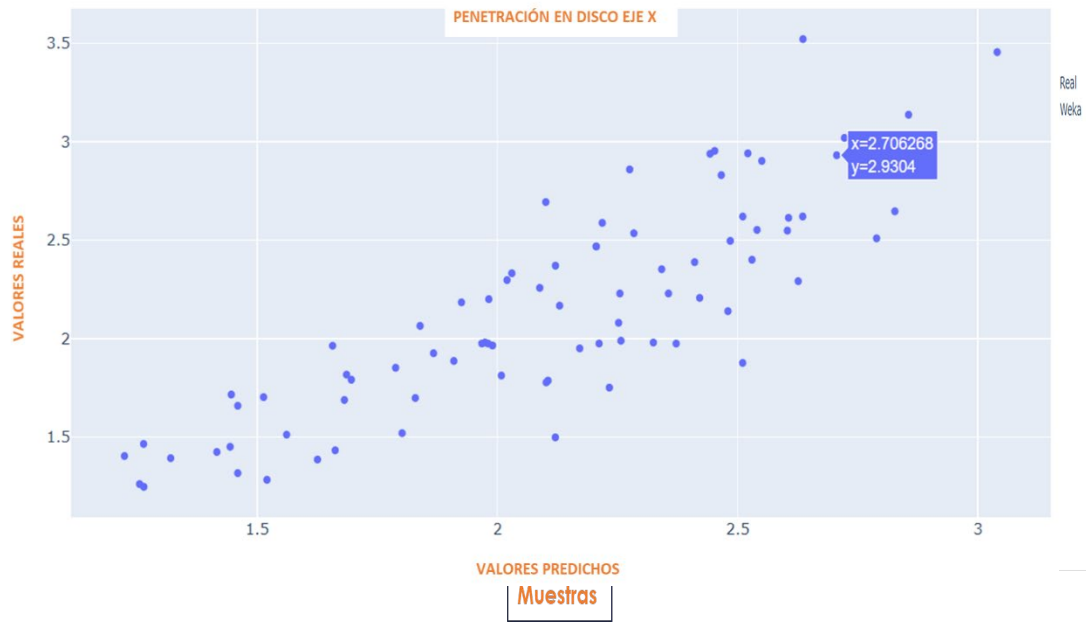


Figura 37. Gráfico de dispersión de los valores reales vs los valores predicho de Pdx.

5.2.3 Modelo en penetración en aro

En la Ecuación (5.3) se puede observar el modelo de regresión generado por el algoritmo SMOreg para la penetración en aro. Este modelo a diferencia de los otros modelos utiliza únicamente dos valores principales que es la tensión de salida (T_s) y la corriente de salida (I_s) y es inversamente a la velocidad (v). Conforme fue explicado en el capítulo 4.2 Cálculo de calor de entrada, las variables principales que actúan en la generación de calor es la tensión o voltaje, la corriente y esta inversamente relacionado a la velocidad, corroborando las variables desarrolladas en el modelo de penetración en aro.

$$Pa = 0.1354Ts + 0.0087Is - 0.0377v - 1.3583 \quad (5.3)$$

En la Figura 38 se muestra un gráfico de dispersión entre los valores reales de penetración en disco en el eje x y los valores predichos por el modelo. En la Figura 39 se observa el gráfico de barras de los valores predichos vs reales.




Figura 38. Gráfico de dispersión de los valores reales vs los valores predicho de penetración en aro.




Figura 39. Gráfico de barras de los valores reales vs los valores predicho del modelo SMOReg de penetración en aro.

5.2.4 Análisis de las variables de soldadura de los modelos propuestos

Como se pudo observar en los modelos desarrollados para la penetración en aro, penetración en disco en el eje X y dilución de soldadura, las variables principales que tienen mayor afectación son la tensión y corriente de salida. La corriente de salida tiene un importante rol en la cantidad de energía del arco eléctrico; incrementar la corriente eléctrica influye directamente en la cantidad de calor que se transfiere a la pieza. La tensión de salida está directamente relacionada con la longitud del arco eléctrico y tiene relación directa con la cantidad de calor que ingresa en el proceso de soldadura. Esto tiene una relación significativa con la ecuación de calor de entrada descrita en el Capítulo 2 Sección 2.5.5. En los tres modelos la velocidad juega un papel inversamente proporcional a las penetraciones y dilución.

Para la aplicación práctica, en el caso de la empresa [REDACTED], el preparador de soldadura tiene la capacidad de ajustar tanto la corriente eléctrica como la tensión del arco, estos ajustes normalmente no son realizados ya que no hay un conocimiento definido de su interacción con el proceso de soldadura, por ello la importancia de la definición de los modelos y de la determinación de los pesos de cada una de las variables de soldadura. Una vez que sean definidos los rangos de ajuste de las variables de soldadura, serán plasmados en el WPS y capacitados a los preparadores para tener mayor habilidad de ajuste del proceso de soldadura en la producción.

5.2.5 Evaluación de algoritmos

Además de obtener los modelos de regresión, se obtuvieron las métricas de evaluación de error medio absoluto como se puede ver en la Figura 40 y la gráfica de la raíz cuadrada del error medio cuadrático para las tres características conforme la Figura 41.




Figura 40. Gráfica del Error Medio absoluto de la base optimizada.

