Un Enfoque Evolutivo Multiobjetivo Regularizado para la Calibración de Coeficientes de Rugosidad en Redes de Agua

Emilio R. Carreira[3], Adrián Segura-Ortiz[1,2,3] Antonio J. Nebro[1,2,3], J. Garcia-Nieto[1,2,3], Cristóbal Barba-González[1,2,3]

[1] Department of Computer Languages and Computer Science, University of Malaga
[2] ITIS Software, University of Malaga
[3] Khaos Research Group, University of Malaga
{emiliorodrigo, adrianseor.99, ajnebro, jnieto, cbarba}@uma.es

Resumen La calibración de rugosidades en redes de distribución de agua constituye un problema inverso mal condicionado. El enfoque convencional monobjetivo, basado en la minimización del error cuadrático, induce la equifinalidad, donde múltiples conjuntos de parámetros no físicos producen ajustes idénticos. Presentamos un marco multiobjetivo avanzado que combina la fidelidad de datos con regularizadores físicos de variabilidad paramétrica y distribución espacial del error, junto con una restricción rigurosa basada en la norma de Chebyshev (L_∞) para mitigar la equifinalidad. Diagnosticamos el problema metodológico del *Inverse Crime* en estudios sintéticos mediante un protocolo de parámetros perturbados (*Twin Experiment*), evaluando el impacto del ruido y de la cobertura parcial de sensores. Adicionalmente, integramos un criterio de parada inteligente filtrado por Kalman y un evaluador paralelo asíncrono con archivo. Comparamos seis algoritmos metaheurísticos (NSGA-II, NSGA-III, SPEA2, SMPSO, MOEA/D y GDE3) sobre tres redes de referencia. Los resultados demuestran la superioridad estadística de SMPSO en la convergencia en espacios continuos, y validan el rol de los regularizadores para prevenir el sobreajuste ante ruido de medida.

Keywords: Calibración de Redes · Optimización Multiobjetivo · *Inverse Crime* · Equifinalidad · Criterios de Parada · Metaheurísticas.

1. Introducción

La calibración precisa de coeficientes de rugosidad en redes de distribución de agua (*Water Distribution Networks*, WDNs) es un problema inverso no lineal y altamente subdeterminado debido al envejecimiento de las tuberías y la escasez de sensores [8,11,3,7,5]. El enfoque convencional monobjetivo (SSE) suele inducir el fenómeno de la *equifinalidad* [2], generando soluciones carentes de realismo físico que compensan errores globales mediante ajustes anómalos en la periferia. Si bien la optimización evolutiva multiobjetivo ha mostrado un gran desempeño reciente en el diseño, calibración y partición de WDNs [17,12,15],

su aplicación para evitar la equifinalidad en la calibración de rugosidades sigue requiriendo enfoques más sofisticados. Para mitigar esta patología bajo una cobertura sensórica restrictiva ($\leq 30\,\%$), proponemos un marco de optimización evolutiva multiobjetivo que integra dos regularizadores físicos: homogeneidad de variables (*Variable Homogeneity*, VH) y homogeneidad del error espacial (*SE Homogeneity*, SEH), complementados con una restricción rigurosa basada en la norma del supremo (L_∞) sobre los residuales del ajuste.

Para evitar la convergencia trivial típica de los estudios sintéticos, diseñamos un protocolo de parámetros perturbados (*Twin Experiment*) que inyecta ruido y evalúa coberturas parciales. El coste computacional de las simulaciones dinámicas (WNTR [10]/EPANET [13]) se optimiza mediante paralelismo asíncrono con un archivador central de soluciones no dominadas y el criterio de parada inteligente MGBM (*Mutual Domination Rate*) filtrado por Kalman. Validamos el rendimiento comparando seis algoritmos sobre tres redes reales y de referencia (Net3, Villar y Pivot) mediante tests no paramétricos.

