

Diseño de Aceros Avanzados Aplicados en la Industria Automotriz Mediante Técnicas de Optimización Numérica e Inteligencia Artificial

Carlos O. Flor-Sánchez
Depto. Posgrado
Instituto Tecnológico de Saltillo
Saltillo, Coahuila, México
cosvaldoflor@gmail.com

Gerardo Altamirano-Guerrero
Depto. Posgrado
Instituto Tecnológico de Saltillo
Saltillo, Coahuila, México
galtamirano@itsaltillo.edu.mx

Edgar O. Reséndiz-Flores
Depto. Posgrado
Instituto Tecnológico de Saltillo
Saltillo, Coahuila, México
eresendiz@itsaltillo.edu.mx

Resumen —En la presente investigación se llevó a cabo un estudio relacionado con la optimización de los principales parámetros de tratamiento térmico (velocidad de enfriamiento, temperatura y tiempo de mantenimiento) involucrados en el procesamiento de un acero de plasticidad inducida por transformación (TRIP). El objetivo de la optimización es determinar la mejor combinación de propiedades mecánicas (YS, UTS y %EL). Para este propósito se aplicó simulación teórica haciendo uso del programa JmatPro, se calcularon los diagramas correspondientes CCT-TTT, los cuales fueron empleados para seleccionar los rangos de cada variable de procesamiento. Mediante un diseño de experimentos se obtuvo una matriz experimental con 17 tratamientos térmicos. Finalmente, el modelado y la optimización de parámetros de procesamiento térmico fue llevado a cabo mediante la aplicación combinada de redes neuronales y algoritmos genéticos. En general, los resultados mostraron que esta aproximación computacional predice satisfactoriamente las propiedades mecánicas de un acero TRIP.

Palabras clave: AHSS, machine learning, optimización multiobjetivo.

Abstract—In the present investigation, a study related to the optimization of the main heat treatment parameters (cooling rate, temperature and holding time) involved in the processing of a transformation-induced plasticity (TRIP) steel was carried out. The goal of optimization is to determine the best combination of mechanical properties (YS, UTS, and % EL). For this purpose, theoretical simulation was applied using the software JmatPro, the corresponding CCT-TTT diagrams were calculated, which were used to select the ranges of each processing variable. Through a design of experiments, an experimental matrix with 17 heat treatments was obtained. Finally, the modeling and optimization of thermal processing parameters was carried out through the combined application of neural networks and genetic algorithms. In general, the results show that this computational approach satisfactorily predicts the mechanical properties of a TRIP steel.

Keywords: AHSS, machine learning, multi objective optimization.

I. INTRODUCCION

En los últimos años, los fabricantes de automóviles han puesto una mayor atención al momento de seleccionar los materiales de la carrocería, considerando principalmente

eficiencia en el consumo de combustible, facilidad de fabricación, seguridad y durabilidad [1, 2]. En este contexto, los aceros de plasticidad inducida por transformación (TRIP - Transformation Induced Plasticity), pertenecientes a la primera generación de la familia de aceros avanzados de alta resistencia (AHSS- Advanced High-Strength Steels), son muy atractivos para la industria automotriz, ya que permiten la reducción del peso del vehículo para disminuir las emisiones contaminantes al tiempo que mejora la seguridad de los pasajeros [3]. Normalmente, este tipo de aceros posee una resistencia mecánica superior a 800 MPa combinada con una buena elongación total a la fractura (EL) de aproximadamente 30%. Los aceros TRIP suelen ser materiales de baja aleación, de bajo a medio contenido de carbono (0.2 a 0.5%) y 0.2 a 2.5% de manganeso y silicio [4]. La buena capacidad de absorber energía de estos aceros se ha atribuido principalmente a la influencia positiva de la austenita retenida en la microestructura multifásica compleja. La retención de austenita se logra mediante los efectos combinados de los elementos de aleación y del tratamiento térmico aplicado [3].

En general, el tratamiento térmico para la manufactura de un acero TRIP consiste en una combinación de recocido intercrítico (IA - Intercritical Annealing) y transformación bainítica isotérmica (IBT - isothermal bainite transformation).

Dependiendo de los parámetros de procesamiento seleccionados, pueden obtenerse microestructuras finales que consisten en ferrita (F), bainita libre de carburos (B), austenita retenida (AR-entre 5 y 20%) y una pequeña fracción de martensita. Las cantidades relativas de estos microconstituyentes tienen un impacto significativo en las propiedades mecánicas [4, 5]. Por lo tanto, para la optimización de propiedades mecánicas, es muy importante conocer los efectos sobre la microestructura de los ciclos térmicos a los que se someten los aceros TRIP durante su procesamiento.

