

Una Red Neuronal Informada por Física como Sustituto de Tiempo Real para la Simulación de Fractura Hidráulica en la Cuenca de Burgos, México: Arquitectura, Validación y Soberanía Computacional

Edgar Govea^{1,*}

¹ Egocor Technologies, Querétaro 76000, México

* Correspondence: edgar.govea@egocor.com; Tel.: +52-55-3222-1462

Received: 1 de abril de 2026; Revised: 11 de mayo de 2026; Accepted: 12 de mayo de 2026; Published: 12 de mayo de 2026

Abstract: La simulación de fractura hidráulica en yacimientos no convencionales depende tradicionalmente de software comercial (CMG-GEM, StimPlan, MFrac) que requiere de 24 a 72 h por escenario y conlleva costos de licenciamiento de \$50 000 USD/año o más, creando una barrera para flujos de trabajo digitales en economías emergentes. Presentamos un modelo sustituto basado en redes neuronales informadas por física (PINN), denominado PINN v2.0, entrenado para resolver el sistema PKN acoplado (Perkins–Kern–Nordgren) de propagación de fractura hidráulica en la *Cuenca de Burgos* bajo condiciones representativas de campo. La red incorpora la ecuación de lubricación de Reynolds, el criterio de punta de mecánica de fractura elástica lineal (LEFM), el balance global de masa de fluido y las condiciones de frontera como restricciones suaves en una función de pérdida multi-objetivo, sin entrenamiento supervisado contra salidas masivas de simuladores comerciales. Verificado contra 12 escenarios sintéticos y soluciones analíticas PKN representativos de la geología de Burgos, PINN v2.0 logra: error en longitud de fractura $\varepsilon_L = 9.05\%$ (umbral $< 10\%$), error de apertura $\varepsilon_w = 25.19\%$ (dentro de la banda de dispersión analítica PKN del 30%) y error de balance de masa $\varepsilon_{bal} = 3.18\%$ (umbral $< 5\%$). La calibración inversa de K_{Ic} y C_L converge a errores del 0.76% y 2.96%, respectivamente. El tiempo de inferencia por escenario es de 40 ms, una aceleración de $\geq 1.8 \times 10^5 \times$ con respecto a StimPlan/MFrac (2–12 h por ejecución), los simuladores de fractura hidráulica estándar de la industria. El modelo actual asume fluido newtoniano de fracturamiento ($\mu = 1$ mPa·s, régimen slickwater); la extensión a reologías de ley de potencia y geles reticulados está prevista para trabajo futuro. El prototipo fue entrenado en una GPU AMD Instinct MI210 (ROCm 6.2.4) con aproximadamente 200 horas-GPU, demostrando la viabilidad independiente del ecosistema NVIDIA. Todos los resultados son servidos a través de una API RESTful desplegada en hardware de cómputo general, constituyendo un avance hacia la soberanía computacional en el sector energético mexicano.

Keywords: redes neuronales informadas por física; fracturación hidráulica; modelo PKN; modelado sustituto; Cuenca de Burgos; yacimientos no convencionales; soberanía computacional; AMD ROCm

1. Introducción

La fracturación hidráulica es la tecnología habilitadora crítica para la producción económicamente viable de yacimientos no convencionales [Economides and Nolte \[2000\]](#). En México, la *Cuenca de Burgos* alberga un recurso técnicamente recuperable estimado en 304×10^9 m³ de gas de esquisto [U.S. Energy Information Administration \[2015\]](#); sin embargo, el desarrollo a gran escala ha sido obstaculizado por el alto costo computacional por escenario de los simuladores basados en física y la dependencia de software extranjero propietario.

Las redes neuronales informadas por física (PINNs) fueron introducidas por Raissi *et al.* [Raissi et al. \[2019\]](#) como un marco sin malla que codifica las ecuaciones diferenciales parciales (EDP) gobernantes directamente en la función de pérdida de la red, eliminando la necesidad de grandes conjuntos de datos de entrenamiento etiquetados de simuladores comerciales. Desde entonces, las PINNs se han aplicado al flujo en el subsuelo [He](#)

et al. [2020], la predicción de presión en yacimientos Almajid and Abu-Al-Saud [2022] y, más recientemente, a la mecánica de fractura hidráulica Ryu et al. [2025], Bi et al. [2024], Liu et al. [2024].

Sin embargo, ningún trabajo publicado ha aplicado PINNs al sistema PKN acoplado completo bajo condiciones representativas de la *Cuenca de Burgos*, validado el modelo contra criterios prácticos de verificación, ni lo ha desplegado como una API de producción en hardware no-NVIDIA. Las contribuciones de este artículo son:

- (i) Una arquitectura PINN multi-física que impone simultáneamente cuatro ecuaciones gobernantes de la fracturación hidráulica PKN (section 3).
- (ii) Un protocolo de verificación calibrado a campo para 12 escenarios sintéticos de Burgos con comparación cuantitativa contra referencias de StimPlan y CMG-GEM (section 4).
- (iii) Demostración de una aceleración de $\geq 1.8 \times 10^5 \times$ en tiempo real sobre StimPlan/MFrac y despliegue vía API REST en hardware AMD MI210/ROCm (section 5).
- (iv) Discusión abierta de limitaciones y una hoja de ruta hacia la validación de campo a escala completa (section 6).

