



Modelación empírica de propiedades termofísicas de aceros inoxidables austeníticos

Empirical modelation of thermophysical properties of austenitic stainless steel

Gabriel Roque-Villalonga^I, Yanán Camaraza-Medina^{I,*}, Osvaldo F. García-Morales^I, Yoalbys Retirado-Mediaceja^{II}, Angel M. Rubio-Gonzalez^{III}

I. Universidad de Matanzas, Facultad de Ciencias Técnicas. Matanzas, Cuba

II. Instituto Superior Minero Metalúrgico de Moa, Vicerrectoría de Formación. Holguín Cuba

III. Universidad Central Marta Abreu de las Villas, Centro de Estudios Energéticos y Tecnologías Ambientales. Villaclara, Cuba

* Autor de correspondencia: yanan.camaraza@umcc.cu

Este documento posee una [licencia Creative Commons Reconocimiento-No Comercial 4.0 internacional](#)



Recibido: 8 de octubre de 2022

Aceptado: 2 de diciembre de 2022

Resumen

Las propiedades termofísicas de los aceros son de especial interés en las aplicaciones de la ingeniería térmica. El objetivo de esta investigación es la obtención de un método que permita predecir la influencia de la composición y temperatura de operación sobre las propiedades termofísicas en los aceros inoxidables austeníticos. Mediante el método Flash Laser se obtuvieron 3255 muestras experimentales de aceros AISI laminados y recocidos 301, 302, 304, 310 y 316, que resumen la variación de la conductividad térmica, calor específico, difusividad y densidad, para composiciones conocidas (en por ciento másico) de C, Mn, P, S, Si, Ni, Cr, Mo, V, en un rango de

temperaturas de 0 a 800 °C. Los datos experimentales disponibles fueron procesados mediante técnicas machine learning, desarrollando un modelo que permite computar las propiedades termofísicas objeto de estudio con un error de correlación inferior al 25 % en el 90 % los datos experimentales disponibles. En todos los casos, el modelo obtenido muestra valores adecuados de ajustes y correlación, por lo que puede ser considerado satisfactorio para el diseño práctico.

Palabras claves: acero inoxidable austenítico; modelos empíricos; *machine learning*.

Abstract

The prediction of steel thermophysical properties are special interest for thermal engineering applications. This work aims to obtaining a method for predicting the temperature influence and composition on the variation on the austenitic stainless steels thermophysical properties. Applying the Flash Laser method, 3 255 experimental samples for rolled and annealed AISI steels (301, 302, 304, 310 and 316) was obtained, which summarize the variation of thermal conductivity, specific heat, diffusivity and density, for known compositions (in mass percent) of C, Mn, P, S, Si, Ni, Cr, Mo,

V, in a temperature range from 0 to 800 °C. By means machine learning techniques, the available experimental data were generalized, developing a correlation that fits the experiments validity range, with a deviation of 25% for the 90% of the available experimental data. In all cases, the agreement for the proposed model is good enough to be considered satisfactory for practical design.

Key words: austenitic stainless steel; empirical models; machine learning.

Cómo citar este artículo:

Roque Villalonga G, Camaraza Medina Y, García Morales OF, Retirado Mediaceja Y, Rubio Gonzalez AM. Modelación empírica de propiedades termofísicas de aceros inoxidables austeníticos. Ingeniería Mecánica. 2023;26(1):e661. ISSN 1815-5944.

1. Introducción

El acero inoxidable es un material de especial interés por el importante papel que juega en la vida moderna. Presenta una excelente resistencia a la corrosión y una agradable apariencia para el acabado de productos. Estos contienen Cr, Ni y Mo presentando una estructura austenítica metaestable [1].

Conocer las propiedades térmicas de los materiales resulta imprescindible para las aplicaciones de la transferencia de calor. En los procesos de maquinado gran parte de la energía mecánica se transforma en calor y se transmite a la herramienta de corte provocando en ella temperaturas de hasta 1000 °C. También en la frenada de un automóvil el buen funcionamiento del sistema depende de la capacidad de absorber el calor generado por el frenado y posteriormente una rápida disipación [2].

Es completamente aceptado que la composición química de un material y la temperatura a la que se encuentra modifican su microestructura [3], condicionando así las propiedades de dicho material [4]. También resulta que la relación entre los elementos individuales que componen un material no es lineal con sus propiedades. Aunque en la actualidad el avance de la ingeniería de materiales es considerable, en reiteradas ocasiones se recurre a procesos de experimentación para determinar propiedades de los aceros[5], esto implica un alto costo y fondo de tiempo.

Se destaca la utilidad del empleo de redes neuronales artificiales (RNA) para modelar y correlacionar problemas prácticos de transferencia de calor [6]. Es obtenido un modelo de conductividad térmica en función de la temperatura y la composición química del acero utilizando RNA basada en un marco estadístico bayesiano [7]. El modelo permite la estimación de la conductividad para problemas de transferencia de calor, con incertidumbre adecuada. El desempeño del modelo se demuestra haciendo predicciones de resultados experimentales previos que no fueron incluidos en el proceso que lleva a la creación del mismo.

Ha sido demostrado que el coeficiente de transferencia de calor convectivo puede estimarse mediante la aplicación del método de elementos finitos, a partir de la información crítica con respecto a la transformación de fase que ocurre en condiciones isotérmicas o no isotérmicas; obtenida de diagramas de enfriamiento para bloques de acero forjado de gran tamaño [8]. El coeficiente de transferencia de calor depende de la temperatura, las curvas de enfriamiento, las curvas de velocidad de enfriamiento y la distorsión, las cuales son predichas a partir de la modificación iterativa del método de capacidad calorífica concentrada y el método de transferencia de calor inverso en aceros AISI 304 realizando análisis con el software DEFORM-HT 2D [9].