Para obtener la microestructura y propiedades mecánicas adecuadas, los parámetros, deben elegirse adecuadamente para producir aceros con las combinaciones óptimas de resistencia y ductilidad. En base a esto, debido a su gran potencial, los algoritmos de aprendizaje automático (ML- Machine Learning)

se han sugerido como una metodología innovadora para desarrollar modelos numéricos que evalúen el comportamiento y desempeño de aceros bajo tratamientos térmicos [6]. Una de las razones es que, dado que se ha generado y acumulado una enorme cantidad de información, los investigadores ahora tienen la oportunidad de utilizar estas bases de datos para entrenar diversos algoritmos de ML [7]. Una vez que se es capaz de aproximar el comportamiento mecánico después del ciclo térmico de estos aceros mediante estas técnicas, es posible optimizar el proceso implementando técnicas de optimización multi-objetivo, como son el caso de los algoritmos evolutivos que han demostrado ser especialmente adecuados para esta tarea [8, 9]. Este tipo de aproximaciones computacionales pueden ser útiles para el diseño particular de rutas de procesamiento óptimas para producir diferentes grados de aceros avanzados de calidad galvanizados en líneas de procesamiento continuo.

Por lo tanto, en la presente investigación se llevó a cabo un estudio sobre la optimización de los parámetros de tratamiento térmico (velocidad de enfriamiento después de la austenización intercrítica, tiempo de transformación de bainita-isotérmica y la velocidad de enfriamiento final), para el procesamiento de un acero experimental tipo AHSS-TRIP de bajo contenido de C aleado con Mn y Si laminado en frío.

II. METODOLOGIA

A. Material

Para la realización del presente proyecto de investigación, se utilizó un acero con bajo contenido de carbono y laminado en frío a 3 mm de espesor.

La composición química fue determinada por el método de análisis de espectrometría de emisiones ópticas y la concentración de C y S por la técnica de combustión de LECO y se muestra en la Tabla I. Los resultados muestran que se trata de un acero con bajo contenido de carbono del 0,264%, con el 2,23% y el 1,85% de Si y Mn, respectivamente

B. Simulación en JMatPro

El programa *JMatPro v-9* (Java-based Materials Properties) fue utilizado como herramienta de apoyo para la simulación de los ciclos de tratamientos térmicos diseñados, predicción de la microestructura (% de fases) y propiedades mecánicas resultantes (dureza, resistencia a la cedencia y resistencia a la

tracción). Para el estudio de las transformaciones de fase *JMatPro* está basado en el modelo de Kirkaldy [10, 11].

El módulo termodinámico calcula las temperaturas críticas, otras temperaturas como la temperatura de transformación de la bainita y martensita son calculadas a partir de fórmulas empíricas. El cálculo del tiempo que tarda una cantidad de transformación a una temperatura deseada está basado en la ecuación de Johnson-Mehl-Avrami.

C. Ciclos térmicos TRIP

A partir de las temperaturas intercríticas y los diagramas de transformación CCT y TTT teóricos, se diseñaron diferentes ciclos térmicos TRIP para determinar el efecto de los parámetros de tratamiento térmico sobre la microestructura y propiedades mecánicas resultantes en los aceros. Las variables de estudio seleccionadas para análisis fueron la velocidad de enfriamiento posterior a la austenización intercrítica (V1), el tiempo de mantenimiento a la temperatura de transformación bainítica IBT (t2), y la velocidad de enfriamiento final (V2). La temperatura y tiempo de austenización intercrítica se mantuvieron constantes a 800 °C y 60 s. Estos ciclos fueron reproducidos teóricamente. Para la configuración de pruebas se utilizó un diseño de experimentos central compuesto con tres puntos centrales.

D. Modelado mediante una red neuronal artificial

Debido a la naturaleza no lineal de la relación entre los parámetros del proceso y las propiedades mecánicas de los aceros, en este trabajo se ha elegido una red neuronal artificial de propagación hacia atrás (BPNN- Back Propagation Neural Network) como herramienta numérica para mapear la compleja relación entre los parámetros de procesamiento y las propiedades mecánicas. Este método es adecuado para modelar sistemas complejos.

La manera más común para seleccionar la arquitectura de una red neuronal, es comenzar con una suposición aproximada basada en la experiencia previa sobre redes utilizadas en problemas similares. En base a esto, se pusieron a prueba diversas configuraciones que fueron desde una hasta tres capas ocultas y, el número de neuronas se incrementó de tres en tres teniendo como límite doce neuronas como máximo en cada capa. La Tabla II muestra un resumen de todas las arquitecturas probadas.