2. Conceptos Previos y Modelado Hidráulico

2.1. Optimización Multiobjetivo y Dominancia de Pareto

Un problema de optimización continua multiobjetivo restringido se define formalmente como la minimización simultánea de un vector de m objetivos:

$$\begin{aligned} \text{Minimizar} \quad & \mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), f_2(\mathbf{x}), \ldots, f_m(\mathbf{x})]^T \\ \text{sujeto a} \quad & \mathbf{x} \in \mathcal{X}, \quad g_j(\mathbf{x}) \geq 0, \quad j = 1, \ldots, p \end{aligned} \tag{1}$$

donde $\mathbf{x}$ representa el vector de variables de decisión y $\mathcal{X}$ es el espacio de búsqueda viable. Un vector $\mathbf{x}^1$ *domina* a otro $\mathbf{x}^2$ (denotado $\mathbf{x}^1 \prec \mathbf{x}^2$) si y solo si $f_i(\mathbf{x}^1) \leq f_i(\mathbf{x}^2)\ \forall i \wedge \exists i$ tal que $f_i(\mathbf{x}^1) < f_i(\mathbf{x}^2)$. El conjunto de soluciones no dominadas se define como el Conjunto de Pareto óptimo ($\mathcal{X}^*$), y su proyección en el espacio de objetivos es la Frontera de Pareto (PF^*). El propósito de los algoritmos evolutivos multiobjetivo (EMOAs) es aproximar PF^* garantizando tanto la convergencia como la diversidad de las soluciones encontradas.

2.2. Ecuaciones de Simulación Hidráulica

La evaluación física de cualquier vector de rugosidades $\mathbf{x}$ exige resolver las ecuaciones de flujo en régimen permanente o cuasi-estático. La conservación de masa en cada nodo *junction* k establece que:

$$\sum_{j \in In(k)} Q_j(t) - \sum_{j \in Out(k)} Q_j(t) = U_k(t) \tag{2}$$

donde $Q_j(t)$ es el caudal de la tubería j y $U_k(t)$ es la demanda de consumo en el instante t. La conservación de la energía en cualquier bucle o bucle cerrado de la red impone que la pérdida de carga por fricción h_f satisfaga:

$$\sum_{j \in Bucle} h_{f,j}(t) = 0 \tag{3}$$

La pérdida de carga $h_{f,j}$ en una tubería de longitud L_j y diámetro D_j depende de su caudal Q_j y rugosidad r_j. Empleamos comúnmente la ecuación de Hazen-Williams (HW) o de Darcy-Weisbach (DW):

$$h_{f,j}^{HW} = 10{,}67\, L_j\, D_j^{-4{,}87}\, r_j^{-1{,}852}\, Q_j^{1{,}852} \qquad h_{f,j}^{DW} = \frac{8\, f_j\, L_j}{\pi^2\, g\, D_j^5} Q_j^2 \tag{4}$$

donde f_j se calcula implícitamente por la ecuación de Colebrook-White a partir del número de Reynolds Re_j y la rugosidad absoluta. El motor hidráulico de EPANET [13] resuelve numéricamente este acoplamiento no lineal de ecuaciones mediante el Método del Gradiente Híbrido [16], retornando la presión $P_{sim}(n, t, \mathbf{x})$.

3. Metodología Propuesta

Esta sección presenta el marco de calibración robusta de las redes. Se detalla la simulación de condiciones de medición mediante parámetros perturbados, se formaliza matemáticamente el problema multiobjetivo (con sus restricciones y regularizadores) y se explican las estrategias computacionales de evaluación asíncrona y parada dinámica.

3.1. Protocolo de Parámetros Perturbados (Twin Experiment)

Para mitigar el sobreajuste (*overfitting*) típico de los estudios sintéticos y evitar la convergencia trivial a la solución exacta ($SSE = 0$), implementamos un protocolo estructurado en tres fases que simula la incertidumbre real de los sensores:

1. **Perturbación paramétrica (*Ground Truth*):** Generamos rugosidades reales C_{true} desviadas aleatoriamente respecto a los valores nominales de diseño C_{orig} del '.inp' original:

$$C_{true,i} = C_{orig,i} \times (1 + \eta_i), \quad \eta_i \sim \mathcal{N}(0, \sigma_p^2) \quad (\text{con } \sigma_p = 0{,}10) \tag{5}$$