Como se puede observar en la Figura 40, a pesar de que la mayoría de los algoritmos tienen un error relativamente pequeño, el SMOreg fue uno de los algoritmos con error más bajo.




Figura 41. Gráfico de la Raíz Cuadrada del Error Medio de la base optimizada.

Además de los algoritmos de Regresión Lineal y SMOreg, en la Figura 33 se pueden observar que hay otros algoritmos con coeficientes de correlación cercanos a 0.80 como són: M5 Rules, Random Forest y Bagging.

En la Tabla 13 se puede observar una muestra aleatoria de 30 datos donde se realiza el cálculo del error porcentual entre los valores estimados y los valores reales de las tres características.

Tabla 14 Error porcentual entre valor estimado y valor real.

Item	VARIABLES DE ENTRADA									VALORES REALES			VALORES PREDICHOS			ERROR				
	WFS	F	lb	ts	Tp	Ts	Cs	v	Hi	Pdx	D	Pa	Pdx	D	Pa	Pdx	D	Pa		
1	13.05	205	90	1.9	34	22.6	283	82.90	462.90	1.25	0.39	1.21	1.26	0.38	1.04	1.35%	2%	14%		
2	13.05	220	90	2.07	34	24.5	283	80.60	516.16	1.45	0.40	1.29	1.44	0.42	1.38	0%	4%	7%		
3	13	205	95	2.1	35	25.6	279	82.90	516.94	1.66	0.41	1.26	1.46	0.42	1.41	12%	3%	12%		
4	13	205	95	2.1	35	25.6	279	82.90	516.94	1.32	0.38	1.25	1.46	0.42	1.41	11%	12%	12%		
5	12.5	260	95	2.1	31.5	26	298	89.81	517.64	1.51	0.41	1.23	1.56	0.42	1.37	3%	3%	11%		
6	13.1	267	95	2.1	34	27.1	265	82.90	519.77	1.39	0.46	1.62	1.63	0.45	1.49	17%	3%	8%		
7	13	240	110	2.05	34	26.6	270	82.90	519.81	1.81	0.47	1.69	2.01	0.49	1.47	11%	2%	13%		
8	12.7	240	100	2.6	33.5	26.9	270	82.90	525.67	1.70	0.44	1.39	1.51	0.38	1.51	11%	15%	9%		
9	13	205	95	2.1	35	25.3	291	82.90	532.86	1.82	0.44	1.34	1.69	0.46	1.47	7%	3%	10%		
10	12.7	240	100	2	33.9	27	273	82.90	533.49	1.79	0.47	1.79	1.70	0.47	1.55	5%	1%	14%		
11	13.2	270	100	2.1	33	27.2	294	89.81	534.26	1.98	0.45	1.38	1.97	0.48	1.50	0%	7%	8%		
12	13.2	270	100	2.1	33	27.1	302	89.81	546.78	2.37	0.51	1.50	2.12	0.51	1.55	11%	0%	3%		
13	12.7	240	100	2	33	27.1	279	82.90	547.23	1.69	0.46	1.69	1.68	0.47	1.61	0%	2%	4%		
14	13	240	95	2.1	35	26.9	288	82.90	560.71	1.89	0.47	1.81	1.91	0.49	1.66	1%	3%	8%		
15	13	240	90	2	35	26.4	304	85.20	565.16	1.98	0.50	1.86	1.97	0.51	1.65	0%	3%	11%		
16	13	240	90	2	35	26.2	290	79.45	573.82	1.93	0.47	1.65	1.87	0.48	1.72	3%	3%	4%		
17	13.5	240	110	2.05	34.4	27.5	290	82.90	577.20	2.39	0.53	1.83	2.41	0.56	1.76	1%	5%	4%		
18	13.1	263	95	2.05	33.9	27.4	298	82.90	590.97	2.17	0.51	1.93	2.13	0.52	1.82	2%	3%	6%		
19	13	240	110	2.05	34.4	28	292	82.90	591.75	2.21	0.53	2.05	2.42	0.56	1.85	10%	5%	10%		
20	13	240	90	2	35	26.9	296	80.60	592.75	2.18	0.53	1.95	1.93	0.50	1.82	12%	6%	7%		
21	13.2	270	100	2.1	33	26.9	332	89.81	596.66	2.93	0.59	1.74	2.71	0.61	1.79	8%	2%	3%		
22	13.1	275	95	2.05	33.5	26.9	307	82.90	597.71	2.35	0.53	1.61	2.34	0.54	1.83	0%	3%	14%		
23	13.9	295	100	2.15	32	26.9	313	82.90	609.39	2.61	0.54	1.93	2.61	0.57	1.88	0%	4%	2%		
24	13.9	295	100	2.15	33	27.8	303	82.90	609.66	2.55	0.57	2.03	2.54	0.56	1.92	0%	1%	5%		
25	13.9	295	100	2.15	33	27.8	307	82.90	617.70	2.55	0.53	1.80	2.60	0.57	1.95	2%	7%	8%		
26	13.1	263	95	2.05	33.5	26.8	320	82.90	620.70	2.83	0.57	1.93	2.47	0.56	1.93	13%	0%	0%		
27	13.1	263	95	2.1	34	27.6	312	82.90	623.25	2.23	0.50	1.67	2.36	0.55	1.97	6%	9%	18%		
28	13.9	295	100	2.15	33	28.2	320	82.90	653.12	2.51	0.54	2.08	2.79	0.59	2.12	11%	9%	2%		
29	13.9	295	100	2.15	33	28.1	324	82.90	658.94	3.14	0.58	1.80	2.86	0.60	2.14	9%	3%	19%		
30	13	205	95	2.1	35	28.7	327	82.90	679.24	1.95	0.52	2.23	2.17	0.54	2.25	11%	3%	1%		
															PROMEDIO			6%	4%	8%