TABLA I. COMPOSICIONES QUÍMICAS (WT %) DE ACERO ESTUDIADO

C	Si	Mn	P	S	Cr	Mo	Ni	Al	Cu	Nb	Ti	Fe
0.264	2.23	1.85	0.0233	0.005	0.215	0.0135	0.063	0.314	0.045	0.0055	0.003	95

TABLA II. RESUMEN DE LAS DISTINTAS ESTRUCTURAS PROBADAS.

3-3-3	3-9-9-3
3-6-3	3-9-12-3
3-9-3	3-9-9-3-3
3-12-3	3-9-9-6-3
3-9-3-3	3-9-9-9-3
3-9-6-3	3-9-9-9-3

Los mejores resultados fueron obtenidos para las arquitecturas con solo dos capas ocultas, la Fig. 1 muestra un ejemplo del comportamiento del MSE para esos casos, el número de neuronas en la primera capa oculta se mantuvo constante en 9. Se puede encontrar que la red con 9 neuronas en la segunda capa oculta produjo el error más pequeño como lo indica la flecha.

Por esta razón, la arquitectura seleccionada para la ANN en este trabajo es de la forma 3-9-9-3 que se muestra en la Fig. 2. Se utilizan 3 entradas en total, que son las variables de tratamiento térmico TRIP (V1, t2 y V2) y se predicen las propiedades mecánicas resultantes (UTS, YS, %EL).

El conjunto de datos de entrenamiento de propiedades mecánicas se muestra en la Tabla III correspondiente a los datos teóricos. La red neuronal fue entrenada usando el algoritmo de Levenberg-Marquardt y se utilizó el error cuadrático medio (MSE) para evaluar el rendimiento de la BPNN.

Se aplicó el método de validación cruzada para mejorar la confiabilidad de los datos. Para este caso el conjunto de datos se dividió aleatoriamente en entrenamiento, validación y prueba en una proporción 8:1:1.

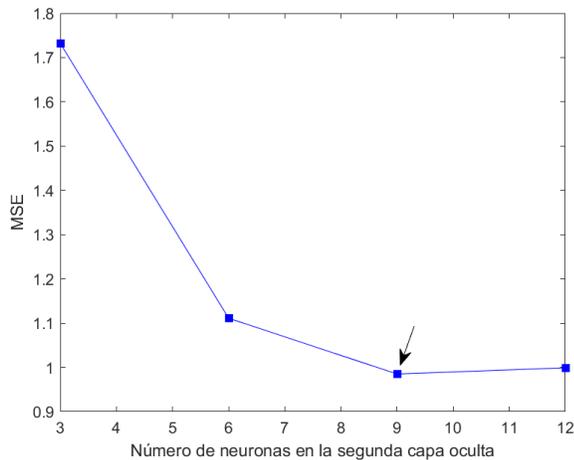


Fig. 1. Rendimiento de la red neuronal variando el número de neuronas en la segunda capa oculta.

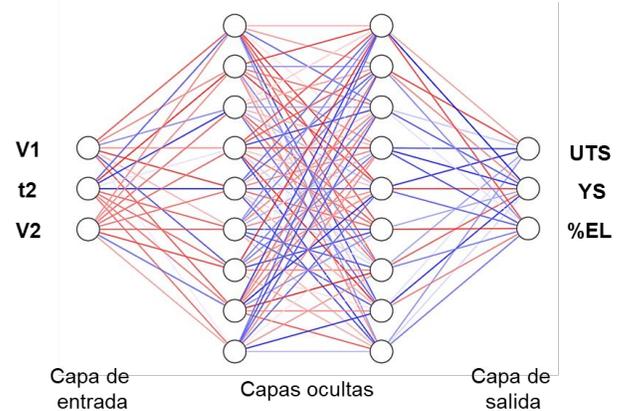


Fig. 2. Arquitectura de la red neuronal utilizada.

E. Optimización Multi-objetivo

Existe un interés industrial por optimizar las propiedades mecánicas, buscando siempre maximizar la última resistencia a la tracción (UTS), minimizar el esfuerzo de cedencia (YS), y maximizar el porcentaje total de elongación (EL). De esta manera surge un problema de optimización multi-objetivo que se resolvió numéricamente a través del algoritmo genético (NSGA-II - Non Dominated Sorting Genetic Algorithm). La red neuronal que se entrenó con los datos de los ciclos térmicos TRIP fue utilizada como función objetivo en este problema de optimización. La optimización del proceso de recocido y galvanizado continuo implica el establecimiento de los mejores ciclos térmicos para así alcanzar el máximo potencial mecánico para esta composición química, el cual es desconocido. Una vez realizado lo anterior, se puede obtener un acero avanzado TRIP galvanizado con la mejor microestructura y propiedades posibles.