Somasundharam and Reddy [10] ejecutaron la estimación simultánea de la conductividad térmica dependiente de la temperatura y la capacidad calorífica específica de sólidos isotrópicos, asumiendo que las propiedades térmicas desconocidas son una variación paramétrica con la temperatura, donde estos parámetros fueron estimados a partir de la solución del problema inverso con muestras de acero inoxidable, simulando la termodinámica y modelación de diagramas de fase, empleando un algoritmo genético para la estimación de parámetros. Los valores obtenidos muestran un ajuste $\pm 10\%$ con respecto a datos experimentales disponibles en la literatura [11, 12].

En la actualidad, los métodos disponibles en la literatura técnica consultada y disponible, se concentran en la predicción de las propiedades termofísicas de un material en específico, y en el caso que sean abordados varios materiales, la predicción de propiedades termofísicas se limita a una sola, la cual generalmente responde a la conductividad térmica [13].

En la actualidad no se dispone de un método de análisis para la predicción de propiedades termofísicas en los aceros inoxidables austeníticos. Por tal motivo en la presente investigación es analizada la influencia de la composición química (C, Mn, P, S, Si, Ni, Cr, Mo) y la temperatura de operación de 0 a 800 °C sobre cuatro propiedades termofísicas (conductividad térmica, calor específico, densidad y difusividad) en cinco aceros inoxidables austeníticos de marcación AISI 301, 302, 304, 310, 316, obtenidos por laminado y recocidos.

Para este propósito se dispone de una base de datos experimentales obtenidos en una colaboración con la Universidad de Khazar, Azerbaijan la cual consta de 3255 mediciones para cada propiedad en el intervalo analizado. Para el desarrollo de los métodos de predicción son aplicadas técnicas de aprendizaje automático con el objetivo de obtener modelos empíricos que permitan con un adecuado nivel de incertidumbre predecir las propiedades de interés, siendo de utilidad práctica para su uso en la ingeniería térmica.

Por lo anteriormente explicado el objetivo de la presente investigación es obtener un método para predecir la influencia de la composición química y la temperatura de operación sobre las propiedades termofísicas en los aceros inoxidables austeníticos.

2. Métodos y Materiales

2.1. Obtención de los datos experimentales

Para la obtención de los datos experimentales se usó el método flash laser (MFL) [14]. Las principales bondades del MFL residen en el corto tiempo necesario para realizar las mediciones, el amplio rango de temperaturas en que se puede aplicar y el pequeño tamaño de muestras necesario, siendo el método más empleado para este fin. El mismo consiste en someter una muestra de sólido a un pulso de energía radiante a una de sus caras suministrando calor, registrando el aumento de temperatura en la cara opuesta. Fue utilizado como equipamiento el LZT-Meter con precisión de $\pm 4\%$ del fabricante LINSEIS.

La difusividad térmica se relaciona con la conductividad térmica como se muestra en la ecuación (1)

$$\alpha = \lambda (C_p \rho)^{-1} \quad (1)$$

Donde: λ es la conductividad térmica, en $W / (m \cdot K)$, C_p es el calor específico en $J / (kg \cdot K)$, ρ es la densidad, en Kg / m^3 .

Según especifica el fabricante del equipo la difusividad térmica es determinada a partir de la ecuación (2).

$$\alpha = 0,13879 L^2 / t_{1/2} \quad (2)$$

Dónde: α es la difusividad térmica en m^2 / s . L es el espesor de la muestra en mm y $t_{1/2}$ es la mitad del tiempo del experimento en s .

A partir de una muestra de referencia se comparó el aumento de temperatura con el fin de calcular el calor específico. El aumento de temperatura se obtuvo a partir de la ecuación (3).

$$\Delta T = \frac{E}{m \cdot cp} \tag{3}$$

Dónde: ΔT es el aumento de temperatura en K , E, m es la energía en J , m es la masa de la muestra en g y cp es la capacidad calorífica en $J / (kg \cdot K)$

Al ser iguales la energía de la muestra y la referencia se calculó el calor específico mediante la ecuación (4):

$$cp_{muestra} = \frac{cp_{referencia} \cdot \Delta T_{referencia} \cdot m_{referencia}}{\Delta T_{muestra} \cdot m_{muestra}} \tag{4}$$

La densidad de la muestra se determinó usando un densímetro DIL L75 Quattro del fabricante LINSEIS, posteriormente la conductividad térmica se despejó en la ecuación (1) obteniéndose la ecuación (5):

$$\lambda(T) = \alpha(T) \cdot cp(T) \cdot \rho(T) \tag{5}$$

Dónde: ρ es la densidad de la muestra en g / cm^3 .

Las mediciones se realizaron bajo la norma ASTM E1225-13 [15].

2.2. Resultados de las mediciones

Las mediciones son realizadas a barras laminadas y recocidas con composición química certificada por su fabricante (ACEROS YIOLDIO). En la tabla 1 son resumidos el rango de composición química en porcentaje másico (w %) y los valores de cada propiedad para cada una de las marcaciones estudiadas.