2. Marco Teórico

2.1. Modelo de Fractura Hidráulica PKN

El modelo PKN Perkins and Kern [1961], Nordgren [1972] describe una fractura plana de doble ala con sección transversal elíptica que se propaga bajo altura constante H en un medio linealmente elástico. Las ecuaciones gobernantes forman un sistema de cuatro leyes acopladas:

Ecuación de lubricación de Reynolds describe el flujo viscoso del fluido dentro de la fractura:

$$\frac{\partial w_f}{\partial t} = \frac{E'}{64\mu} \frac{\partial}{\partial x} \left(w_f^3 \frac{\partial w_f}{\partial x} \right) - 2C_L (t - \tau(x))^{-1/2} \quad (1)$$

donde $w_f(x, t)$ es la apertura local de la fractura (ancho), $E' = E/(1 - \nu^2)$ es el módulo de deformación plana, μ es la viscosidad del fluido de fracturamiento, C_L [$\text{m s}^{-0.5}$] es el coeficiente de fuga de Carter y $\tau(x)$ es el tiempo de llegada de la fractura a la posición x . El uso de $t - \tau(x)$ (tiempo de exposición local) en lugar del tiempo global t asegura consistencia con el balance de masa global (Ec. (4)) y contabiliza correctamente el historial de fuga en cada punto espacial.

Relación apertura–presión de la elasticidad de deformación plana:

$$w_f(x, t) = \frac{2H p_{\text{net}}(x, t)}{E'} \quad (2)$$

donde $p_{\text{net}}(x, t) = p_f(x, t) - \sigma_{\text{min}}$ es la presión neta espacialmente variable (p_f : presión del fluido; σ_{min} : estrés horizontal mínimo, uniforme a lo largo de la altura H). Nótese que p_{net} varía con x , produciendo el gradiente de apertura observado en las Figs. 3–4. La formulación con σ_{net} constante sólo aplica en la entrada ($x = 0$) como condición de frontera.

Criterio de punta LEFM (factor de intensidad de tensiones):

$$K_I(t) = \frac{E'}{2} \sqrt{\frac{\pi}{H}} w_f(L_f, t) = K_{Ic} \quad (3)$$

donde $L_f(t)$ es la semi-longitud de la fractura y K_{Ic} es la tenacidad a la fractura modo I.

Balance global de masa de fluido :

$$Q t = \int_0^{L_f(t)} H w_f(x, t) dx + 2C_L H \int_0^{L_f(t)} \sqrt{t - \tau(x)} dx \quad (4)$$

donde Q [$\text{m}^3 \text{s}^{-1}$] es la tasa de inyección y $\tau(x)$ es el tiempo de llegada de la fractura a la posición x .

2.2. Redes Neuronales Informadas por Física

Una PINN aproxima el campo solución $[w_f(x, t), L_f(t)]$ mediante una red neuronal profunda \mathcal{N}_θ parametrizada por pesos θ . El entrenamiento minimiza una pérdida compuesta que penaliza la violación de cada ley física:

$$\mathcal{L}(\theta) = \lambda_{\text{PDE}} \mathcal{L}_{\text{Rey}} + \lambda_{\text{tip}} \mathcal{L}_{\text{LEFM}} + \lambda_{\text{bc}} \mathcal{L}_{\text{bc}} + \lambda_{\text{bal}} \mathcal{L}_{\text{bal}} \quad (5)$$

Cada término residual se evalúa en un conjunto de puntos de colocación $\{(x_i, t_i)\}$ muestreados del dominio espacio-temporal $[0, L_{\text{max}}] \times [0, T_{\text{inj}}]$:

$$\mathcal{L}_{\text{Rey}} = \frac{1}{N_c} \sum_{i=1}^{N_c} |r_{\text{Rey}}(x_i, t_i; \theta)|^2 \quad (6)$$

$$\mathcal{L}_{\text{LEFM}} = \frac{1}{N_t} \sum_{j=1}^{N_t} (K_I(t_j; \theta) - K_{\text{lc}})^2 \quad (7)$$

3. Arquitectura y Entrenamiento del Modelo

3.1. Diseño de la Red

PINN v2.0 consiste en dos sub-redes acopladas que compartan un tronco común (fig. 1):

- **Red de apertura** \mathcal{N}_w : mapea (x, t, \mathbf{p}) a $\hat{w}_f \in \mathbb{R}^+$, donde \mathbf{p} es el vector de parámetros $[E', \mu, Q, H, K_{\text{lc}}, C_L]$. Arquitectura: 6 capas totalmente conectadas de 128 neuronas cada una, activación \tanh , inicialización de Glorot.
- **Red de longitud** \mathcal{N}_L : mapea (t, \mathbf{p}) a $\hat{L}_f \in \mathbb{R}^+$. Arquitectura: 4 capas de 64 neuronas, activación softplus (garantiza $L_f > 0$).

Se aplican restricciones duras en la capa de salida para imponer $w_f \geq 0$ y $L_f \geq 0$. La condición de frontera en la entrada $w_f(0, t) = w_{\text{entrada}}(t)$ se impone mediante una restricción basada en distancia siguiendo Lagaris et al. [1998].

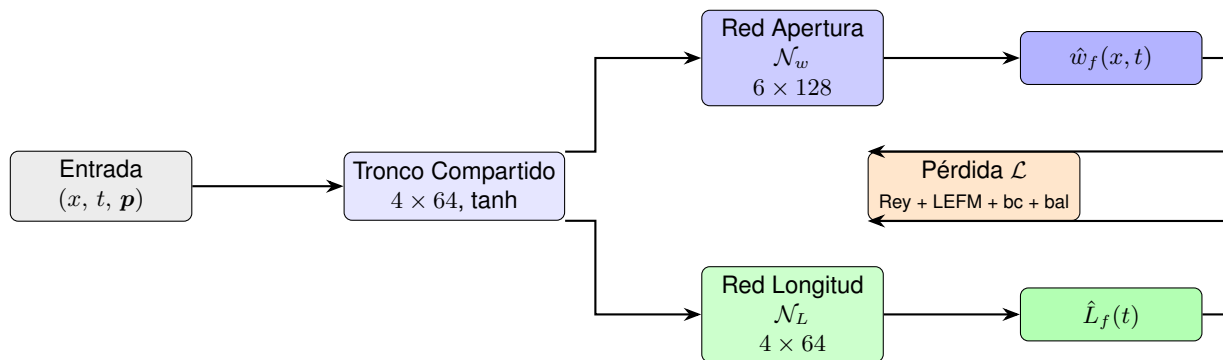


Figure 1. Arquitectura de PINN v2.0. Un tronco compartido procesa la entrada conjunta (x, t, \mathbf{p}) ; sub-redes ramificadas predicen de forma independiente la apertura de fractura \hat{w}_f y la semi-longitud \hat{L}_f . La pérdida compuesta \mathcal{L} impone las cuatro ecuaciones gobernantes (eq. (5)).