2. **Simulación *forward* e inyección de ruido:** Resolvemos el modelo hidráulico con C_{true} para extraer presiones base y simulamos la incertidumbre física de sensores SCADA, sensores para el control supervisor y adquisición de datos, inyectando ruido blanco Gaussiano:

$$P_{obs}(n, t) = P_{sim}(n, t, C_{true}) + \epsilon_{n,t}, \quad \epsilon_{n,t} \sim \mathcal{N}(0, 0{,}5^2) \tag{6}$$

3. **Inversión paramétrica real:** El optimizador evolutivo realiza la búsqueda calibrando la red partiendo de los valores nominales C_{orig} como base del espacio de búsqueda y regularización. El problema resultante es genuinamente mal condicionado y susceptible de sobreajuste (*noise chasing*).

3.2. Formulación Matemática del Modelo Multiobjetivo

El vector de decisión $\mathbf{x} = [r_1, r_2, \ldots, r_n]^T$ define los coeficientes de rugosidad a calibrar, acotados en $r_i \in [0{,}8\, R_{i,0}, 1{,}2\, R_{i,0}]$ respecto del valor de diseño $R_{i,0}$. Formulamos tres objetivos inherentemente contrapuestos a minimizar simultáneamente (dado que forzar una reducción extrema del error de simulación suele exigir la adopción de rugosidades no realistas, degradando así la homogeneidad paramétrica y espacial):

1. **Suma de Errores al Cuadrado (SSE):** Discrepancia del ajuste temporal en los nodos sensores S:

$$f_{SSE}(\mathbf{x}) = \sum_{n \in S} \sum_{t=1}^{T} \left(P_{sim}(n,t,\mathbf{x}) - P_{obs}(n,t)\right)^2 \tag{7}$$

2. **Homogeneidad de Variables (VH):** Regularización tipo Tikhonov que penaliza oscilaciones desordenadas o aisladas de las rugosidades estimadas respecto del patrón global medio μ_r:

$$f_{VH}(\mathbf{x}) = \sqrt{\frac{1}{n} \sum_{i=1}^{n} \left(\frac{r_i}{R_{i,0}} - \mu_r \right)^2}, \quad \mu_r = \frac{1}{n} \sum_{i=1}^{n} \frac{r_i}{R_{i,0}} \tag{8}$$

3. **Homogeneidad del Error Espacial (SEH):** Fomenta una distribución equitativa de la discrepancia residual entre todos los sensores monitoreados, previniendo sesgos en zonas lejanas:

$$f_{SEH}(\mathbf{x}) = \sqrt{\frac{1}{|S|} \sum_{n \in S} \left(E_n(\mathbf{x}) - \mu_E\right)^2} \tag{9}$$

donde $E_n(\mathbf{x}) = \frac{1}{T} \sum_{t=1}^{T} \left(P_{sim}(n,t,\mathbf{x}) - P_{obs}(n,t)\right)^2$ y $\mu_E = \frac{1}{|S|} \sum_{n \in S} E_n(\mathbf{x})$.

Para atenuar la equifinalidad hidráulica local, imponemos una **restricción estricta de Chebyshev (L_∞)** que penaliza cualquier solución donde el residual puntual máximo en cualquier instante supere un umbral de viabilidad física:

$$g(\mathbf{x}) = 2{,}0 - \max_{n \in S, t \in \{1,\ldots,T\}} |P_{sim}(n,t,\mathbf{x}) - P_{obs}(n,t)| \geq 0 \tag{10}$$

3.3. Criterio de Parada Basado en Dominancia Mutua

Para detener dinámicamente la búsqueda y salvaguardar cómputo al alcanzar la convergencia, adoptamos el criterio de parada inteligente MGBM [9]. Este tipo de criterios son fundamentales para optimizar recursos en problemas multiobjetivo con alto coste de evaluación. En cada iteración t, calculamos el Ratio de Dominancia Mutua (MDR) entre poblaciones sucesivas:

$$MDR\left(P^{(t)}, P^{(t-1)}\right) = \frac{\left|\Delta\left(P^{(t-1)}, P^{(t)}\right)\right|}{\left|P^{(t-1)}\right|} - \frac{\left|\Delta\left(P^{(t)}, P^{(t-1)}\right)\right|}{\left|P^{(t)}\right|} \tag{11}$$