5.3. DISCUSIÓN DE RESULTADOS

En las ecuaciones (11), (12) y (13) se mostraron los modelos desarrollados para cada una de las características de la medición de penetración de soldadura (Penetración en disco en el eje X, Penetración en Aro y dilución de soldadura). Se pudo observar que en los tres modelos, la corriente de salida, tensión de salida y velocidad de avance juegan un papel importante en la penetración de soldadura. Al incrementar la tensión o corriente de salida, la penetración de soldadura se ve incrementada. Sin embargo, al mantener constante dichas características y únicamente incrementar la velocidad de avance, la penetración de soldadura decrece. Este comportamiento, corresponde con la Ecuación (6) de calor de entrada, donde de forma analítica se explica el comportamiento de la cantidad de energía que ingresa al proceso de soldadura a través de las variables eléctricas (American Welding Society, 2014). El calor de entrada juega un papel fundamental en la estabilidad del arco eléctrico, la calidad del cordón de soldadura y las transformaciones metalúrgicas de fase del material base, así como del material de aporte, como lo menciona Phillips (2016). Además, en esta investigación se corrobora el importante papel que tiene el calor de entrada en la penetración del proceso de soldadura (Phillips, 2016).

En los tres modelos se pudo observar que la tensión de salida es la variable que tiene mayor interacción e influencia con la penetración de soldadura. Este trabajo coincide con investigaciones como (Alam & Khan, 2011), al determinar que al incrementar el voltaje, la penetración de soldadura se ve afectada, incrementando sustancialmente (American Welding Society, 2014). Razak (2017) demuestra en los resultados de su investigación como al incrementar la tensión, la penetración de soldadura se incrementa (Abdul Razak, Ghalib, & Hakim Ramli, 2017). En el caso de la empresa ██████████, la tensión de salida, a pesar de jugar un rol importante en el proceso, es una variable que durante el desarrollo del producto se determina y a lo largo de la vida del producto se mantiene constante, como se presentó en la Sección 3.5.

La corriente de salida es la segunda variable que tiene mayor influencia conforme a los resultados de los algoritmos en los tres modelos. Esta corriente de salida está directamente relacionada con el calor de entrada y con la penetración de soldadura. Al incrementar la corriente de salida, la penetración del cordón de soldadura se incrementa. Estas observaciones coinciden con la literatura citada en la Sección 2.11 Estado del arte. Por ejemplo, Alam (2011) denota en sus resultados que, al incrementar la corriente de salida, la penetración rápidamente incrementa. Otros autores como Jeffus, L (2012) describen en su libro que la corriente eléctrica afecta significativamente el proceso, ya que, al incrementar la corriente, se incrementa la temperatura y, por lo tanto, se incrementa la penetración (Jeffus, 2012). Razak. (2017) coincide con los resultados obtenidos en este estudio utilizando el proceso de soldadura FCAW, donde demuestra en su experimentación que al incrementar la corriente, se obtiene mayor penetración (Abdul Razak, Ghalib, & Hakim Ramli, 2017).

La velocidad de alimentación de alambre es una variable que afecta positivamente a la penetración de aro y la dilución de soldadura, como se presentó en las Ecuaciones (11) y (12), respectivamente. Esta variable es uno de los parámetros en los que más se realizan ajustes en el proceso diariamente para la empresa [REDACTED]. Los resultados de los modelos obtenidos coinciden con investigaciones relacionadas, como es la de Ramos (2013) donde muestra como al incrementar sustancialmente la velocidad de alimentación de alambre, la penetración de soldadura se incrementa (Ramos-Jaime, López-Juárez, & Pérez, 2013). Una observación muy importante es que en el caso de la penetración en aro denotada en la Ecuación (13), la velocidad de alimentación de alambre no ejerce un papel fundamental como variable crítica, ya que según algunos autores como es Jeffus, L (2012) algunas veces si se incrementa la velocidad de alimentación de alambre sin incrementar la cantidad de energía para fundir dicho material de aporte, la penetración en lugar de incrementar, disminuye (Jeffus, 2012). Otros autores como Alam et al. (2011) corroboran esta teoría al demostrar que, al incrementar la velocidad de alimentación de alambre sin incrementar el voltaje, la penetración disminuye (Alam & Khan, 2011). Por ello, es importante definir estas

conjeturas y plasmarlas en nuestros procedimientos de soldadura calificados, con la finalidad de que cualquier usuario que requiera incrementar la penetración de soldadura tenga en consideración incrementar también el voltaje o tensión de salida.