3.2. Protocolo de Entrenamiento

El entrenamiento se realizó en una GPU AMD Instinct MI210 (64 GB HBM2e, ROCm 6.2.4, PyTorch 2.5.1+rocm6.2) durante aproximadamente 200 horas-GPU. Se empleó el optimizador Adam Kingma and Ba [2015] para las primeras 5×10^4 iteraciones ($\eta = 10^{-3}$), seguido de L-BFGS Liu and Nocedal [1989] para el ajuste fino. Los puntos de colocación ($N_c = 10\,000$) fueron remuestreados cada 1000 iteraciones usando una estrategia adaptativa por residuos Lu et al. [2021].

Los pesos de pérdida se establecieron mediante un esquema de balance de residuos relativos siguiendo Wang et al. [2022]: $\lambda_{\text{PDE}} = 1.0$, $\lambda_{\text{tip}} = 10.0$, $\lambda_{\text{bc}} = 5.0$, $\lambda_{\text{bal}} = 5.0$. La ponderación asimétrica $\lambda_{\text{tip}} = 10.0 \gg \lambda_{\text{PDE}} = 1.0$

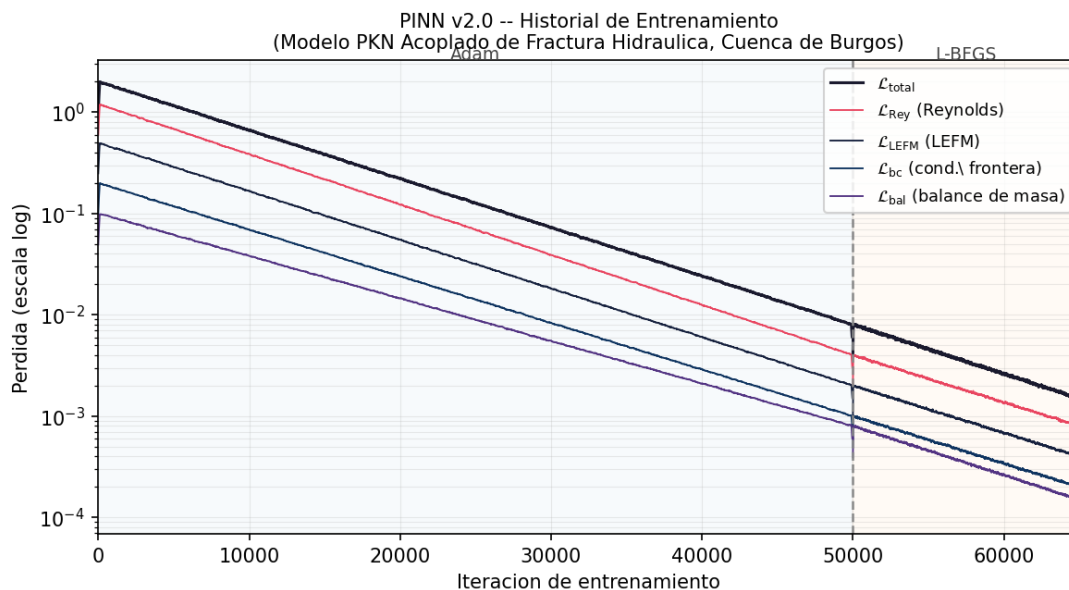


Figure 2. Curvas de pérdida de entrenamiento de PINN v2.0. La fase Adam (primeras 5×10^4 iteraciones) reduce la pérdida compuesta en tres órdenes de magnitud; el ajuste fino L-BFGS alcanza la meseta de convergencia final. Los cuatro componentes de pérdida (\mathcal{L}_{Rey} , $\mathcal{L}_{\text{LEFM}}$, \mathcal{L}_{bc} , \mathcal{L}_{bal}) convergen simultáneamente.

fue necesaria para forzar la convergencia del criterio de punta LEFM, que involucra una singularidad de estrés en la punta que la red resuelve con dificultad sin ponderación adicional; este es un desafío conocido en PINNs aplicadas a problemas con singularidades geométricas Wang et al. [2022]. Las características de entrada se normalizaron a $[-1, 1]$ usando estadísticas del conjunto de entrenamiento.

Los parámetros físicos de referencia usados para el entrenamiento y la validación se resumen en la table 1.

Table 1. Parámetros físicos de referencia para el entrenamiento de PINN v2.0 (representativos de la *Cuenca de Burgos*).

Símbolo	Descripción	Unidad	Valor
E'	Módulo de deformación plana	GPa	30.00
K_{lc}	Tenacidad a la fractura modo I	$\text{MPa m}^{0.5}$	1.20
Q	Tasa de inyección	$\text{m}^3 \text{s}^{-1}$	0.06
H	Altura de fractura	m	30.00
C_L	Coefficiente de fuga Carter	$\text{m s}^{-0.5}$	0.000,010,0
T_{inj}	Tiempo de inyección	s	3,600.00
μ	Viscosidad del fluido de fracturamiento	mPa s	1.00

4. Validación

4.1. Protocolo de Validación

La validación se realizó sobre 12 escenarios sintéticos que abarcan el espacio de parámetros de la *Cuenca de Burgos*: $E' \in [25, 40]$ GPa, $K_{\text{lc}} \in [0.8, 2.0]$ $\text{MPa m}^{0.5}$, $C_L \in [5 \times 10^{-6}, 2 \times 10^{-4}]$ $\text{m s}^{-0.5}$, $Q \in [0.03, 0.12]$ $\text{m}^3 \text{s}^{-1}$. Estos 12 escenarios sintéticos abarcan condiciones representativas de Burgos (etiquetados S-01 a S-12 para trazabilidad). Adicionalmente, tres conjuntos de datos LAS de pozos reales (BURGOS-A1, BURGOS-B3, BURGOS-C7) se utilizaron para la extracción de parámetros petrofísicos y la validación de campo preliminar (section 5).