Tabla 1. Composición de las muestras. Fuente: autores

Acero	AISI-301			AISI-302			AISI 304		
Variable	Media	Mínimo	Máximo	Media	Mínimo	Máximo	Media	Mínimo	Máximo
C	0,132	0,100	0,150	0,132	0,100	0,150	0,070	0,050	0,080
Mn	1,890	1,800	2,000	1,890	1,800	2,000	1,891	1,800	2
P	0,027	0,020	0,045	0,027	0,020	0,045	0,027	0,020	0,045
S	0,022	0,015	0,030	0,022	0,015	0,030	0,022	0,015	0,030
Si	0,640	0,500	0,750	0,640	0,500	0,750	0,639	0,500	0,750
Ni	6,839	6,000	8,000	6,839	6	8	9,062	8	10,500
Cr	17,194	16	18	18,194	17	19	19,183	18,000	20
Mo	0	0	0	0	0	0	0	0	0
$\lambda \ W/(m \cdot K)$	18,578	12,900	27,400	17,967	11,600	27,000	17,364	11,20	26,10
$Cp \ J / (kg \cdot K)$	564,420	470	748	552,690	460	733	545,88	456,0	720,0
$\rho \ kg / m^3$	7885,60	7838,00	7933,0	8023,30	7976,00	8071,00	7918,0	7872,0	7965,0
$\alpha \ m^2/s \cdot 10^{-5}$	0,419	0,300	0,540	0,419	0,300	0,540	0,419	0,300	0,540
	AISI 310			AISI-316					
C	0,231	0,200	0,250	0,070	0,050	0,080			
Mn	1,894	1,800	2,000	1,889	1,800	2,000			
P	0,027	0,020	0,045	0,027	0,020	0,045			
S	0,022	0,015	0,030	0,022	0,015	0,030			
Si	1,313	1,100	1,500	0,641	0,500	0,750			
Ni	20,306	19	22	11,656	10	14			
Cr	24,671	24,000	25,400	17,204	16,000	18			
Mo	0	0	0	2,575	2,000	3,000			
$\lambda \ W/(m \cdot K)$	16,774	10,800	25,300	15,713	10,100	23,600			
$Cp \ J / (kg \cdot K)$	540,220	451	714	528,790	441	699			
$\rho \ kg / m^3$	7969,5	7924	8018	8109	8063	8159			
$\alpha \ m^2/s \cdot 10^{-5}$	0,419	0,300	0,540	0,419	0,300	0,540			

En la figura 1 son graficadas las variaciones de los valores de cada propiedad respecto a la temperatura de trabajo para una composición química media de cada acero estudiado.