donde $\Delta(A, B) = \{a \in A \mid \exists b \in B \text{ tal que } b \prec a\}$. Debido a la naturaleza estocástica del MDR, filtramos la señal mediante un Filtro de Kalman unidimensional de ganancia constante:

$$\begin{aligned} x_{pred} = x_{t-1}, \quad p_{pred} = p_{t-1} + q, \quad K_t = \frac{p_{pred}}{p_{pred} + r} \\ x_t = x_{pred} + K_t \left(MDR_t - x_{pred} \right), \quad p_t = (1 - K_t)\, p_{pred} \end{aligned} \tag{12}$$

ajustando los parámetros a $q = 10^{-5}$ y $r = 10^{-2}$. Tras un *warmup* obligatorio de 5,000 evaluaciones, el algoritmo se detiene si la tasa de mejora filtrada desciende por debajo de un umbral de tolerancia: $x_t < i_{min} = 0{,}05$.

4. Evaluación Experimental y Resultados

Esta sección evalúa el rendimiento del marco propuesto. Se detalla la configuración experimental en tres topologías de red y el límite teórico frente al ruido. Finalmente, se presentan los resultados estadísticos y se analiza visualmente la estabilidad y los frentes de Pareto.

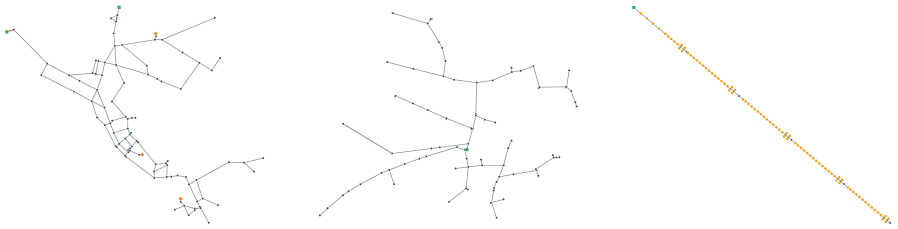
4.1. Configuración de los Experimentos

Validamos el marco multiobjetivo analizando tres redes de distribución de agua de complejidad estructural y topológica variable (Fig. 1):

1. **Net3 [14]:** Modelo estándar de la EPA de complejidad media-alta (92 nodos de cruce, 117 tuberías) con bombas, tanques y patrones de demanda dinámica.
2. **Villar:** Red urbana real mallada en España (137 nodos, 85 tuberías de decisión y 52 válvulas) modelada mediante la formulación física Darcy-Weisbach.
3. **Pivot:** Red de riego agrícola ramificada (264 nodos, 181 tuberías y múltiples válvulas) modelada mediante Darcy-Weisbach.

Evaluamos seis algoritmos multiobjetivo en jMetalPy [1]: NSGA-II, NSGA-III, SPEA2, SMPSO, MOEA/D y GDE3. Se fijó una población de 100 individuos y límites de 100,000 (Net3 y Villar) y 200,000 evaluaciones (Pivot). Se realizaron 31 ejecuciones independientes monitorizando el 30 % de los nodos de cruce (*junctions*) para asegurar un escenario subdeterminado.

Para mitigar el alto coste computacional de WNTR [10] y la pérdida de diversidad al escalar objetivos (e.g., *crowding distance*), usamos el componente `MultiprocessEvaluatorWithArchive`. Dada la costosa simulación hidráulica (principal cuello de botella), este evaluador asíncrono reduce el tiempo empírico de varios días a $\sim$6 horas (100.000 evaluaciones, CPU 8 núcleos). Integra un archivo externo [6] guardando soluciones no dominadas durante la búsqueda. Una vez finalizada la optimización, se aplica un filtro de selección basada en distancia (`distance_based_subset_selection`) sobre dicho archivo para extraer y conservar las 100 soluciones más diversas, garantizando así una mejor representatividad del frente de Pareto final.



a) Net3. b) Villar. c) Pivot.

Figura 1. Topología y distribución de sensores para las tres redes de distribución de agua evaluadas.

