

# PINNs para la Determinación del Coeficiente de Difusividad Térmica del Cobre en Geometrías Simples

Arnold S. Aguirre<sup>†</sup> & Renzo A. Loayza<sup>†</sup>

<sup>†</sup>Sección Física, Pontificia Universidad Católica del Perú

## Objetivos

Estimar el coeficiente de difusividad térmica del cobre,  $\alpha$ , a partir de datos experimentales de temperatura en el tiempo, formulando el problema como un **problema inverso** gobernado por la ecuación de difusión de Fourier.

Implementar **Physics-Informed Neural Networks (PINNs)** para inferir simultáneamente  $T(\mathbf{x}, t)$  y el parámetro oculto  $\alpha$ , incorporando restricciones físicas en la función de pérdida.

Evaluar el desempeño en dos geometrías simples: (i) varilla delgada (1D) y (ii) lámina rectangular (2D), y comparar con un valor de referencia reportado para  $T < 100^\circ\text{C}$ .

## Resumen y Motivación

La estimación precisa del coeficiente de difusividad térmica en metales es esencial para modelar procesos de transferencia de calor y calibrar modelos térmicos de ingeniería. Este trabajo aborda la identificación de  $\alpha$  en cobre a partir de mediciones discretas de temperatura en el tiempo usando **PINNs**, un marco de aprendizaje automático que integra datos y ecuaciones diferenciales en un único esquema de entrenamiento [1, 2]. Se analizan dos configuraciones experimentales con sensores DS18B20 y un sistema de adquisición basado en ESP32: una varilla (1D) y una lámina (2D). La PINN se entrena con los datos experimentales para reconstruir  $T(\mathbf{x}, t)$  y estimar  $\alpha$  como variable entrenable. Se obtienen valores promedio  $\langle\alpha\rangle = 1.08\text{ cm}^2/\text{s}$  (varilla) y  $\langle\alpha\rangle = 1.065\text{ cm}^2/\text{s}$  (lámina), con errores relativos  $\approx 6.1\%$  y  $7.0\%$  frente al valor de referencia  $\alpha_{\text{ref}} = 1.15\text{ cm}^2/\text{s}$ .




Figure 1: Arreglo experimental y adquisición de datos (ESP32 + sensores DS18B20).

## Desarrollo Experimental

**Geometrías y medición.** Se registró la temperatura  $T(t)$  en tres puntos igualmente espaciados:

Varilla: longitud  $0.07\text{ m}$ .

Lámina:  $0.07\text{ m} \times 0.029\text{ m}$ .

Posiciones:  $0.015\text{ m}$ ,  $0.035\text{ m}$ ,  $0.055\text{ m}$ .

**Montaje.** El sistema consta de un ESP32 conectado a protoboard controlando tres sensores DS18B20. La lámina se recubrió con baquelita para favorecer el aislamiento térmico. La muestra se pone en contacto con una placa térmica calentada hasta  $\sim 78^\circ\text{C}$ , usando pasta térmica en sensores y zona de contacto para mejorar la conducción.

**Interpretación física.** En el régimen de conducción dominante (sin convección apreciable), se modela la evolución térmica mediante difusión. En este marco,  $\alpha$  sintetiza la respuesta térmica efectiva del sistema bajo la configuración experimental considerada.

## Arquitectura y Entrenamiento

**Arquitectura.** Se emplearon redes densas con activación **tanh**.

Varilla (1D): 4 bloques, 128 neuronas de salida por bloque, 1500 épocas.

Lámina (2D): 10 bloques, 137 neuronas de salida por bloque, 3500 épocas.

**Promedio temporal de  $\alpha$ .** Para reportar un valor representativo:

$$\langle\alpha\rangle = \frac{1}{|\Omega| t_f} \int_0^{t_f} \int_{\Omega} \alpha(\mathbf{x}, t) d\mathbf{x} dt, \quad (5)$$

y se presenta el promedio temporal sobre el dominio espacial (tal como en las curvas mostradas en el póster base).

**Comentario metodológico.** En PINNs, la consistencia física se impone vía (1)–(3). Este mecanismo mitiga la sensibilidad típica de problemas inversos y favorece soluciones físicamente admisibles [1, 2].