La velocidad de avance juega un rol inversamente proporcional a la penetración de soldadura, conforme las Ecuaciones (11), (12) y (13). Al incrementar la velocidad de soldadura, la penetración de soldadura disminuye, corroborando la relación de estas variables con la teoría del calor de entrada (Phillips, 2016). Esto, coincide con los resultados de otros autores como es Alam et al. (2011) donde denotan que, al incrementar la velocidad de avance, el calor de entrada por unidad de superficie disminuye y por ende disminuye la penetración de soldadura. Definir la velocidad de avance en la industria automotriz juega un papel muy importante, ya que está directamente relacionada con la productividad del proceso de soldadura. El conocer la interacción y peso que tiene esta variable en la geometría del perfil transversal de la soldadura es de vital importancia para el ingeniero de soldadura, ya que, puede objetivar las condiciones máximas de producción y sus fronteras, sin afectar la calidad del producto.

Como fue mencionado en el Capítulo 3.1, el proceso de soldadura estudiado en esta tesis es un GMAW pulsado. Esto quiere decir que es un proceso de soldadura con arco eléctrico y atmósfera protegida donde se controla el método de transferencia metálica con base en el pulsado (Palani & Murungan, 2006). Este proceso utiliza dos corrientes, una corriente de pulsado y una corriente base, además de poder configurar la frecuencia (también conocida como el periodo de pulsado de inicio hasta el siguiente pulsado) y el tiempo en que se realiza el pulsado (Palani & Murungan, 2006). Estas características actualmente son variables comúnmente utilizadas como constantes, pero de acuerdo con los resultados de nuestros modelos, al incrementar la corriente base y la tensión de impulso, la penetración en disco en el eje X y la dilución de soldadura se ven afectados positivamente. Al igual, al incrementar el tiempo de impulso, esta variable afecta negativamente la penetración de soldadura. Como se presentó en la Tabla 4, la

media de los datos de tiempo de impulso es de 2.07 milisegundos con una desviación estándar de 0.04; dado que no se tiene mucha variabilidad en la base de datos, esto pudo ser un factor importante que contribuyó en la generación de los modelos de regresión.

Respecto a los modelos de regresión obtenidos, se pudo observar en la Figura 35 que el algoritmo SMOreg fue el que obtuvo el mejor resultado en las tres características a predecir con un coeficiente de correlación cercano al 0.86. Esto es algo muy interesante de analizar ya que a pesar de utilizar algoritmos de mayor complejidad como son los perceptrones multicapa y los algoritmos de ensamble, el algoritmo que tuvo la mayor correlación fue la regresión apoyada por máquinas de soporte vectorial. Como se mencionó en el capítulo 4.2.5 Evaluación de algoritmos, hay otros algoritmos con coeficientes de correlación cercanos al 0.80 como fueron: Regresión Lineal, Random Forest, M5 Rules y Bagging. Cada uno de estos algoritmos obtuvo un menor coeficiente de correlación y mayor error que el SMOreg, además, un punto importante a denotar es que la Regresión lineal y el SMOreg son algoritmos que generan un modelo en función de las variables a comparación del M5 Rules o Random Forest que generan árboles de decisiones, esta diferencia es muy importante en la parte práctica, ya que al momento de realizar la capacitación a los preparadores y personal operativo respecto a las variables de mayor interacción en la penetración de soldadura, el tener un valor numérico o peso en cada variable, hace que sea más fácil la explicación y entendible para nuestro personal.

Al analizar la Tabla 7, con los errores porcentuales de los valores estimados y los valores reales, se pudo observar que en ningún ítem el error es mayor al 15%. Esto es algo muy importante de denotar, ya que si el usuario quisiera implementar algoritmos y modelos de regresión para predecir la penetración de soldadura sin necesidad de realizar el corte, el usuario deberá tomar en consideración el error porcentual y la desviación estándar para determinar el especificado de la penetración; así se lograría absorber el error en el especificado. Al calcular el

promedio de los errores de la muestra aleatoria de la Tabla 7 se pudo observar que en las tres características no se tiene un error porcentual promedio mayor al 8%.

CONCLUSIONES

En este trabajo de investigación se estudió el desarrollo de los modelos matemáticos para predecir la penetración de soldadura en un proceso GMAW-P para un rin de acero de la empresa [REDACTED] con algoritmos de inteligencia artificial y aprendizaje automático. El estudio fue realizado con la finalidad de conocer cuáles son las variables que tienen mayor interacción con la penetración de soldadura con el objetivo de reducir el tiempo en el desarrollo del producto, así como también evaluar métodos alternos para evaluar la calidad de soldadura sin necesidad destruir la pieza.

Se construyó una base de datos a partir de los datos de penetración y parámetros de soldadura de un periodo de un año del área de ensamble de Equitron. Se ordenaron, preprocesaron y limpiaron los parametros de entrada: velocidad de alimentación de alambre, frecuencia, corriente base, tiempo de impulso, tensión de impulso, voltaje de salida, corriente de salida, velocidad de soldadura y calor de entrada; así como los parámetros de salida: penetración en disco eje X, penetración en aro y dilución de soldadura.

Una vez obtenida la base de datos se realizó la aplicación de once algoritmos de inteligencia artificial y aprendizaje automatico con la finalidad de obtener los modelos de regresión de la penetración de soldadura. Se utilizaron dos técnicas de validación: división de base de datos y validación cruzada.

Cada algoritmo fue evaluado utilizando tres métricas de evaluación: coeficiente de correlación, error medio absoluto y raíz cuadrada del error medio.

A continuación se presentan observaciones y conclusiones del estudio realizado.