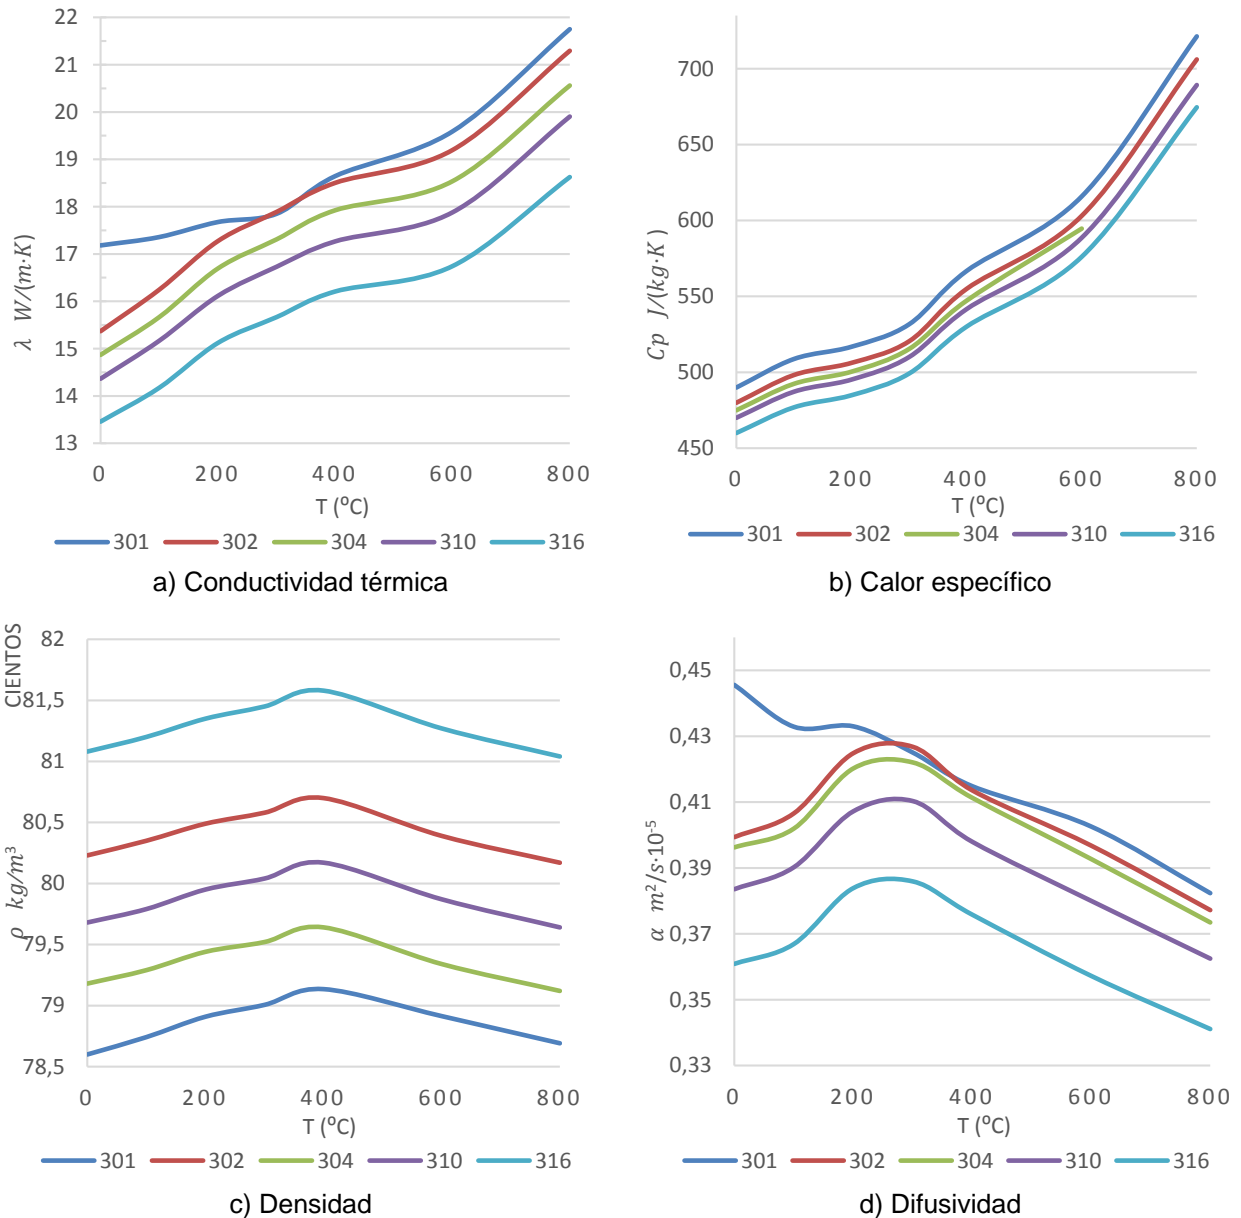


Fig. 1. Variación de las propiedades con la temperatura de trabajo. Fuente: autores

2.3. Procesamiento de los datos

Es realizado un análisis de varianza (ANOVA) para comprobar que todas las variables independientes aporten significativamente al modelo, en todos los casos se confirma la hipótesis nula. Se estimó el coeficiente de correlación de Pearson comprobándose que no existe alta correlación lineal entre predictores. Se efectuó un filtrado por varianza para eliminar predictores no informativos. Se analizó la existencia de predictores con varianza cero o muy próxima a cero y no resulta el caso.

Cuando se ejecutó el centrado de los datos se consiguió que todos los predictores tuvieran una media igual a cero, sustrayendo a cada valor la media del predictor. Para el normalizado de los datos se usó la ecuación (6).

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \tag{6}$$

Dónde: X' es el valor normalizado, X es el valor real, X_{min} es el valor mínimo de la variable en cuestión y X_{max} el valor máximo.

Se efectuó una división aleatoria de los datos en proporción 80-20, de ellos, el mayor conjunto se empleó para entrenamiento y validación de modelos y el menor para su comprobación. Durante la división se garantizó la distribución similar de la variable de respuesta en ambos conjuntos.

2.4. K-Vecino más cercano

El algoritmo de aprendizaje *K-Nearest Neighbor* (KNN) que se basa en asignar como valor de predicción la clase dominante entre un determinado número de observaciones vecinas, denominado en este caso hiperparámetro *k*, el cual permite buenas aproximaciones en muchos casos a pesar de su baja complejidad [16]. Esta razón genera que sea la primera elección para modelar los casos de estudio.

Para cada una de las propiedades se optimiza *k* mediante una búsqueda de malla, entrenando el modelo para valores de 1 a 10. Es implementada una validación cruzada en la que se toma un 10 % del subconjunto de entrenamiento como subconjunto de validación y esto a su vez es repetido en cinco ocasiones, garantizando la convergencia de los modelos. La figura 2 muestra el desarrollo de las optimizaciones, con los datos previamente centrados y normalizados, en función del aumento de *k*.