Generalmente, NSGA-II se puede detallar a grandes rasgos en los siguientes pasos.

Paso 1: Inicialización de la población

Se inicializa una población de padres según las restricciones del problema.

Paso 2: Clasificación no dominada

La población se ordena de acuerdo a los niveles de no dominancia (ordenamiento de los frentes de Pareto F_1, F_2, \dots, F_n .)

Paso 3: Crowding distance (CD)

Una vez que se completa la clasificación, se calcula una CD para cada individuo de la siguiente manera

$$CD_j^i = \frac{fobj_j^{i+1} - fobj_j^{i-1}}{fobj_j^{max} - fobj_j^{min}} \quad (1)$$

donde $fobj_j^{max}$ y $fobj_j^{min}$ son los valores máximos y mínimos de la función objetivo j , $fobj_j^{i+1}$ y $fobj_j^{i-1}$ son las soluciones vecinas a la configuración i para cada una de las funciones objetivo j . El mecanismo de CD se utiliza para mantener la diversidad entre las soluciones desarrolladas, es

la medida del espacio de búsqueda alrededor de i que no está ocupado por otra solución en la población.

Paso 4: Selección

La selección de individuos se lleva a cabo mediante un torneo de selección binaria tomando en cuenta el nivel de no dominancia y la CD. En el caso de estar situados en el mismo frente de Pareto, el ganador del torneo es aquel que tiene mejor (la más alta) crowding distance.

Paso 5: Operadores genéticos

Para calcular la descendencia $x_i^{(1,t+1)}$ y $x_i^{(2,t+1)}$, a partir de las soluciones de los padres $x_i^{(1,t)}$ y $x_i^{(2,t)}$, utiliza el operador de cruce binario simulado (SBX-Simulated Binary Crossover).

La descendencia se calcula de la siguiente manera:

$$x_i^{(1,t+1)} = 0.5[(1 + \beta_i) x_i^{(1,t)} + (1 - \beta_i)x_i^{(2,t)}] \quad (2)$$

$$x_i^{(2,t+1)} = 0.5[(1 + \beta_i) x_i^{(2,t)} + (1 - \beta_i)x_i^{(1,t)}] \quad (3)$$

$$\beta_i = \left| \frac{x_i^{(2,t+1)} - x_i^{(1,t+1)}}{x_i^{(2,t)} - x_i^{(1,t)}} \right| \quad (4)$$

Por otra parte, el operador mutación con probabilidad polinomial, cambia elementos de una solución al azar, buscando aumentar la diversidad de la población y proporciona un mecanismo para escapar de un óptimos locales.

Paso 6: Recombinación y selección

La población de descendientes y la población de la generación actual se combinan y los individuos de la próxima generación se establecen por selección. La nueva generación se llena por cada frente hasta que el tamaño de la población excede el tamaño de la población actual.

Por último, el algoritmo termina cuando se alcanza el número de generaciones establecido por el usuario.

Considerando esto, la configuración de parámetros utilizada en este trabajo es la siguiente: el número máximo de generaciones, el tamaño de la población, el porcentaje de cruce y de mutación fueron 1000, 100, 0.9 y 0.33, respectivamente.

Finalmente, se define el siguiente problema de optimización multi-objetivo:

$$\min (-f_1(x), f_2(x), -f_3(x))$$

Sujeto a

$$15 \leq x_1 \leq 60$$

$$30 \leq x_2 \leq 60$$

$$15 \leq x_3 \leq 60$$

Donde $x = (x_1, x_2, x_3)^t$. Además, x_1 denota la velocidad de enfriamiento (V1), x_2 el tiempo de mantenimiento (t2) y x_3 es la velocidad de enfriamiento (V2). $f(x) = (f_1(x), f_2(x), f_3(x))$ se refiere a la salida no lineal del

modelo BPNN donde $f_1(x), f_2(x), f_3(x)$ denotan las respuestas UTS, YS y %EL, respectivamente.