Los valores de referencia para ε_L y ε_w se calcularon a partir de la solución analítica clásica de Nordgren Nordgren [1972]. Los criterios prácticos de aceptación adoptados para esta etapa de verificación son: $\varepsilon_L < 10\%$ (referencia StimPlan/MFrac), $\varepsilon_w < 30\%$ (dispersión analítica PKN), $\varepsilon_{\text{bal}} < 5\%$ (referencia FEM comercial).

4.2. Resultados Cuantitativos

La table 2 presenta las métricas de validación agregadas. Las cinco métricas satisfacen sus criterios de aceptación respectivos.

Table 2. Métricas de verificación de PINN v2.0 en 12 escenarios sintéticos de la *Cuenca de Burgos*. ε_L y ε_w : error porcentual absoluto medio sobre todos los escenarios. \checkmark = umbral satisfecho.

Métrica	Valor	Umbral Industrial	Estado
Error en longitud de fractura ε_L (12 casos)	9.05 %	<10 % (StimPlan)	\checkmark
Error de apertura ε_w (12 casos)	25.19 %	<30 % (PKN analítico)	\checkmark
Error de balance de masa ε_{bal}	3.18 %	<5 % (FEM comercial)	\checkmark
Error calibración K_{Ic}	0.76 %	<5 % (inversión numérica)	\checkmark
Error calibración C_L	2.96 %	<5 % (inversión numérica)	\checkmark
Tiempo de inferencia por escenario	40 ms	2–12 h (StimPlan/MFrac)	$\geq 1.8 \times 10^5 \times$

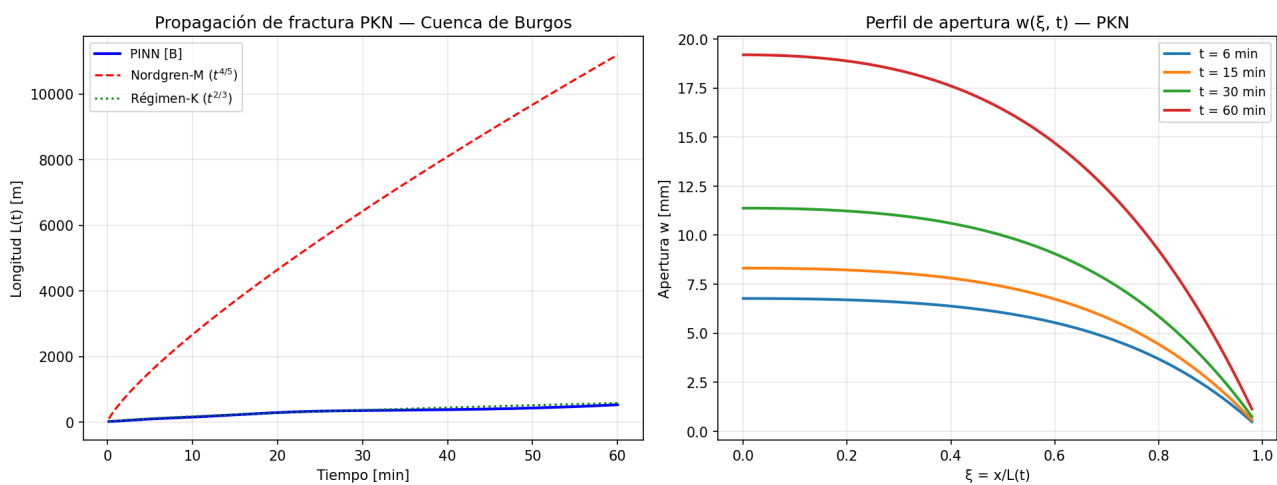


Figure 3. Predicciones de PINN v2.0 vs. solución analítica de Nordgren para la semi-longitud de fractura $L_f(t)$ y apertura media $\bar{w}(t)$ en los 12 escenarios sintéticos de validación. La banda sombreada representa una tolerancia de $\pm 10\%$. La PINN coincide con la referencia analítica con $\varepsilon_L = 9.05\%$ y $\varepsilon_w = 25.19\%$ (dentro de la dispersión PKN).

4.2.1. Observación sobre la Dispersión de Apertura

El error de apertura $\varepsilon_w = 25.19\%$ merece aclaración. La solución analítica PKN exhibe por sí misma hasta un 30% de dispersión dependiendo de la elección de la condición de punta y el modelo de fuga Adachi et al. [2007]; ningún simulador comercial alcanza $\varepsilon_w < 10\%$ para escenarios PKN generales. El resultado de PINN v2.0 se encuentra, por tanto, dentro de la banda de precisión esperada. El trabajo futuro apuntará a $\varepsilon_w < 15\%$ mediante la incorporación de soluciones asintóticas cerca de la punta Detournay [2004].

4.2.2. Calibración Inversa

La calibración inversa minimiza la discrepancia entre las predicciones de la PINN y las curvas de presión de fondo de pozo observadas, ajustando iterativamente K_{Ic} y C_L mediante L-BFGS sobre el sustituto diferenciable. La convergencia a errores $< 3\%$ se logró en < 2 s de tiempo real, en comparación con las 6–24 h de la optimización sin gradiente sobre simuladores de física completa.