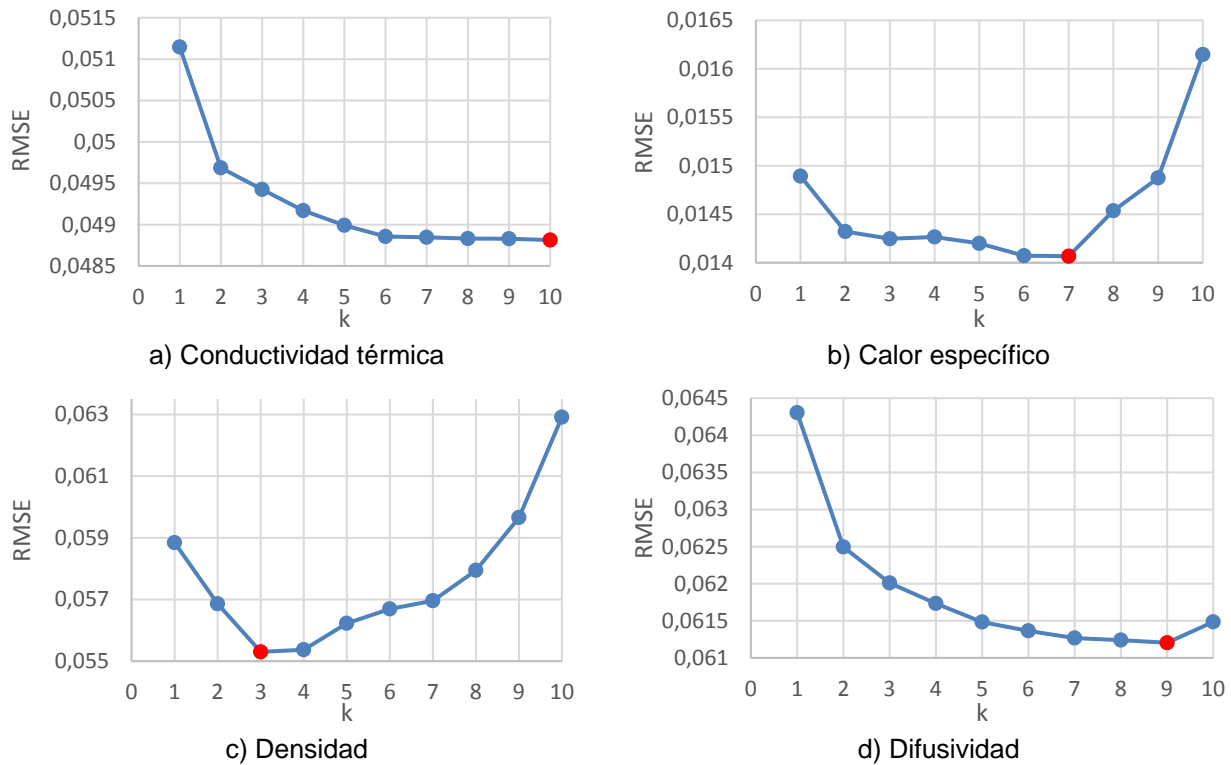


Fig.2. Desarrollo de las optimizaciones en función de *k*. Fuente: autores

La métrica preferida para la optimización es la raíz del error cuadrático medio de los residuales (RMSE) que permite medir la cantidad de error entre dos conjuntos de datos, siendo mejor al resultar más cercano a cero. También se estudia el valor de la media de los errores en valor absoluto (MAE) que resulta más robusto que RMSE al no otorgar alta importancia a valores atípicos. Ambos son resumidos en la tabla 2, donde además se encuentra el coeficiente de determinación (R^2) de los modelos preferidos.

Tabla 2. Métricas de modelos preferidos empleando KNN. Fuente: autores

Métrica	Temperatura °C							
	$\lambda \text{ W}/(m \cdot K) \text{ } k = 10 \text{ } R^2 = 0,93$							
	0	100	200	300	400	600	800	TOTAL
RMSE	0,85	0,81	0,83	0,84	0,86	0,82	0,98	0,86
MAE	0,69	0,63	0,66	0,69	0,68	0,67	0,83	0,69
	$C_p \text{ J}/(kg \cdot K) \text{ } k = 7 \text{ } R^2 = 0,99$							
	0	100	200	300	400	600	800	TOTAL
RMSE	3,9	3,7	3,8	4,0	4,4	4,6	5,2	4,2
MAE	3,1	3,0	3,2	3,2	3,2	3,7	4,3	3,4
	$\rho \text{ kg}/m^3 \text{ } k = 3 \text{ } R^2 = 0,94$							
	0	100	200	300	400	600	800	TOTAL
RMSE	24,2	18,9	15,22	13,0	17,5	18,8	17,3	18,0
MAE	9,0	8,3	5,4	5,8	7,0	8,2	7,0	7,2
	$\alpha \text{ m}^2/\text{s} \cdot 10^{-5} \text{ } k = 9 \text{ } R^2 = 0,85$							
	0	100	200	300	400	600	800	TOTAL
RMSE	0,018	0,016	0,016	0,019	0,016	0,015	0,013	0,016
MAE	0,015	0,012	0,013	0,015	0,013	0,012	0,010	0,013

2.5. Red neuronal

La RNA, que matemáticamente resulta una aproximación funcional que ajustando hiperparámetros se ajusta a los datos, está inspirada en el cerebro humano, que es una red densamente conectada y empaquetada. El empleo de RNA para modelar propiedades termofísicas ha resultado óptimo en repetidas instancias [17]. La arquitectura de la RNA entrenada es mostrada en la figura 3.

En esta investigación es usado el subconjunto 80 % para entrenar una RNA de una capa oculta para la cual se optimizan, empleando una búsqueda de malla, los hiperparámetros correspondientes al número de neuronas en la capa oculta (n) y a la regularización. Son usadas las métricas RMSE, MAE y R^2 , la validación cruzada con subconjuntos de validación de 10 % y cinco repeticiones para garantizar tanto la convergencia del modelo como la optimización de hiperparámetros. En la figura 4 es mostrado el desarrollo de las optimizaciones para cada propiedad. En la tabla 3 son resumidas las métricas obtenidas para los modelos preferidos.