III DISCUSIÓN DE RESULTADOS

A. Cálculo de Diagramas de Transformación usando JMatPro

Utilizando la composición química promedio presentada en la Tabla I se calcularon los diagramas CCT y TTT. Estos diagramas fueron utilizados como herramienta de apoyo para el diseño de los ciclos experimentales de tratamiento térmico TRIP. En particular, el diagrama CCT se empleó como base para el diseño de las rampas de enfriamiento (V1, velocidad de enfriamiento posterior a la austenización intercrítica y V2, velocidad de enfriamiento final). Por su parte, el diagrama TTT se utilizó en el diseño de la etapa de mantenimiento isotérmico (t2, tiempo de mantenimiento a la temperatura de transformación bainítica).

B. Diagramas de transformación CCT y TTT para la Transformación de Austenita Intercrítica

La Fig. 3 muestra los diagramas CCT y TTT teóricos en un mismo grafico de manera sobrepuesta, la línea verde sólida representa el diagrama CCT y la línea azul discontinua el diagrama TTT. En general, el diagrama CCT obtenido para esta condición exhibe 4 principales regiones correspondientes a la transformación de ferrita, perlita, bainita y martensita. La austenita permanece metaestable a velocidades de enfriamiento mayores a ~ 20 °C/s y transforma inicialmente a perlita a velocidades de enfriamiento menores a ~ 10 °C/s y $T > \sim 450$ °C. Subsecuentemente, el siguiente producto de transformación del acero es etiquetado como ferrita proeutectoide y solo tiene lugar en un rango de velocidad de enfriamiento de ~ 0.01 a 1 °C/s. Por otro lado, en relación a la transformación martensítica, el diagrama CCT calculado reveló que hay un rango de velocidades de enfriamiento (20-100 °C/s) donde la austenita transforma totalmente a martensita. Según estos resultados teóricos de transformaciones de fase, las velocidades de enfriamiento (V1 y V2) para el diseño y procesamiento experimental de aceros TRIP deben ser superiores a 10 °C/s.

Por otra parte, el diagrama revela las siguientes transformaciones de fase: Ferrita pro-eutectoide (F), perlita (P), bainita (B). La transformación perlítica se encuentra a temperaturas superiores a 450 °C, observándose el inicio de la transformación en 8 segundos a 630 °C. La transformación bainítica ocurre entre 450 y 230 °C y se inicia en ~ 15 segundos a 380 °C. Por otra parte, de acuerdo con el diagrama TTT, el tiempo de mantenimiento a la temperatura de transformación bainítica debe ser superior a 15 s, aproximadamente.

Una vez analizados los diagramas de transformación, se diseñaron los ciclos térmicos requeridos para la creación de una microestructura que favorezca el fenómeno TRIP. La velocidad V1, el tiempo t2 y la velocidad V2 se variaron en los rangos de 15 a 60 °C/s, 30 a 60 s y 15 a 60 °C/s, respectivamente. Mientras que, las temperaturas T1 y T2 se mantuvieron constantes a 800 °C y 400 °C, respectivamente. Por lo que, el ciclo térmico no sería compatible con el proceso

de galvanizado continuo debido principalmente a que la temperatura T2 está por debajo del punto de fusión del zinc.

C. Simulación teórica de ciclos térmicos

El efecto de los parámetros de tratamiento térmico TRIP, V1, t2 y V2, sobre las propiedades mecánicas y microestructura fue simulado usando el programa *JMatPro* a partir de la composición química del acero experimental.

El diseño de experimentos central compuesto dio como resultado un total de 17 pruebas con V1, t2, V2 como variables de entrada y UTS, YS, %EL, YS/UTS, porcentaje de F, B, M, A, P como variables de salida se ilustran en la Tabla III. Como se puede apreciar, el programa calcula una microestructura consistente de 42% ferrita, la cual corresponde a la ferrita intercrítica, además de cantidades variadas de bainita y martensita.

Por otra parte, el software no es capaz de calcular de manera precisa la austenita retenida, la cual es la principal característica del acero TRIP. Resulta claro que el programa *JMatPro* no puede aplicarse directamente para el cálculo de microestructuras de este tipo, no obstante, se puede suponer que gran parte de la martensita calculada por el programa resultará en austenita retenida (AR) debido al enriquecimiento de carbono de la austenita, más la presencia de elementos estabilizadores de la austenita como Mn y Si [12, 13].

Estos resultados demuestran que el software no puede aplicarse para calcular el efecto de este tipo de tratamientos térmicos sobre las propiedades mecánicas de aceros, lo cual, sugiere que ambos diagramas de transformación CCT y TTT, así como los diferentes ciclos térmicos TRIP tengan que ser realizados y reproducidos experimentalmente.