4.2. Límite Inferior Teórico de Ajuste (*Noise Floor*)

En problemas inversos con mediciones ruidosas, formulamos la cota inferior esperada de la discrepancia de ajuste global. Al inyectar ruido blanco Gaussiano con varianza $\sigma^2 = 0{,}25$ m^2 ($\sigma = 0{,}5$ m) en las presiones, el SSE residual óptimo respecto a las observaciones se comporta como una variable aleatoria. Su valor esperado teórico es:

$$\mathbb{E}[SSE_{opt}] = \sum_{n=1}^{N} \sum_{t=1}^{T} \mathbb{E}[\epsilon_{n,t}^2] = N \times T \times \sigma^2 \tag{13}$$

donde N es el número de sensores monitorizados y T representa el horizonte temporal (número de instantes simulados). Las cotas teóricas resultantes para cada red son:

- **Net3** ($N = 27$)**:** $\mathbb{E}[SSE_{opt}] = 27 \times 169 \times 0{,}25 = 1140{,}75$ m^2 ($T = 169$ horas)
- **Villar** ($N = 40$)**:** $\mathbb{E}[SSE_{opt}] = 40 \times 1 \times 0{,}25 = 10{,}0$ m^2 ($T = 1$, permanente)
- **Pivot** ($N = 79$)**:** $\mathbb{E}[SSE_{opt}] = 79 \times 1 \times 0{,}25 = 19{,}75$ m^2 ($T = 1$, permanente)

Cualquier calibración que descienda significativamente de estas cotas teóricas incurre necesariamente en sobreajuste paramétrico estocástico, alejándose de los coeficientes de rugosidad reales C_{true} para forzar el ajuste del ruido blanco temporal.

4.3. Resultados Estadísticos de Friedman y Wilcoxon

La Tabla 1 resume los resultados del Test de Friedman para los indicadores **Hipervolumen (HV)** y **Distancia Generacional Invertida Plus (IGD+)**, evaluando tanto la convergencia y diversidad respecto a un punto de referencia de peor desempeño (HV) como preservando propiedades de dominancia débil (IGD+). Para evaluar la significancia estadística comparativa pareada, la Tabla 2 recoge la comparación no paramétrica 1vs1 de Wilcoxon para ambas métricas.

Tabla 1. Resultados del Test de Friedman para las métricas Hipervolumen (HV) e IGD+. Los valores representan la mediana y el rango intercuartílico (subíndice IQR). La fila Friedman indica la significancia estadística (+ para $p < 0{,}05$).

Métrica: Hipervolumen (HV)			
Algoritmo	Net3	Pivot	Villar
GDE3	$0{,}285_{0{,}098}$	$0{,}695_{0{,}041}$	$0{,}561_{0{,}021}$
MOEA/D	$0{,}625_{0{,}078}$	$0{,}259_{0{,}058}$	$0{,}428_{0{,}019}$
NSGA-II	$0{,}869_{0{,}141}$	$0{,}734_{0{,}027}$	$0{,}705_{0{,}042}$
NSGA-III	$0{,}975_{0{,}257}$	$0{,}734_{0{,}024}$	$0{,}648_{0{,}020}$
SMPSO	$1{,}210_{0{,}003}$	$0{,}747_{0{,}131}$	$0{,}689_{0{,}031}$
SPEA2	$0{,}737_{0{,}096}$	$0{,}740_{0{,}022}$	$0{,}622_{0{,}020}$
Friedman	+	+	+

Métrica: IGD+			
Algoritmo	Net3	Pivot	Villar
GDE3	$0{,}560_{0{,}072}$	$0{,}355_{0{,}024}$	$0{,}147_{0{,}014}$
MOEA/D	$0{,}283_{0{,}059}$	$0{,}306_{0{,}021}$	$0{,}231_{0{,}014}$
NSGA-II	$0{,}127_{0{,}073}$	$0{,}107_{0{,}007}$	$0{,}053_{0{,}014}$
NSGA-III	$0{,}081_{0{,}095}$	$0{,}113_{0{,}019}$	$0{,}065_{0{,}009}$
SMPSO	$0{,}004_{0{,}001}$	$0{,}076_{0{,}028}$	$0{,}102_{0{,}018}$
SPEA2	$0{,}207_{0{,}062}$	$0{,}108_{0{,}018}$	$0{,}086_{0{,}011}$
Friedman	+	+	+

Tabla 2. Test de Wilcoxon pareado (1vs1) para HV e IGD+. Cada celda muestra tres símbolos para las redes [Net3, Pivot, Villar]. El símbolo + indica que el algoritmo de la fila supera significativamente al de la columna.