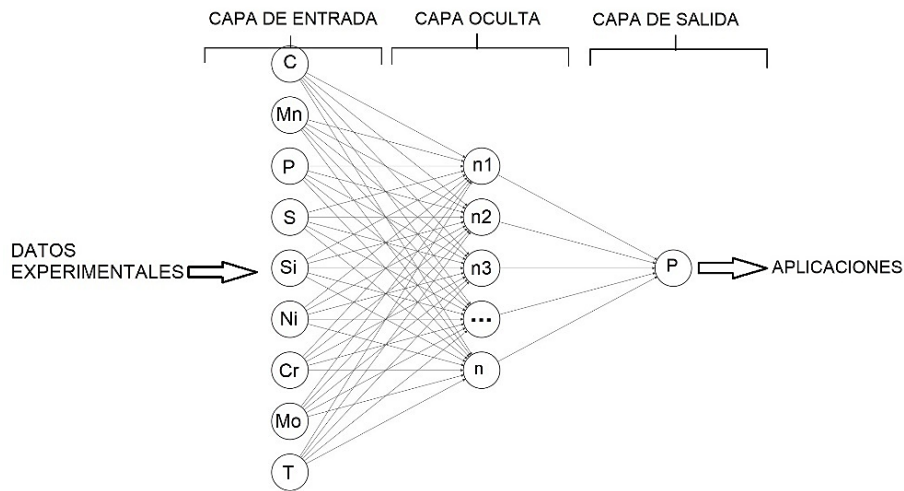


Fig. 3. Arquitectura de la RNA. Fuente: autores

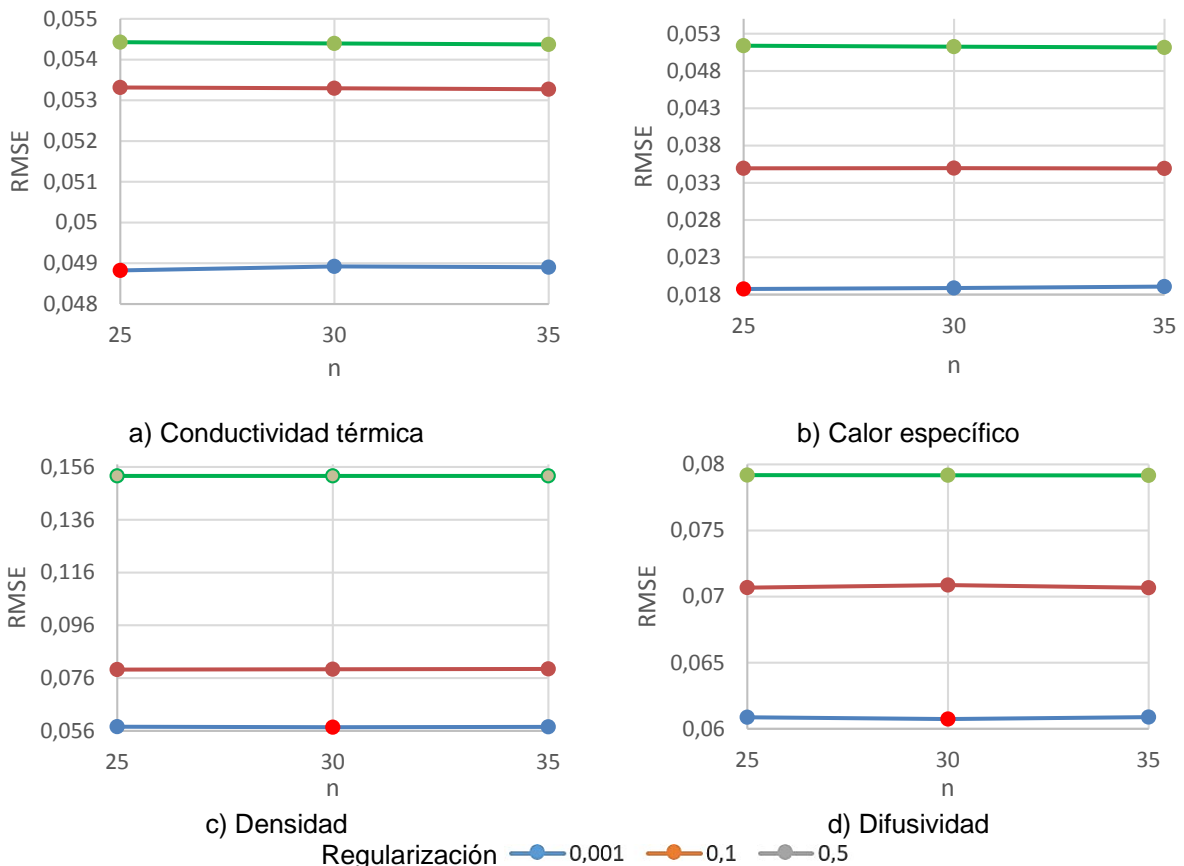


Fig. 4. Desarrollo de las optimizaciones en función de n y la regularización. Fuente: autores

Tabla 3. Métricas de modelos preferidos empleando RNA. Fuente: autores

Métrica	Temperatura °C							
	0	100	200	300	400	600	800	TOTAL
$\lambda \text{ W}/(m \cdot K) n = 25 \text{Regularización} = 0,001 R^2 = 0,91$								
RMSE	0,80	0,77	0,78	0,82	0,84	0,82	0,90	0,82
MAE	0,64	0,62	0,63	0,67	0,68	0,67	0,74	0,66
$C_p \text{ J}/(kg \cdot K) n = 25 \text{Regularización} = 0,001 R^2 = 0,99$								
RMSE	5,1	6,4	4,1	6,2	6,4	4,7	5,9	5,6
MAE	4,1	5,3	3,5	5,2	5,2	3,8	4,8	4,5
$\rho \text{ kg}/m^3 n = 30 \text{Regularización} = 0,001 R^2 = 0,95$								
RMSE	25,2	18,6	14,0	16,6	17,9	14,3	17,8	17,0
MAE	13,2	10,5	6,9	8,5	8,6	8,7	9,6	9,4
$\alpha \text{ m}^2/s \cdot 10^{-5} n = 30 \text{Regularización} = 0,001 R^2 = 0,94$								
RMSE	0,018	0,016	0,016	0,018	0,016	0,015	0,013	0,016
MAE	0,015	0,012	0,013	0,015	0,013	0,012	0,010	0,013

Resultados y Discusión

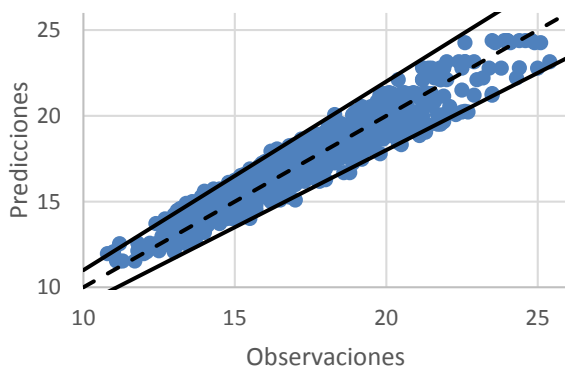
Una vez obtenidos los modelos mediante KNN y RNA es realizada una comparación de las métricas de los modelos preferidos en cada caso para seleccionar el óptimo en cada propiedad, ver tabla 4.