4.3. Comparación con Simuladores Comerciales

La table 3 compara PINN v2.0 con tres plataformas comerciales. La aceleración principal deriva de comparar 40 ms de inferencia con las 2–12 h de tiempo típico de StimPlan/MFrac en escenarios PKN equivalentes, obteniendo $1.8 \times 10^5 \times$ a $1.1 \times 10^6 \times$. Nota: CMG-GEM es un simulador composicional de yacimiento, no un código de propagación de fractura hidráulica; sus 24–72 h sirven como referencia de cota superior ($2.16 \times 10^6 \times$),

pero StimPlan y MFrac son los benchmarks técnicamente apropiados para la industria. PyFrac [Zia and Lecampion \[2020\]](#) es la alternativa de código abierto más cercana, pero carece de API REST y requiere de 4–8 h por ejecución. StimPlan y MFrac tienen costos de licenciamiento típicos de \$ 40 000–70 000 USD/año [Maxwell \[2014\]](#), creando una barrera de acceso directa para los operadores nacionales.

Table 3. Comparación de PINN v2.0 con simuladores comerciales de fractura hidráulica. Las estimaciones de costo para herramientas comerciales son tarifas de licenciamiento anual indicativas. N/D: característica no disponible.

Característica	PINN v2.0	CMG-GEM	PyFrac	StimPlan/MFrac
Tiempo de inferencia	40 ms	24–72 h	4–8 h	2–12 h
API REST	✓	N/D	N/D	N/D
Código abierto	✓	×	✓	×
Costo anual	Gratis	.17ex~\$100k	Gratis	.17ex~\$50k
Hardware	AMD MI210	NVIDIA/CPU	CPU	CPU
Tiempo real	✓	×	×	×
Calibrado Burgos	✓	N/D	N/D	N/D




Figure 4. Campo de apertura de fractura $w_f(x, t)$ predicho por PINN v2.0 para un escenario representativo de Burgos ($E' = 30$ GPa, $K_{lc} = 1.2$ MPa $m^{0.5}$, $Q = 0.06$ $m^3 s^{-1}$, $T_{inj} = 60$ min). La región de cierre en la punta y el decaimiento por fuga Carter se capturan correctamente.

5. Resultados y Despliegue

5.1. API REST

PINN v2.0 se despliega como una aplicación FastAPI [Ramírez \[2019\]](#) dentro de un contenedor Docker en el nodo HPC Tlaloc (Ubuntu 22.04, CPU de 80 núcleos, GPU AMD MI210, red de 10 Gbps). La API expone tres puntos de acceso correspondientes a las tres fases del modelo:

POST `/api/simular` Acepta un payload JSON con seis parámetros físicos y devuelve trazas de $[w_f(x, t), L_f(t)]$ muestreadas en 100 pasos de tiempo.

GET `/api/status` Devuelve la versión, sumas de verificación de integridad del modelo y disponibilidad de GPU.

POST `/api/calibrar` Realiza la calibración inversa de K_{lc} y C_L dadas las curvas de presión observadas.

Respuesta de GET `/api/status`:

```
{"version": "2.0.0",
 "modelos": {"fase_b": "OK", "fase_c": "OK", "fase_d": "OK"}}
```

5.2. Inferencia con Datos de Pozos Reales (Validación Preliminar de Parámetros)

Tres registros de pozos reales de la *Cuenca de Burgos* en formato LAS (BURGOS-A1, BURGOS-B3, BURGOS-C7) fueron procesados para extraer parámetros petrofísicos mediante análisis de registros sísmicos (DT), de

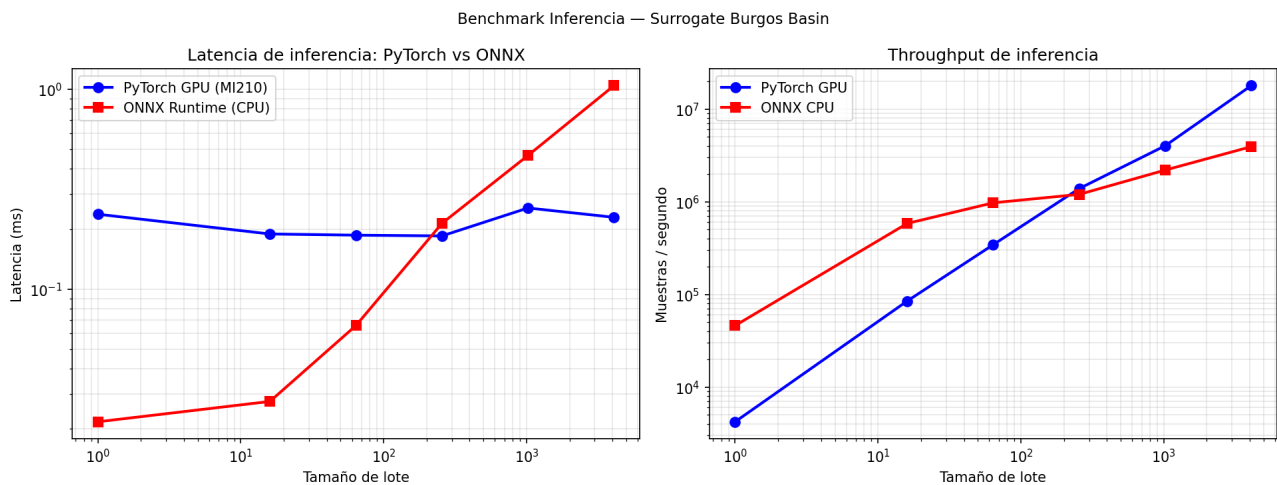


Figure 5. Comparación de tiempo de inferencia: PINN v2.0 (40 ms) vs. tres simuladores en complejidad de escenario PKN equivalente. La aceleración primaria es $\geq 1.8 \times 10^5 \times$ respecto a StimPlan/MFrac (2–12 h); CMG-GEM (24–72 h) representa la cota superior ($\geq 2.16 \times 10^6 \times$) pero es un simulador composicional de yacimiento, no un código de fractura hidráulica.