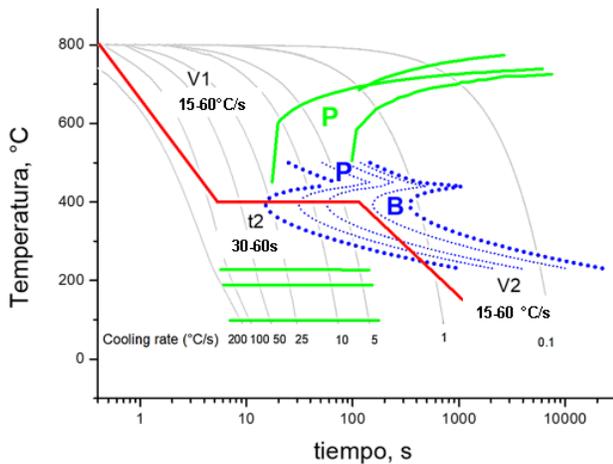


Fig. 3. Acoplamiento de los diagramas CCT (línea verde continua) y TTT (línea azul discontinua) para la transformación de austenita intercrítica (austenizada a 800 °C). La línea roja ilustra un tratamiento térmico típico adecuado para la fabricación de acero TRIP.

Como se mencionó anteriormente, Los datos reportados en la Tabla III se utilizaron para entrenar la red neuronal artificial aplicada para la predicción de propiedades mecánicas con las variables de tratamiento térmico de entrada ya mencionadas.

D. Modelado mediante una red neuronal

El desempeño de la BPNN entrenada se muestra en la Fig. 4, donde se compara el conjunto de datos de prueba (y_k) calculados con *JMarPro* y las respuestas de salida (Y_k) de la BPNN. Se puede inferir del modelo BPNN que los 17 resultados predichos están de acuerdo con los resultados calculados con el MSE de 0.985. Por lo tanto, se puede concluir que el modelo BPNN en este estudio puede usarse para predecir las propiedades mecánicas teóricas de los aceros TRIP galvanizados. En base a la literatura [7, 14], cualquier modelo bien entrenado basado en ANN es superior a cualquier otro enfoque estadístico debido a la naturaleza de las estructuras de redes neuronales artificiales para modelar fenómenos no lineales. Además, según el MSE, otra conclusión es que 17 ensayos fueron suficientes para que la red neuronal tenga un buen desempeño.

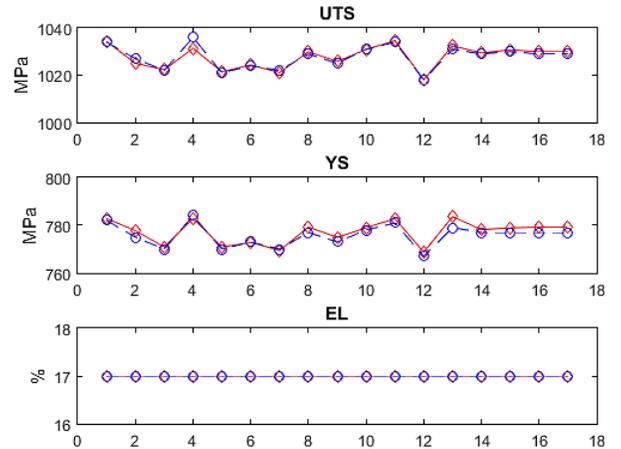


Fig. 4. Comparación entre los valores teóricos (línea discontinua azul-círculo) y los predichos por el modelo BPNN (línea continua roja-diamante).

E. Optimización Multi-Objetivo

Como se mencionó en las secciones anteriores, el objetivo principal de este trabajo de investigación es minimizar el esfuerzo de cedencia (YS) y maximizar tanto la resistencia última a la tracción (UTS) como el alargamiento total (EL).

Los resultados de la optimización dieron como resultado un Frente de Pareto con 39 soluciones óptimas. Cabe señalar que el número de tratamientos óptimos representados en el Frente de Pareto fue mayor que los datos de entrenamiento. Por lo tanto, se logró el propósito de la optimización.

De las 39 soluciones óptimas se seleccionaron 5 condiciones de tratamiento térmico (pruebas 3, 12, 15, 22 y 27) para ser validados teóricamente mediante *JMatPro*. Los criterios para seleccionar las pruebas de validación fueron particularmente 2, primero que los parámetros sean los más próximos a los utilizados en líneas industriales de recocido y galvanizado continuo y segundo que los valores de los parámetros seleccionados no sean muy similares entre cada condición, es decir, los ciclos de tratamiento térmico más extremos.