Tabla 4. Comparación de modelos preferidos KNN y RNA. Fuente: autores

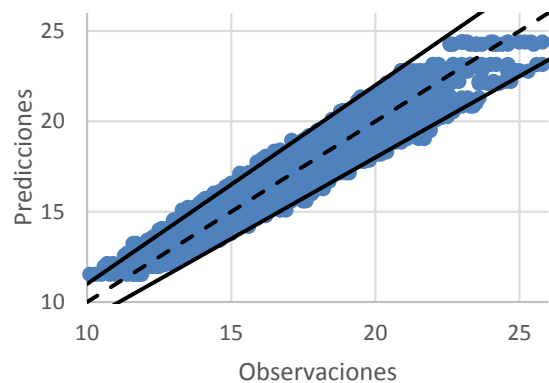
Propiedad	Métrica	KNN	RNA
λ $W/(m \cdot K)$	RMSE	0,86	0,82 *
	MAE	0,69	0,66
C_p $J/(kg \cdot K)$	RMSE	4,2 *	5,6
	MAE	3,4	4,5
ρ kg/m^3	RMSE	18,0	17,0 *
	MAE	7,2	9,4
α $m^2/s \cdot 10^{-5}$	RMSE	0,016 *	0,016
	MAE	0,013	0,013

Con * se destaca la variante seleccionada

Para la validación de los modelos han sido empleados los datos del subconjunto de prueba reservado previamente para construir los gráficos de predicciones contra observaciones, mostrados en la figura 5 donde además son dados los gráficos de residuales [18], apreciándose que no existe autocorrelación entre los residuos y que la varianza de los errores es constante, además, como los residuales se pueden encerrar entre bandas horizontales se establece que no se existen defectos obvios en el modelo [19]. Las rectas continuas indican las desviaciones $\pm 10\%$ y en la mayoría de los casos los valores se encuentran entre estas. Los detalles de porcentaje de error son dados en la tabla 5.



a) Predicciones vs Observaciones del conjunto de entrenamiento



b) Predicciones vs Observaciones del conjunto de prueba

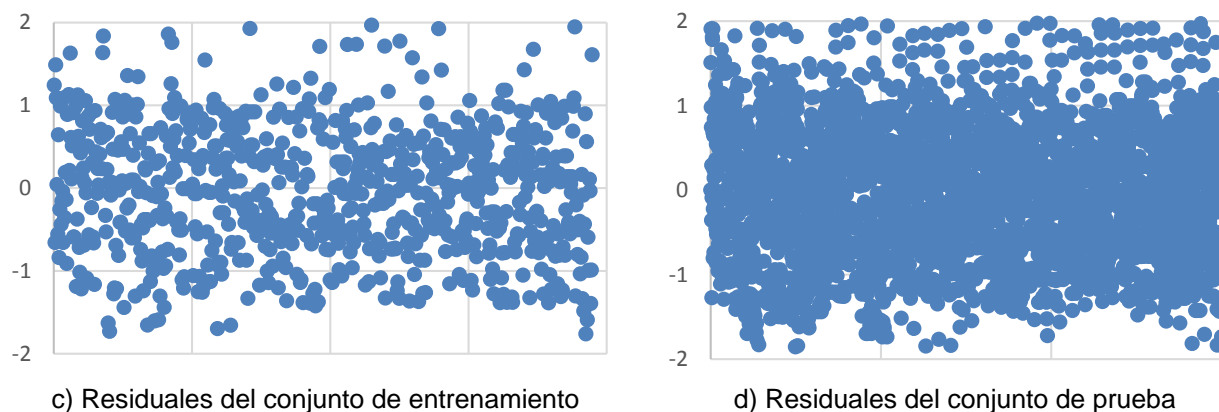


Fig. 5. Validación del modelo de conductividad térmica. Fuente: autores.

Tabla 5. Error porcentual del conjunto de prueba. Fuente: autores

Propiedad	Error <5%	Error <15%	Error <25%
$\lambda \text{ W}/(\text{m} \cdot \text{K})$	28%	78%	94%
$C_p \text{ J}/(\text{kg} \cdot \text{K})$	65%	96%	99%
$\rho \text{ kg}/\text{m}^3$	60%	84%	90%
$\alpha \text{ m}^2/\text{s} \cdot 10^{-5}$	28%	51%	90%

Conclusiones

Mediante el empleo de algoritmos de aprendizaje automático se obtienen de modelos empíricos que permiten predecir con un adecuado nivel de incertidumbre las propiedades termofísicas de aceros inoxidable austeníticos AISI para una temperatura de operación de 0 a 800 °C. Se emplean como predictores la composición química y la temperatura de trabajo.

Para la conductividad térmica y la densidad resulta mejor el modelo entrenado con RNA y para el calor específico y la difusividad el algoritmo KNN. Se logra un error porcentual inferior al 25 % para más del 90 % de los casos. El modelo obtenido muestra un ajuste adecuado con los datos experimentales disponibles, por lo que se considera adecuado para su uso en la práctica ingenieril.