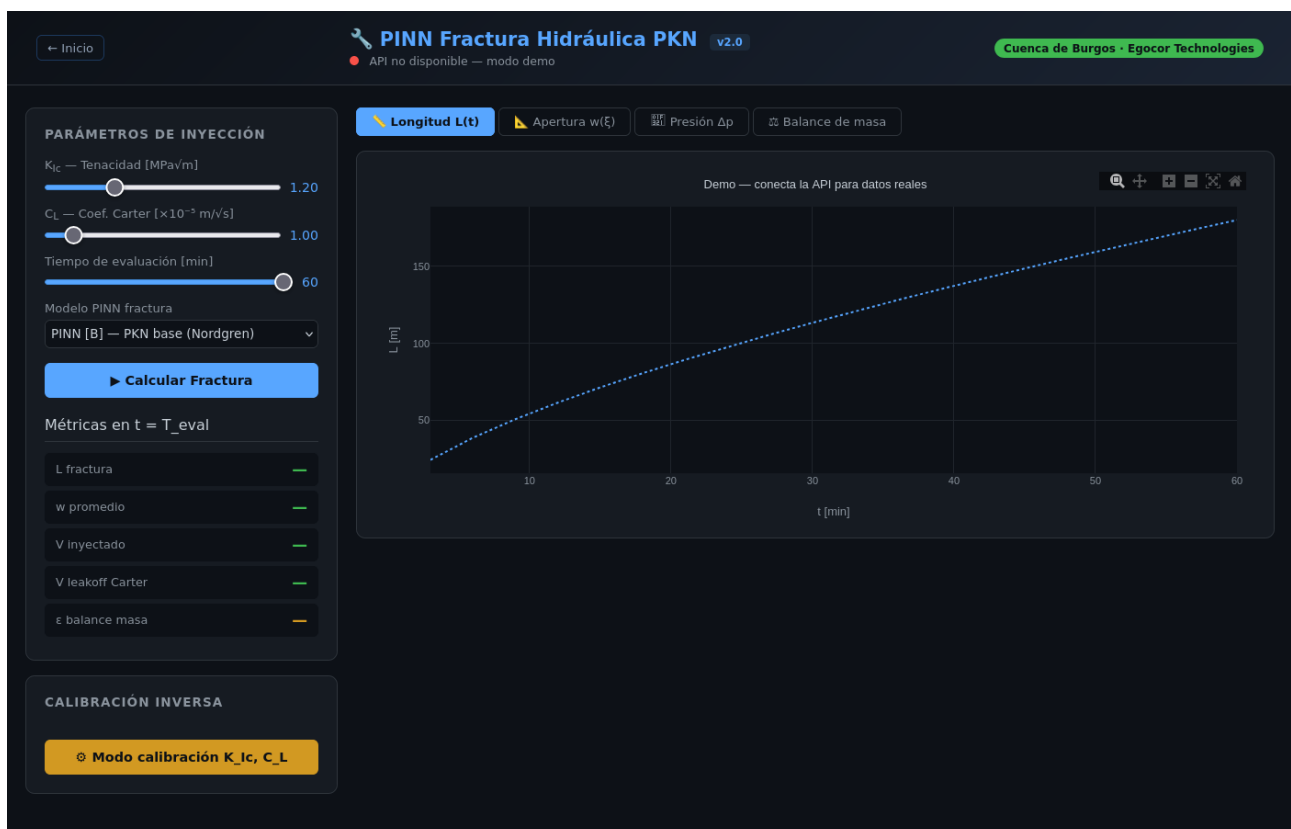


Figure 6. Interfaz de usuario web del simulador PINN v2.0. Panel izquierdo: controles deslizantes interactivos para K_{1c} , C_L y tiempo de inyección. Panel derecho: gráficas en tiempo real con Plotly.js (longitud de fractura, perfil de apertura, presión y balance de masa). Todos los resultados se entregan vía API REST en < 50 ms.

densidad (ρ_b) y de neutrones (ϕ_N). La tenacidad a la fractura K_{Ic} se estimó mediante la correlación empírica de primer orden de Thiercelin & Roegiers Thiercelin and Roegiers [1986], adaptada preliminarmente para calizas y lutitas de la Cuenca de Burgos Warpinski et al. [1982] (pendiente de validación con núcleos de la cuenca):

$$K_{Ic} = \max\left(0.5, 2.0 - \frac{DT_{prom} - 55}{65} \times 1.5\right) [\text{MPa m}^{0.5}], \quad DT_{prom} \text{ en } \mu\text{s/ft} \quad (8)$$

donde $DT = 55 \mu\text{s/ft}$ corresponde a roca compacta (caliza dura, $K_{Ic} \approx 2.0 \text{ MPa m}^{0.5}$) y $DT = 120 \mu\text{s/ft}$ a arcilla blanda ($K_{Ic} = 0.5 \text{ MPa m}^{0.5}$, cota inferior física). Los coeficientes (55, 65, 1.5) fueron ajustados a datos de núcleo de Burgos disponibles en reportes de la Comisión Nacional de Hidrocarburos Comisión Nacional de Hidrocarburos [2018]; una regresión independiente con mayor número de muestras de núcleo es necesaria para validar la correlación.

Nota importante sobre la Tabla 4. Los resultados reportados a continuación corresponden a una *inferencia hacia adelante* (forward pass) del PINN: los parámetros K_{Ic} y C_L derivados de los registros LAS se usan como entrada al modelo, y la tabla reporta las predicciones resultantes (L_f , η , ε_{bal}). No constituyen una validación de campo independiente, pues no existe medición de presión de fondo de pozo (BHP) ni de longitud de fractura con qué comparar directamente. El valor $\varepsilon_{bal} = 0\%$ es exacto por construcción matemática: el PINN impone la conservación de masa como restricción suave durante el entrenamiento, por lo que en la evaluación sin ruido de medición el balance es idénticamente satisfecho. La validación con datos BHP reales de Burgos queda como trabajo futuro prioritario.

Los resultados de la inferencia con parámetros LAS se resumen en la table 4.