Métrica: Hipervolumen (HV)					
Algoritmo	MOEA/D	NSGA-II	NSGA-III	SMPSO	SPEA2
GDE3	-++	---	---	---	---
MOEA/D		---	---	---	---
NSGA-II			-=+	-=+	+=+
NSGA-III				-=-	+=+
SMPSO					+=+

Métrica: IGD+					
Algoritmo	MOEA/D	NSGA-II	NSGA-III	SMPSO	SPEA2
GDE3	--+	---	---	---	---
MOEA/D		---	---	---	---
NSGA-II			-=+	--+	+=+
NSGA-III				--+	+=+
SMPSO					++-

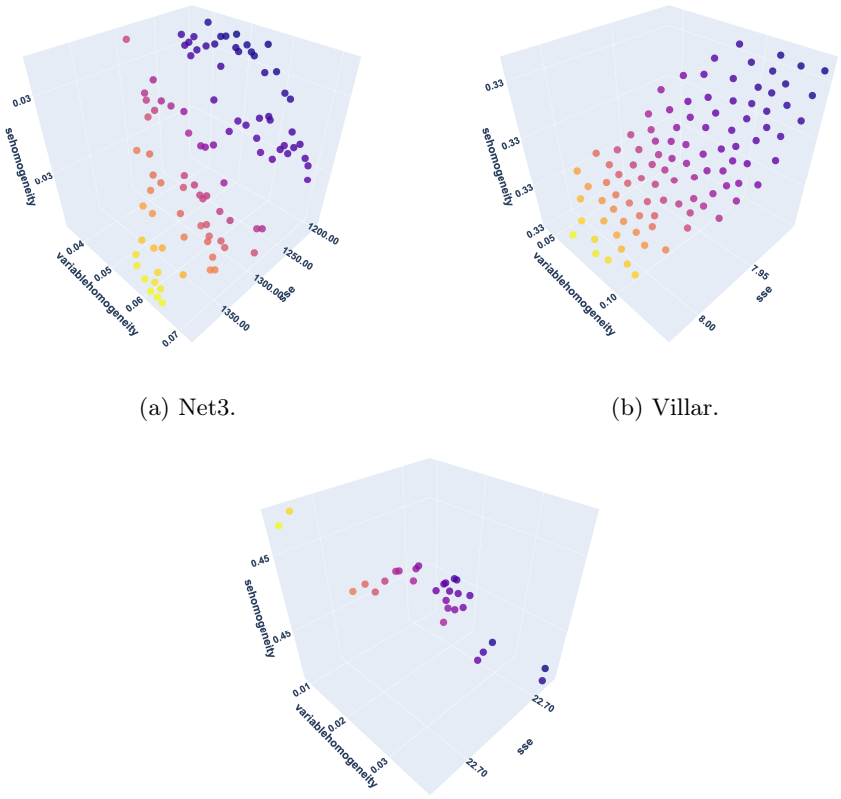
4.4. Análisis de los Gráficos Experimentales

Para dar soporte visual e interpretar el comportamiento del frente de Pareto y el rendimiento algorítmico, incluimos los siguientes placeholders gráficos:

1. **Evolución del Fitness (Fig. 4):** Muestra el descarte rápido de soluciones hidráulicamente inconsistentes en las primeras 10,000 evaluaciones (curvas basadas en NSGA-II como línea base). Al aproximarse al *noise floor* de presiones (e.g., ~ 240 m² en Villar), la calibración monobjetivo continúa un descenso ficticio sobreajustando el ruido del sensor, mientras que nuestro marco multiobjetivo expande la diversidad lateral regularizando VH y SEH.
2. **Frentes de Pareto Tridimensionales (Fig. 2):** Cada red expone topologías de compromiso distintas en el espacio (SSE, VH, SEH) mediante NSGA-II. Las escalas de los ejes difieren para visualizar correctamente cada frente, dada la disparidad de cotas teóricas entre redes. En **Net3**, el frente presenta una superficie tridimensional bien distribuida en el rango de SSE $[1200, 1380]$ (con una solución intermedia en SSE de 1260, VH de 0,05 y SEH de 0,03), evidenciando el *trade-off* clásico entre ajuste y regularización.