- Se lograron desarrollar los modelos matemáticos con base en las variables eléctricas de soldadura para predecir la penetración en disco en eje X,

penetración en aro y dilución de soldadura, aplicando algoritmos de inteligencia artificial y aprendizaje automático.

- Se evaluaron los modelos de regresión obtenidos de los once algoritmos con las dos técnicas de validación. El algoritmo que obtuvo el coeficiente de correlación más alto, el error medio absoluto más bajo y la raíz cuadrada del error medio más bajo fue el SMOreg con la técnica de validación cruzada. Con este algoritmo se logró obtener un error porcentual promedio menor al 8% entre los valores estimados y los valores reales.
- Además del algoritmo SMOreg, se evaluaron otros algoritmos como Regresión lineal, Random forest, M5 Rules y Bagging donde se obtuvieron los coeficientes de correlación cercanos a 0.80.
- Las variables que tuvieron mayor influencia positiva en las tres características (penetración en disco en eje X, penetración en aro y dilución de soldadura) fueron la tensión de salida y la corriente de salida.
- La variable que tuvo la mayor influencia negativa en las tres características (penetración en disco en eje X, penetración en aro y dilución de soldadura) fue la velocidad de avance.
- La velocidad de alimentación de alambre es una variable importante a considerar para mejorar la penetración de soldadura siempre y cuando se ajuste la cantidad de calor de entrada.
- Se observó que cuando se tiene variación en los datos, la precisión de los modelos de regresión se ve afectada como fue observado y descrito en el Capítulo 3 Sección 3.5 Análisis de la base de datos global.
- La hipótesis *"Un modelo matemático obtenido mediante algoritmos de inteligencia artificial y aprendizaje automático que tiene como variables de entrada la velocidad de alambre, tensión de impulso, corriente base, frecuencia y tiempo de impulso es capaz de predecir las dimensiones de penetración del cordón de soldadura en un proceso GMAW-P con un coeficiente de correlación mayor a 0.80"* se logró comprobar y aceptar con el algoritmo SMOreg explicado en el capítulo 4.2.

TRABAJO FUTURO

A continuación se muestran algunas recomendaciones para mejorar los procesos de soldadura GMAW con aplicaciones de algoritmos de aprendizaje automático e inteligencia artificial.

- Como parte del proceso de automatización de los procesos industriales y la aplicación de sistemas robóticos, uno de los procesos de mayor aplicación en el área de soldadura es el proceso GMAW-Tandem. Este proceso es el de mayor tasa de depósito y por ende de productividad. Por lo que se recomienda realizar los estudios de la interacción de soldadura de los dos alambres de soldadura con respecto a la penetración de soldadura con los algoritmos que se aplican en este trabajo de investigación.
- Algunos procesos en el área de fabricación de rines de acero es el Butt Weld o solda a tope. Este proceso de resistencia es menos utilizado en el área industrial y por ende se tiene menor conocimiento de su comportamiento y ajuste. Además, uno de los principales problemas generados en este proceso es la dificultad en determinar los parámetros óptimos para obtener las propiedades mecánicas adecuadas. Por ello se recomienda comenzar a desarrollar estudios aplicando las herramientas y algoritmos previamente desarrolladas para este tipo de procesos.
- A partir de los resultados mostrados en esta investigación se recomienda comenzar a analizar los requisitos específicos de los clientes con la finalidad de evaluar la factibilidad de aplicar este tipo de pruebas no destructivas para evaluar la calidad de la junta soldada sin necesidad de destruir la pieza. Se recomienda aplicar los modelos generados por el algoritmo SMOreg para las tres características de soldadura: dilución, penetración en aro y penetración en disco en eje X con la finalidad de reducir las pruebas destructivas que beneficiarían a la empresa en la reducción de chatarra diaria por evaluación de soldadura.

APORTACIÓN DE LA TESIS

En este trabajo de investigación se estudió la aplicación de algoritmos de aprendizaje automático e inteligencia artificial para el proceso de soldadura GMAW, logrando las siguientes aportaciones: Se determinó el modelo matemático de dilución de soldadura. Se determinó el modelo matemático para la penetración de soldadura en el eje X. Se determinó el modelo matemático para la penetración en aro. Con cada modelo matemático desarrollado se logró determinar cuáles son las variables que tienen mayor interacción con las características de penetración. Se logró realizar una publicación para la revista Capital Intelectual #18 ISSN: 2007-9893 con el trabajo de investigación "Predicción de penetración en el proceso de soldadura GMAW con algoritmos de aprendizaje automático". La investigación realizada es vanguardista para la Empresa [REDACTED] en el área de soldadura ya que no se tenía desarrollo de aplicaciones de aprendizaje automático e inteligencia artificial para el proceso de soldadura GMAW.

APORTACIÓN SOCIAL DE LA TESIS

La principal aportación social de este trabajo de investigación es la generación del conocimiento para mejorar el proceso de soldadura GMAW. Con la determinación de los modelos matemáticos de cada una de las variables de penetración se puede determinar la interacción de cada una de las variables a la penetración de soldadura. Este conocimiento es muy importante para los preparadores de soldadura y personal operativo, ya que al conocer qué comportamiento tiene cada variable, ellos pueden realizar los ajustes necesarios en el proceso, reduciendo el tiempo de desarrollo de un producto, mejorando la productividad de la línea y reduciendo el tiempo muerto por ajuste.