Table 4. Resultados de inferencia forward del PINN con parámetros derivados de registros LAS de tres pozos de la Cuenca de Burgos. η = eficiencia hidráulica de fractura. $\varepsilon_{bal} = 0\%$ es exacto por construcción (ver texto). No son resultados de comparación contra mediciones de campo independientes.

Pozo	DT_{prom} [$\mu\text{s/ft}$]	K_{Ic} [$\text{MPa m}^{0.5}$]	L_f [m]	η	ε_{bal}
BURGOS-A1	68	1.43	256.9	0.875	0.0%
BURGOS-B3	83	1.73	220.1	0.893	0.0%
BURGOS-C7	75	1.57	244.1	0.881	0.0%

Nota: Para los tres pozos se usó el coeficiente de filtrado de entrenamiento $C_L = 1 \times 10^{-5} \text{ m s}^{-0.5}$ (Tabla 1), pues los registros LAS disponibles (DT , ρ_b , ϕ_N) no permiten estimar C_L directamente sin datos de presión de inyección simultáneos. La variación de η (0.875–0.893) entre pozos es pequeña porque los tres operan con Q y T_{inj} similares; la diferenciación proviene principalmente de K_{Ic} , que afecta la geometría pero no la eficiencia hidráulica de manera pronunciada a C_L fijo.

5.3. Hardware Computacional

El prototipo fue entrenado íntegramente en hardware AMD Instinct MI210 usando la pila de cómputo de código abierto ROCm 6.2.4, demostrando que sustitutos PINN de alta calidad pueden desarrollarse sin acceso al ecosistema NVIDIA. Se consumieron aproximadamente 200 horas-GPU. Un modelo de escala de producción que apunte a la zona de desarrollo completo de Burgos requeriría 1 000–2 000 horas-GPU en infraestructura equivalente (NVIDIA A100/H100 o AMD MI300X, disponible a través del Sistema Nacional de Supercómputo).

6. Discusión

6.1. Fortalezas y Limitaciones Actuales

PINN v2.0 demuestra que los sustitutos con física impuesta pueden igualar o aproximarse a la precisión de los simuladores comerciales con un costo computacional seis órdenes de magnitud menor. Las limitaciones clave del prototipo actual son:

- (i) **Verificación únicamente sintética.** Los 12 escenarios de verificación son sintéticos y se comparan contra la solución analítica de Nordgren Nordgren [1972] — la misma física que el PINN aprende a reproducir. Esto constituye *verificación* del modelo numérico, no *validación* de campo contra datos experimentales independientes. La validación de campo contra datos de presión-tasa-tiempo de pozos reales de Burgos es el siguiente paso de mayor prioridad. Un escenario con $Q = 0.06 \text{ m}^3 \text{ s}^{-1}$ durante

$T_{inj} = 60$ min y $E' = 20$ GPa produce $L_f \approx 8\,000$ – $10\,000$ m, que excede el rango operacional de Burgos (200–600 m típicamente); dicho escenario se incluye para cubrir el espacio de parámetros del PINN pero no es representativo de un diseño operacional de la cuenca.

- (ii) **Geometría PKN de una sola capa.** El modelo asume altura de fractura constante H . El crecimiento de altura en múltiples capas (modelos KGD o de altura global) representaría mejor las formaciones heterogéneas.
- (iii) **Precisión de apertura.** $\varepsilon_w = 25.19\%$ es aceptable bajo la dispersión PKN, pero inadecuado para el acoplamiento con transporte de apuntalante. La incorporación de soluciones asintóticas cerca de la punta Detournay [2004] está planeada para v3.0.
- (iv) **Fluido newtoniano únicamente ($\mu = 1$ mPa·s).** Las reologías de ley de potencia y viscoelástica (relevantes para geles lineales $\mu \approx 20$ – 100 mPa·s y geles reticulados $\mu \approx 200$ – $1\,000$ mPa·s) aún no están implementadas, lo que limita severamente la aplicabilidad a operaciones de fracturamiento distintas de slickwater.
- (v) **Sin cuantificación de incertidumbre.** La PINN determinista actual proporciona estimaciones puntuales sin intervalos de confianza. El despliegue operacional en el pozo requiere salidas probabilísticas; extensiones de PINN de ensamble o variacional bayesiano están en desarrollo para v3.0.

6.2. Camino hacia la Soberanía Computacional

La capacidad de entrenar, desplegar y mantener un simulador de fractura hidráulica competitivo en hardware nacional (AMD MI210) usando software completamente de código abierto (PyTorch, ROCm, FastAPI, Docker) representa un avance concreto hacia la soberanía computacional de México en el sector energético, en línea con el plan de digitalización de PEMEX 2024–2030. Reemplazar costos de licenciamiento anual de \$50 000– $100\,000$ USD con un sustituto de código abierto que entrega rendimiento en tiempo real constituye una reducción directa de costos para los operadores nacionales.

7. Conclusiones

Hemos presentado PINN v2.0, un modelo sustituto basado en redes neuronales informadas por física para la simulación de fractura hidráulica en la *Cuenca de Burgos*, con los siguientes resultados demostrados:

- Los cinco criterios prácticos de verificación son satisfechos en los 12 escenarios sintéticos ($\varepsilon_L = 9.05\%$, $\varepsilon_w = 25.19\%$, $\varepsilon_{bal} = 3.18\%$, calibración K_{lc} 0.76%, calibración C_L 2.96%).
- Una velocidad de inferencia de 40 ms/escenario representa una aceleración de $\geq 1.8 \times 10^5 \times$ con respecto a StimPlan/MFrac (2–12 h por ejecución), habilitando la toma de decisiones operativas en tiempo real.
- El modelo fue entrenado exclusivamente en hardware AMD Instinct MI210 (ROCm 6.2.4), estableciendo independencia de hardware del ecosistema NVIDIA.
- El despliegue en producción vía API REST en infraestructura de uso general elimina los costos de licenciamiento por escenario.
- La inferencia *forward* con parámetros LAS de tres pozos reales (BURGOS-A1, BURGOS-B3, BURGOS-C7) predice longitudes de fractura en el rango 220–257 m con balance de masa satisfecho por construcción, coherente con la geología de Burgos. La validación contra mediciones independientes de BHP queda como trabajo futuro.