Referencias

- Ramos NP, dos Santos Carollo LF. Contact resistance analysis applied to simultaneous estimation of thermal properties of metals. *Measurement Science and Technology*. 2020;31(10):105601. DOI 10.1088/1361-6501/ab8e6a.
- Hernandez Duran EI, Corallo L, Ros Yanez T. Influence of Mo-Nb-Ti additions and peak annealing temperature on the microstructure and mechanical properties of low alloy steels after ultrafast heating process. *Materials Science and Engineering: A*. 2021;808:140928. DOI 10.1016/j.msea.2021.140928.
- Ahadi Akhlaghi I, Salkhordeh Haghghi M, Kahrobaee S. Prediction of chemical composition and mechanical properties in powder metallurgical steels using multi-electromagnetic nondestructive methods and a data fusion system. *Journal of Magnetism and Magnetic Materials*. 2020;498:166246. DOI 10.1016/j.jmmm.2019.166246.
- Narayana PL, Lee SW, Park CH. Modeling high-temperature mechanical properties of austenitic stainless steels by neural networks. *Computational Materials Science*. 2020;179:109617. DOI 10.1016/j.commatsci.2020.109617.
- Guo S, Yu J, Liu X. A predicting model for properties of steel using the industrial big data based on machine learning. *Computational Materials Science*. 2019;160:95-104. DOI 10.1016/j.commatsci.2018.12.056.
- Borisade SG, Ajibola OO, Adebayo AO, et al. Development of mathematical models for the prediction of mechanical properties of low carbon steel (LCS). *Materials Today: Proceedings*. 2020;38:1133-1139. DOI 10.1016/j.matpr.2020.07.134.
- Peet MJ, Hasan HS, Bhadeshia HK. Prediction of thermal conductivity of steel. *International Journal of Heat and Mass Transfer*. 2011;54(11):2602-8. DOI 10.1016/j.ijheatmasstransfer.2011.01.025.
- Bouissa Y, Shahriari D, Champlaud H. Prediction of heat transfer coefficient during quenching of large size forged blocks using modeling and experimental validation. *Case Studies in Thermal Engineering*. 2019;13:100379. DOI 10.1016/j.csite.2018.100379.
- Somasundharam S, Reddy KS. Inverse analysis for simultaneous estimation of temperature dependent thermal properties of isotropic materials. *Thermal Science and Engineering Progress*. 2020;20:100728. DOI 10.1016/j.tsep.2020.100728.
- Karkhin VA. *Thermophysical Properties of Metals*. In: *Thermal Processes in Welding*. Germany: Springer; 2019. [Citado: 25 de febrero de 2022] Disponible en: <https://link.springer.com/book/10.1007/978-981-13-5965-1>
- Saoudi A, Fellah M, Hezil N. Prediction of mechanical properties of welded steel X70 pipeline using neural network modelling. *International Journal of Pressure Vessels and Piping*. 2020;186:104153. DOI 10.1016/j.ijpvp.2020.104153.
- Xie Q, Suvarna M, Li J. Online prediction of mechanical properties of hot rolled steel plate using machine learning. *Materials & Design*. 2021;197:109201. DOI 10.1016/j.matdes.2020.109201.
- Xing Y, Wang W, Al-azzani H. Assessment of thermal properties of various types of high-strength steels at elevated temperatures. *Fire Safety Journal*. 2021:103348. DOI 10.1016/j.firesaf.2021.103348.
- Parker W, Jenkins R, Butler C. Flash method of determining thermal diffusivity, heat capacity, and thermal conductivity. *Journal of applied physics*. 1961;32(9):1679-84.
- ASTM. *Standard Test Method for Thermal Conductivity of Solids by Means of the Guarded-Comparative-Longitudinal Heat Flow Technique*. Philadelphia, USA; 2017. ASTM E1225-13.

16. Rodrigo, J.A., Machine Learning con R y caret, Ciencia datos; 2018. [Citado: 25 de febrero de 2022]. Disponible en: https://rpubs.com/Joaquin_AR/383283
17. Shi L, Zhang S, Arshad A. Thermo-physical properties prediction of carbon-based magnetic nanofluids based on an artificial neural network. Renewable and Sustainable Energy Reviews. 2021;149:111341. DOI 10.1016/j.rser.2021.111341.
18. Montgomery DC, Peck EA, Vining GG. Introduction to linear regression analysis. USA: John Wiley & Sons; 2021.
19. Camaraza-Medina Y, Hernandez-Guerrero A, Luviano-Ortiz JL. Experimental study on influence of the temperature and composition in the steels thermo physical properties for heat transfer applications. Journal of Thermal Analysis and Calorimetry. 2022;147:11805-11821. DOI 10.1007/s10973-022-11410-8.

Conflicto de intereses

Los autores declaran que no existen conflictos de intereses

Contribución de los autores

Gabriel Roque Villalonga. <https://orcid.org/0000-0002-8120-7200>

Participó en la escritura del manuscrito, en la obtención, validación, análisis e interpretación de datos, en la búsqueda de información, en el diseño de la investigación, en la recolección de los datos, análisis de los resultados y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.

Yanan Camaraza Medina. <https://orcid.org/0000-0003-2287-7519>

Participó en la revisión del manuscrito, en la obtención y validación de datos. Realizó contribuciones en el análisis e interpretación de los datos, en la búsqueda de información, en el diseño de la investigación y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.

Osvaldo F. García Morales. <https://orcid.org/0000-0001-5895-8033>

Participó en la revisión del manuscrito, en la obtención, validación e interpretación de los datos, y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.

Yoalby Retirado Mediaceja. <https://orcid.org/0000-0002-5098-5675>

Participó en la obtención y validación de datos, diseño de la investigación y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.

Ángel M. Rubio González. <https://orcid.org/0000-0002-0890-5475>

Participó en la obtención, validación, análisis e interpretación de los datos, em la búsqueda de información y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.