REFERENCIAS

- Abdul Razak, M. F., Ghalib, A., & Hakim Ramli, M. A. (2017). Prediction of flux core arc welding (FCW) bead geometry and welding parameters for 1G position. *International Journal of Materials, Mechanics and Manufacturing*, 1-12.
- Abhulimen, I. U., & Achebo, J. I. (2014). Application Of Artificial Neural Network In Predicting The Weld Quality Of A Tungsten Inert Gas Welded Mild Steel Pipe Joint. *International Journal of Scientific & Technology Research*, 1-12.
- Alam, S., & Khan, M. I. (2011). Prediction of weld bead penetration for steel using submerged arc welding process parameters. *International Journal of Engineering Science and Technology (IJEST)*, 1-9.
- Al-Faruk, A., Hasib, A., Ahmed, N., & Das, U. (2010). Prediction of weld bead geometry and penetration in electric arc welding using artificial neural networks. *International Journal of Mechanical & Mechatronics Engineering*, 10(4), 19-24. Retrieved from <https://ijens.org/105004-3232%20IJMME-IJENS.pdf>
- American Welding Society. (2010). *3.0 Terms and Definitions*. US : AWS.
- American Welding Society;. (2014). *Specification for welding procedure and performance qualification AWS B2.1/B2.1M*. US: AWS.
- AWS D11 Committee on Welding Iron Casting. (1989). *Guide for Welding Iron Castings: (ANSI/AWS D11.2-89 (R2006)) - 5.3.1 Definition and General Description*. Retrieved from Knovel.com: <https://app.knovel.com/hotlink/pdf/id:kt0095W201/guide-welding-iron-castings/definition-general-description>
- Aza, G. (2000). Clasificación de aceros. In G. Aza, *Compendio de norma para producto de aceros* (pp. 8-14). Chile: Palabras de acero.
- Azom, F. (2012). *AISI 1010 Carbon Steels*. Retrieved from Azom: <https://www.azom.com/article.aspx?ArticleID=6539>
- Balamurugan, K., Abhilash, A. P., Sathiya, P., & Naveen Sait, A. (2014). Artificial neural network simulation and particle swarm optimisation of friction welding parameters of 904L superaustenitic stainless steel. *Multidiscipline Modeling in Materials and Structures*, 250-264.
- Benyounis, K. Y., & Olabi, A. G. (2008). Optimization of different welding processes using statistical and numerical approaches – A reference guide. *Advances in Engineering Software*, 483-496.
- Berk, R. A. (2016). Random forest. In R. A. Berk, *Statistical learning from a regression perspective* (pp. 205-258). Springer.
- Bhagwan, F., Awale, A. S., Bhusare, H. S., & Nirantar, S. R. (2018). Metal Inert Gas (MIG) Welding Process Optimization using Teaching-Learning Based Optimization (TLBO) Algorithm. *Materials Today: Proceedings*, 7086-7095.
- Blogur, A. (2018). Missingno: a missing data visualization suite. *Journal of Open Source Software*, 547.

- Breiman, L. (2001). *Random Forest. Machine Learning*. Berkely CA: University of California.
- Chattopadhyay, R. (2014). Green Tribology, Green Surface Engineering, and Global Warming. In R. Chattopadhyay, *3.9.11.3 Gas Metal Arc Welding (GMAW)* (pp. 166-167). ASM Internationa.
- Contreras, C., & Meneses, J. (2015). Calibración y automatización de un proyector de perfiles usado para el control de calidad en la fabricación de perfiles plásticos extruidos. *Revista Investigaciones Aplicadas*, 9(1), 7-11. doi:<http://dx.doi.org/10.18566/ria.v09n01.a02>
- del Val Román, J. L. (2016). Industria 4.0: la transformación digital de la industria. In *Proceedings of the Conferencia de Directores y Decanos de Ingeniería Informática*, (p. 10). Valencia, Spain: Informes CODDII.
- Dey, V., Pratihari, D., Datta, G., Jha, M., Saha, T., & Bapat, A. (2009). Optimization of bead geometry in electron beam welding using a genetic algorithm. *Journal of Materials Processing Technology*, 209(3), 1151-1157. Retrieved from <https://doi.org/10.1016/j.jmatprotec.2008.03.019>
- Flores de la Torre, R. I. (2014). *Análisis comparativo de árboles de decisión y máquina de vectores soporte para conjuntos de datos de diabetes y hepatitis*. Universidad Autónoma del Estado de México. Retrieved from Universidad Autonoma del Estado de México: <http://ri.uaemex.mx/handle/20.500.11799/40493>
- Galvery, W., & Marlow, F. (2006). Wire feed welding processes: gas metal & flux cored arc welding. In W. Galvery, & F. Marlow, *Welding essentials: questions and answers* (2 ed., pp. 152-154). Industrial Press. Retrieved from <https://app.knovel.com/hotlink/toc/id:kpWEQAE002/welding-essentials-questions/welding-essentials-questions>
- Ganjigatti, J. P., Dilip, K. P., & Choudhury, A. (2007). Global versus cluster-wise regression analyses for prediction of bead geometry in MIG welding process. *Journal of Materials Processing Technology*, 352-366.
- García Sánchez, A. (2009). *Optimización de los parámetros de soldadura en el proceso de arco eléctrico con gas de protección (GMAW) para soldar un acero A-27.20*. Corporación Mexicana de Investigación de materiales. Retrieved from <https://comimsa.repositorioinstitucional.mx/jspui/bitstream/1022/63/1/TESIS%20Armando%20G%20abr%2009.pdf>
- Goyal, M. (2014). Modeling of sediment yield prediction using m5 model tree algorithm and wavelet regression. *Water Resources Management*, 28(7), 1991-2003. doi:<https://doi.org/10.1007/s11269-014-0590-6>
- Hakan, A. (2007). Prediction of gas metal arc welding parameters based on artificial neural networks. *Materials & Design*, 2015-2023.
- Hao, X., Dong, H., Li, S., & Li, P. (2018). Lap joining of TC4 titanium alloy to 304 stainless steel with fillet weld by GTAW using copper-based filler wire. *Journal of Materials Processing Technology*, 88-100.