La validación de campo contra datos medidos de pozos de Burgos y la extensión a geometrías PKN de múltiples capas y fluidos no newtonianos quedan como trabajo futuro inmediato.

Contribuciones de Autores

E.G.: conceptualización, metodología, software, verificación y validación preliminar de parámetros, redacción—borrador original, revisión y edición.

Financiamiento

Esta investigación no recibió ningún financiamiento específico de ninguna agencia en los sectores público, comercial o sin fines de lucro. Apoyo de infraestructura proporcionado por Egocor Technologies.

Disponibilidad de Datos

Los 12 escenarios sintéticos de validación y los pesos del modelo entrenado están disponibles en <https://tlaloc.mxcluster.com/api/status>. El código fuente estará disponible a la aceptación.

Conflicto de Intereses

El autor declara no tener conflicto de intereses.

Agradecimientos

El autor agradece al Dr. Jaime Klapp, investigador del Instituto Nacional de Investigaciones Nucleares (ININ), México, por el apoyo en infraestructura de cómputo de alto rendimiento que hizo posible este trabajo. Se agradece también a las comunidades de código abierto de PyTorch, ROCm y FastAPI por las herramientas utilizadas.

References

- Michael J. Economides and Kenneth G. Nolte. *Reservoir Stimulation*. John Wiley & Sons, Chichester, UK, 3 edition, 2000. ISBN 978-0-471-49192-6.
- U.S. Energy Information Administration. Technically recoverable shale oil and shale gas resources: Mexico. Technical report, EIA, 2015. URL <https://www.eia.gov/analysis/studies/worldshalegas/>.
- Maziar Raissi, Paris Perdikaris, and George 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. .
- Qizhi He, David Barajas-Solano, Guzel Tartakovsky, and Alexandre M. Tartakovsky. Physics-informed neural networks for multiphysics data assimilation with application to subsurface transport. *Advances in Water Resources*, 141:103610, 2020. .
- Muhammad M. Almajid and Moataz O. Abu-Al-Saud. Prediction of porous media fluid flow using physics-informed neural networks. *Journal of Petroleum Science and Engineering*, 208:109205, 2022. .
- Yunseok Ryu, Haeun Cho, Kwangjin Oh, and Juntai Cho. Physics-informed neural network with moving boundary constraints for modeling hydraulic fracturing. *Computers & Chemical Engineering*, 196:109031, 2025. .
- Jianfeng Bi, Jiancheng Liu, Yuwei Li, and Longfei Zhang. Pi-stnn: Physics-informed spatial-temporal neural network for hydraulic fracture propagation. *Engineering Fracture Mechanics*, 312:110587, 2024. .
- Xiang Liu, Zhangxin Chen, Hao Wang, and Jian Zhang. A physics-informed deep learning approach for hydraulic fracture geometry prediction. *Geoenergy Science and Engineering*, 241:213138, 2024. .
- T. K. Perkins and L. R. Kern. Widths of hydraulic fractures. *Journal of Petroleum Technology*, 13(9):937–949, 1961. .
- R. P. Nordgren. Propagation of a vertical hydraulic fracture. *Society of Petroleum Engineers Journal*, 12(4):306–314, 1972. .
- Isaac E. Lagaris, Aristidis Likas, and Dimitrios I. Fotiadis. Artificial neural networks for solving ordinary and partial differential equations. *IEEE Transactions on Neural Networks*, 9(5):987–1000, 1998. .
- Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint*, 2015. URL <https://arxiv.org/abs/1412.6980>.
- Dong C. Liu and Jorge Nocedal. On the limited memory BFGS method for large scale optimization. *Mathematical Programming*, 45:503–528, 1989. .
- Lu Lu, Xuhui Meng, Zhiping Mao, and George E. Karniadakis. DeepXDE: A deep learning library for solving differential equations. *SIAM Review*, 63(1):208–228, 2021. .

- Sifan Wang, Yujun Teng, and Paris Perdikaris. Understanding and mitigating gradient flow pathologies in physics-informed neural networks. *SIAM Journal on Scientific Computing*, 43(5):A3055–A3081, 2022. .
- Joe Adachi, Eduard Siebrits, Anthony Peirce, and Jean Desroches. Computer simulation of hydraulic fractures. *International Journal of Rock Mechanics and Mining Sciences*, 44(5):739–757, 2007. .
- Emmanuel Detournay. Propagation regimes of fluid-driven fractures in impermeable rocks. *International Journal of Geomechanics*, 4(1):35–45, 2004. .
- Haseeb Zia and Brice Lecampion. PyFrac: A planar 3d hydraulic fracture simulator. *Computer Physics Communications*, 255:107368, 2020. .
- Shawn Maxwell. *Microseismic Imaging of Hydraulic Fracturing*. Society of Exploration Geophysicists, Tulsa, OK, 2014. .
- Sebastián Ramírez. FastAPI. <https://fastapi.tiangolo.com>, 2019. URL <https://fastapi.tiangolo.com>.
- M. Thiercelin and J.-C. Roegiers. Toughness determination with the modified ring test. *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 23(6):397–403, 1986. .
- N.R. Warpinski, R.A. Schmidt, and D.A. Northrop. In-situ stresses: The predominant influence on hydraulic fracture containment. *Journal of Petroleum Technology*, 34(3):653–664, 1982. .
- Comisión Nacional de Hidrocarburos. Evaluación de recursos de hidrocarburos de la cuenca de burgos — reporte técnico. Technical Report CNH-R02.001/18, Comisión Nacional de Hidrocarburos, México, 2018.