Los resultados obtenidos de la validación fueron comparados con los resultados numéricos predichos a través

de la red neuronal y se muestran en la Tabla IV. Como se puede apreciar en la Fig. 5, se lograron excelentes predicciones de los resultados teóricos a través del modelo BPNN empleado. Para los tres casos estudiados, el porcentaje de error en la predicción de las propiedades mecánicas de YS, UTS y EL no supera el 2%, lo cual es bastante destacable. Basado en lo anterior, se puede concluir que el modelo BPNN y el algoritmo NSGA-II se pueden utilizar de manera simultánea para la optimización y predicción de las propiedades mecánicas de aceros avanzados galvanizados grado TRIP.

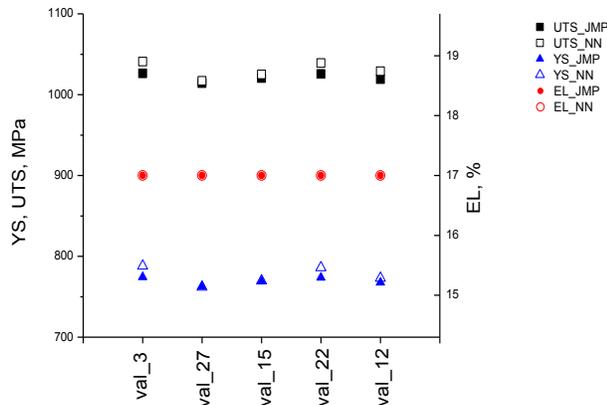


Fig. 5. Comparación entre los resultados del modelo (BPNN) y los resultados teóricos (JMP).

IV CONCLUSIONES

A. Según el análisis teórico, las cantidades relativas de ferrita, bainita, martensita, austenita, así como las propiedades mecánicas dependen de manera directa de los parámetros del tratamiento térmico TRIP: V1, t2 y V2.

B. Debido a que el programa *JMatPro* no toma en cuenta la estabilización de la austenita ni considera el enriquecimiento con carbono de la austenita intercrítica, no es posible utilizarlo para el diseño de estos tipos de aceros AHSS. Sin embargo, este programa sirve como un apoyo para detectar las tendencias generales del efecto de la velocidad de enfriamiento sobre comportamiento de transformaciones de fase en el material.

C. La compleja relación entre los parámetros de procesamiento térmico y las propiedades mecánicas, se puede modelar exitosamente a través de una BPNN.

D. El algoritmo genético pudo usarse de manera eficiente para encontrar los parámetros del proceso resultantes en una buena combinación de resistencia y ductilidad, utilizando una red neuronal de propagación hacia atrás como función objetivo.

E. La metodología/estrategia computacional planteada por vez primera en el diseño de procesos TRIP basada en la aplicación simultánea de redes neuronales y algoritmos genéticos puede predecir correctamente las propiedades

mecánicas finales de aceros TRIP procesados bajo condiciones de recocido y galvanizado continuo.

AGRADECIMIENTOS

Los autores agradecen al CINVESTAV/Unidad Saltillo por el apoyo otorgado a este proyecto.

REFERENCIAS

- [1] M. C. Elish, "Moral Crumple Zones: Cautionary Tales in Human-Robot Interaction," *Engag. Sci. Technol. Soc.*, vol. 5, p. 40, 2019, doi: 10.17351/ests2019.260.
- [2] D. Bhattacharya, "Developments in Advanced High Strength Steels," *Aist*, no. 724, pp. 1–8, 2005, doi: 10.4271/2005-01-1329.
- [3] B. Kuceroová, L.; Jirková, H.; Mašek, "Continuous Cooling of CMnSi TRIP Steel.," *Mater*, vol. 2, pp. 677–680, 2014.
- [4] A. . Chiang, J.; Boyd, J.D.; Pilkey, "Effect of microstructure on retained austenite stability and tensile behaviour in an aluminum-alloyed TRIP steel," *Mater. Sci. Eng*, vol. 638, pp. 132–142, 2015.
- [5] S. Kuang, Y. lin Kang, H. Yu, and R. dong Liu, "Effect of continuous annealing parameters on the mechanical properties and microstructures of a cold rolled dual phase steel," *Int. J. Miner. Metall. Mater.*, vol. 16, no. 2, pp. 159–164, 2009, doi: 10.1016/S1674-4799(09)60027-3.
- [6] P.] Seol, J.-B.; Raabe, D.; Choi, "Atomic scale effects of alloying, partitioning, solute drag and austempering on the mechanical properties of high-carbon bainitic-austenitic TRIP steels," *Acta Mater*, vol. 60, pp. 6183–6199, 2002.
- [7] K. Min, B. Choi, K. Park, and E. Cho, "Machine learning assisted optimization of electrochemical properties for Ni-rich cathode materials," *Sci. Rep.*, vol. 8, no. 1, pp. 1–7, 2018, doi: 10.1038/s41598-018-34201-4.
- [8] Y. Jin and B. Sendhoff, "Pareto-based multiobjective machine learning: An overview and case studies," *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, vol. 38, no. 3, pp. 397–415, 2008, doi: 10.1109/TSMCC.2008.919172.
- [9] C. Von L, "Algoritmos Evolutivos para Optimización Multiobjetivo," *AIAA*, vol. 41, no. 4, 2003.
- [10] J. L. Lee and H. K. D. H. Bhadeshia, "A methodology for the prediction of time-temperature-transformation diagrams," *Mater. Sci. Eng. A*, vol. 171, no. 1–2, pp. 223–230, Nov. 1993, doi: 10.1016/0921-5093(93)90409-8.
- [11] D. V. Doane, J. S. (John S. Kirkaldy, Metallurgical Society of AIME. Heat Treatment Committee., and American Society for Metals. Activity on Phase Transformations., *Hardenability concepts with applications to steel: proceedings of a symposium held at the Sheraton-Chicago Hotel, October 24-26, 1977*. Metallurgical Society of AIME, 1978.