- Hernández Luquín, M. F., & Escalante, H. J. (2020). *Aprendizaje profundo localmente ponderado*. Reporte técnico No. CCC-20-002, INAOE, Ciencias Computacionales, Puebla. Retrieved from INAOE. Ciencias computacionales: <http://ccc.inaoep.mx/archivos/CCC-20-002.pdf>
- Hoffman, D. (2014). *Welding*. US: Pearson.
- Ibrahim, I., Mohamat, S., Amir, A., & Ghalib, A. (2012). The effect of gas metal arc welding (GMAW) processes on different welding parameters. *Procedia Engineering*, 41, 1502-1506. doi:<https://doi.org/10.1016/j.proeng.2012.07.342>
- Jeffus, L. (2012). *Welding and metal Fabrication*. USA: DELMAR Cengage Learning.
- Jing, X., Zhao, H., Zhang, S., & Ruan, Y. (2019). Research on monitoring method of ethylene oxide process by improving c4. 5 algorithm. In H. Jin, X. Lin, X. Cheng, X. Shi, N. Xiao, & Y. Huang (Ed.), *Big Data 2019. Communications in Computer and Information Science*. 1120, pp. 395-405. Singapore: Springer. doi:https://doi.org/10.1007/978-981-15-1899-7_28
- Katherasan, D. (2012). Modeling and optimization of flux cored arc welding by genetic algorithm and simulated annealing algorithm. *Multidiscipline Modeling in materials and structure*, 307-326.
- Kuehl, R. (2001). Comenzando con diseños totalmente aleatorizados. In R. Kuehl, *Diseño de experimentos: Principios estadísticos de diseño y análisis de investigación* (2 ed., pp. 37-72). Mexico: Thomson Learning.
- Li, C., & Jiang, L. (2006). Using locally weighted learning to improve SMOreg for regression. *Pacific Rim International Conference on Artificial Intelligence* (pp. 375-348). Berlin: Springer.
- Linnert, G. E. (1994). Repelled transfer in GMAW. In G. Linnert, *Welding metallurgy: carbon and alloy steels* (4 ed., Vol. 1. Fundamentals, p. 776). American Welding Society. Retrieved from <https://app.knovel.com/hotlink/pdf/id:kt0095ROTH/welding-metallurgy-carbon/repelled-transfer-in>
- López Takeyas, B. (2015). *Introducción a la inteligencia artificial*. (I. T. Laredo, Ed.) Retrieved from Ing. Bruno López Takeyas: <http://itnuevolaredo.edu.mx/takeyas/Articulos/Inteligencia%20Artificial/ARTICULO%20Introduccion%20a%20la%20Inteligencia%20Artificial.pdf>
- Manikya, K. (2008). Prediction of bead geometry in pulsed GMA welding using back propagation neural network. *Journal of Materials Processing Technology*, 300-305.
- Morate, D. (s.f.). *Manual de WEKA*. (Universidad de Salamanca, Ed.) Doctorado Formación en la Sociedad del Conocimiento. Retrieved from <https://knowledgesociety.usal.es/sites/default/files/MANUAL%20WEKA.pdf>
- Nabendu, G., Pradip, K. P., & Goutam, N. (2016). Parametric optimization of MIG welding on 316L austenitic stainless steel by grey-based Taguchi Method. *Procedia technology*, 25, 1038-1048. doi:<https://doi.org/10.1016/j.protcy.2016.08.204>