Figure 2: Esquema conceptual de la PINN para (a) predicción de  $\hat{T}$  y (b) estimación de  $\alpha$  como variable oculta.

## Formulación

Se adopta la ecuación de difusión térmica (Fourier):

$$\frac{\partial T}{\partial t} = \alpha \Delta T, \quad (\mathbf{x}, t) \in \Omega \times (0, t_f). \quad (1)$$

con condición inicial y de frontera:

$$\begin{aligned} T(\mathbf{x}, 0) &= T_0(\mathbf{x}), \quad \mathbf{x} \in \Omega, \\ T(\mathbf{x}, t) &= \bar{T}(\mathbf{x}, t), \quad \mathbf{x} \in \partial\Omega. \end{aligned} \quad (2)$$

**PINN.** Se aproxima  $T(\mathbf{x}, t) \approx \hat{T}_\theta(\mathbf{x}, t)$  con una red neuronal de parámetros  $\theta$ ; en el problema inverso se introduce además  $\alpha$  como parámetro entrenable  $\alpha \in \mathbb{R}_+$ , optimizado conjuntamente.

**Residuo físico.** Definimos:

$$\mathcal{R}_\theta(\mathbf{x}, t) = \frac{\partial \hat{T}_\theta}{\partial t} - \alpha \Delta \hat{T}_\theta. \quad (3)$$

**Pérdida (forward).** Para  $\alpha$  fijo:

$$\begin{aligned} \mathcal{L}(\theta) &= \lambda_d \text{MSE}_d(\hat{T}_\theta, T^{\text{data}}) \\ &\quad + \lambda_f \text{MSE}_f(\mathcal{R}_\theta) \\ &\quad + \lambda_b \text{MSE}_b(\text{IC/BC}). \end{aligned} \quad (4)$$

**Pérdida (inverse).** Para estimar  $\alpha$ :  $\min_{\theta, \alpha} \mathcal{L}(\theta, \alpha)$ , con  $\mathcal{R}_\theta$  dado por (3). Este enfoque integra datos y física como regularización estructural del problema inverso [1, 2].

## Resultados

Se reporta la evolución del promedio temporal de  $\alpha$  sobre el dominio espacial, evidenciando convergencia hacia un valor estable en ambas geometrías.




Figure 3: Promedio temporal de  $\alpha$  (varilla 1D).




Figure 4: Promedio temporal de  $\alpha$  (lámina 2D).

Los valores obtenidos presentan discrepancias moderadas ( $\sim 6\text{--}7\%$ ), plausibles dada la incertidumbre instrumental, condiciones de contacto térmico y aproximaciones del modelo (p.ej., idealización de condiciones de frontera).

## Conclusiones

Se formuló la determinación de  $\alpha$  como un **problema inverso** gobernado por la ecuación de difusión (1), y se resolvió mediante PINNs optimizando conjuntamente  $(\theta, \alpha)$ .

En dos configuraciones experimentales con cobre (1D y 2D), la PINN identificó  $\langle\alpha\rangle$  con errores relativos de  $6.1\%$  y  $7.0\%$  respecto del valor de referencia para  $T < 100^\circ\text{C}$ .

La incorporación explícita de la física en la pérdida (1) mejora la consistencia del ajuste e impone soluciones físicamente admisibles, alineándose con la literatura de alto impacto sobre PINNs y aprendizaje informado por física [1, 2].

**Trabajo futuro.** Extender el enfoque a (i) geometrías 3D, (ii) condiciones de frontera más realistas (mixtas) y (iii) cuantificación explícita de incertidumbre en  $\alpha$  a partir de ruido experimental.

## Referencias

- [1] M. Raissi, P. Perdikaris, and G. E. Karniadakis, “Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations,” *Journal of Computational Physics* **378**, 686–707 (2019).
- [2] G. E. Karniadakis *et al.*, “Physics-informed machine learning,” *Nature Reviews Physics* **3**, 422–440 (2021).
- [3] G. Daurelio, M. Dell’Erba, and L. Cento, “Cutting copper sheets by CO<sub>2</sub> laser (Long thought uncuttable on a practical basis, copper has surrendered to the CO<sub>2</sub> laser),” *Lasers & Applications* **5**, 59–64 (1986).