[12] N. Fonstein, *Advanced High Strength Sheet Steels*. 2015.

[13] W. DING, Z. hua GONG, B. feng WANG, D. TANG, and H. tao JIANG, “Microstructure and Mechanical Properties of TRIP Steel with Annealed Martensite,” *J. Iron Steel Res. Int.*, vol. 21, no. 5, pp. 527–531, 2014, doi: 10.1016/S1006-706X(14)60082-0.

[14] H. Vafaenezhad, S. Ghanei, S. H. Seyedein, H. Beygi, and M. Mazinani, “Process Control Strategies for Dual-Phase Steel Manufacturing Using ANN and ANFIS,” *J. Mater. Eng. Perform.*, vol. 23, no. 11, pp. 3975–3983, Nov. 2014, doi: 10.1007/s11665-014-1174-6.

TABLA III. MATRIZ DE RESULTADOS TEÓRICOS UTILIZADOS PARA EL ENTRENAMIENTO DE LA RED NEURONAL.

V1	t2	V2	UTS	YS	YS/UTS	EL	F	B	M	A	P
°C/s	s	°C/s	MPa	MPa		%	%	%	%	%	%
50	36	51	1034	782	0.756	17	42	20	37	1	0
37	45	15	1027	775	0.755	17	42	40	17	0	0
37	60	37	1022	770	0.753	17	42	56	1.5	0	0
37	30	37	1036	784	0.757	17	42	13	43	1	0
60	45	37	1030	777	0.754	17	42	35	22.67	0.5	0
24	54	24	1021	770	0.754	17	42	51	6	0	0.5
51	54	24	1024	773	0.755	17	42	50	7.8	0	0
24	54	51	1022	770	0.753	17	42	49	7.8	0	0.5
37	45	37	1029	777	0.755	17	42	35.62	21	0.5	0
37	45	37	1029	777	0.755	17	42	35.62	21	0.5	0
51	54	51	1025	773	0.754	17	42	48	10	0	0
24	36	51	1031	778	0.755	17	42	21	35	1	0.5
51	36	24	1034	781	0.755	17	42	22	35	1	0
15	45	37	1018	767	0.753	17	42	38	17	0.5	2.35
37	45	37	1028	777	0.756	17	42	36	21	0.5	0
24	36	24	1031	779	0.756	17	42	23.5	32	1	0.5
37	45	60	1029	777	0.755	17	42	34.5	23	0.5	0

TABLA IV. RESULTADOS DE OPTIMIZACIÓN MULTI-OBJETIVO MEDIANTE ALGORITMOS GENÉTICOS COMPARADOS CON RESULTADOS TEÓRICOS OBTENIDOS POR *JMATPRO*.

Muestra	Variables de entrada			Modelo			Teórico			Error (%)		
	V1	t2	V2	UTS	YS	EL	UTS	YS	EL	UTS	YS	EL
				MPa	MPa	%	MPa	MPa	%	MPa	MPa	%
Val_3	15	30	44	1041	788	17	1026	774	17	1.4	1.8	0
Val_27	15	53	36	1017	762	17	1014	762	17	0.3	0	0
Val_15	15	40	33	1025	770	17	1020	768	17	0.5	0.3	0
Val_22	15	31	35	1039	786	17	1025	773	17	1.3	1.7	0
Val_12	15	43	40	1029	773	17	1018	767	17	1.1	0.8	0