- Navas Moreno, F. (2016). *Introducción a la minería de datos con WEKA: aplicación a un problema económico*. Universidad de Jaén. Facultad de Ciencias Sociales y Jurídicas. Retrieved from Universidad de Jaen: <http://tauja.ujaen.es/handle/10953.1/6984>
- Ngo, T.-T., Wang, C.-C., Huang, J. H., & Than, V.-T. (2019). *Estimating heat generation and welding temperature for gas metal arc welding process*. Retrieved from Elsevier: <http://www.sciencedirect.com/science/article/pii/S135943111931350X>
Base de datos.
- Oberg, E., Horton, F., Holbrook, L., & Ryffel, H. H. (2012). Welding controls. In E. J. Oberg, F. D. Horton, L. Holbrook, & H. H. Ryffel, *Machinery's handbook (29th edition) & guide to machinery's handbook (29 ed., p. 1473)*. Industrial Press.
- O'Brien, R. L. (1997). *Jefferson's Welding Encyclopedia (18th Edition) - GAS METAL ARC WELDING (GMAW)*. Retrieved from Knovel: <https://app.knovel.com/hotlink/pdf/id:kt00952I21/jeffersons-welding-encyclopedia/gas-metal-arc-welding>
- Oh , W.-B., Yun , T.-J., Lee, B.-R., Kim, C.-G., Liang, Z.-L., & Kim, I.-S. (2019). A study on intelligent algorithm to control welding parameters for lap-joint. *Procedia Manufacturing*, 30, 48-55. doi:<https://doi.org/10.1016/j.promfg.2019.02.008>
- Olsen, F. O. (2009). Brief history of arc welding. In F. Olsen, *Hybrid laser-arc welding* (pp. 3-6). CRC. Retrieved from <https://app.knovel.com/hotlink/pdf/id:kt008WRPR1/hybrid-laser-arc-welding/brief-history-arc-welding>
- Palani, P. K., & Murungan, N. (2006, february). Selection of parameters of pulsed current gas metal arc welding. *Journal of Materials Processing Technology*, 172(1), 1-10. doi:<https://doi.org/10.1016/j.jmatprotec.2005.07.013>
- Phillips, D. (2016). Welding position. In D. Phillips, *Welding engineering: an Introduction* (pp. 10-12). US: John Wiley & Sons.
- Ramos-Jaime, D., López-Juárez, I., & Pérez, P. (2013). Effect of process parameters on robotic GMAW bead area estimation. *Procedia Technology*, 7, 398-405. doi:<https://doi.org/10.1016/j.protcy.2013.04.050>
- Reina, M. (2003). *Soldadura de los aceros: aplicaciones*. Madrid: Weld-Work.
- Rosano Lara, F. (1996). *Fundamento de redes neuronales artificiales*. (U. A. México, Ed.) Retrieved from *Conceptos y fenómenos fundamentales de nuestro tiempo*: http://conceptos.sociales.unam.mx/conceptos_final/598trabajo.pdf
- Saedi Daryan, A., & Yahyai, M. (2017). Predicting the behavior of welded angle connections in fire using artificial neural network. *Journal of Structural Fire Engineering*, 9(1), 28-52. doi:<https://doi.org/10.1108/JSFE-07-2016-0011>
- Sammut, C., & Webb, G. (2017). Bagging. In C. Sammut, & G. Webb, *Encyclopedia of Machine Learning and Data Mining*. Boston: Springer.

- Sammut, C., & Webb, G. I. (2017). Random subspace method. In C. Sammut, & G. I. Webb, *Encyclopedia of Machine Learning and Data Mining*. Boston: Springer. doi:https://doi.org/10.1007/978-1-4899-7687-1_696
- Schweißtechnik, C. (1994). *Cloos robot manual*. Germany: Haiger. Retrieved from Cloos Robot Manual.
- Sing, R. P., Garg, R. K., & Shukla, D. (2015). Optimization of response parameters for polarity in submerged arc welding. *Multidiscipline Modeling in Materials and Structures*, 11(4), 494-506. doi:<https://doi.org/10.1108/MMMS-04-2015-0024>
- Singh, P. (2019). Random forest. In P. Singh, *Machine learning with PySpark: with natural language processing and recommender systems*. Berkeley, CA: Apress.
- Sukhomay , P., Surjya, K. P., & Arun, K. S. (2008). Artificial neural network modeling of weld joint strength prediction of a pulsed metal inert gas welding process using arc signals. *Journal of Materials Processing Technology*, 464-474.
- Tham, G., Mohamad, N. H., Faruqi, M., & Saedon, J. (2017). Prediction of weld bead geometry for small-wire submerged Arc Welding in 1G position. *Journal of Mechanical Engineering*, 145-156.
- Tussel, F. (2011, octubre). *Análisis de regresión: introducción teórica y práctica basada en R*. (U. d. Vasco, Ed.) Retrieved from Departamento Métodos Cuantitativos:
<http://www.et.bs.ehu.es/~etptupaf/nuevo/ficheros/estad3/nreg1.pdf>
- Valera, J., Miguel, V., Manjabacas, M., Ayllón, J., Martínez, A., Amat, F., & Coello, J. (2017). Experiencia de innovación educativa relativa a los proceso de soldadura en el paradigma industria 4.0. In M. López Solera, C. Pérez de los Reyes, & A. Sanz Redondo (Eds.), *Experiencias de Innovación Docente en Enseñanza Superior de Castilla-La Mancha 2017* (p. 219). Universidad de Castilla-La Mancha. doi:<https://ruidera.uclm.es/xmlui/handle/10578/14556>
- Vallejo, H. (2001, julio). PLC: los controladores lógicos programables. *Saber Electrónica*, 14(166), 3-11. Retrieved from
<https://www.sistemamid.com/panel/uploads/biblioteca/1/349/1259/6572/6620/78618.pdf>
- Vitoriano, B. (2007, julio). *Teoría de la decisión: decisión con incertidumbre, decisión multicriterio y teoría de juegos*. (U. A. Morelos, Ed.) Retrieved from Metabase de Recursos Educativos de la UAEM:
<http://metabase.uaem.mx/xmlui/handle/123456789/1295>
- Witten, I., & Frank, E. (2005). *Data mining: practical machine learning tools and techniques* (2 ed.). Elsevier.