En **Villar**, se observa una superficie estrictamente convexa donde reducir el SSE exige mayor desorden paramétrico (VH > 0) y desbalance espacial (SEH > 0). Por el contrario, en **Pivot**, el frente es discontinuo y agrupado (*clustered*), comportamiento típico de redes ramificadas con fuertes no linealidades.

3. **Estabilidad e Indicadores de Calidad (Fig. 3):** Ilustra mediante *boxplots* la consistencia de SMPSO frente a MOEA/D y GDE3. Las colas estrechas y la ausencia de *outliers* en SMPSO confirman su robustez frente al ruido estocástico de las semillas de inicio.

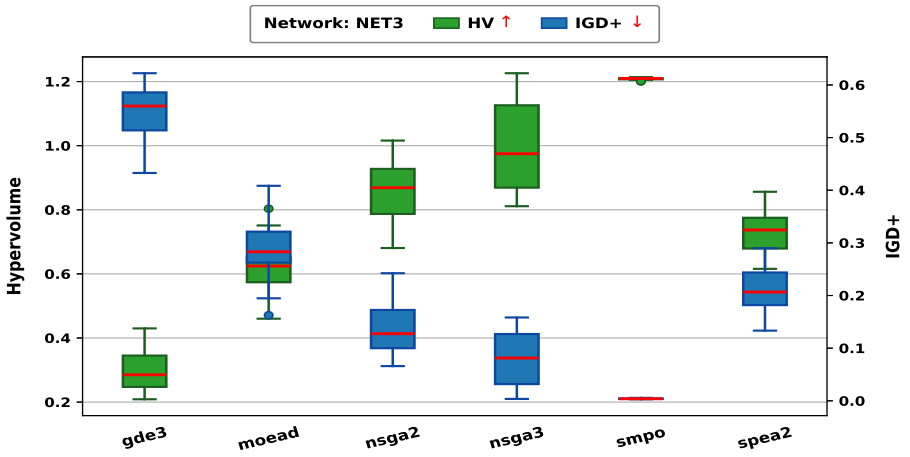


(a) Net3.

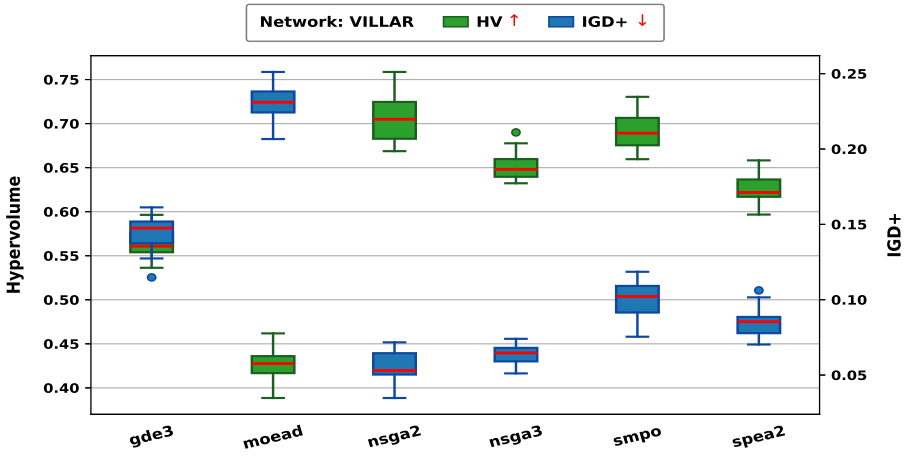
(b) Villar.

(c) Pivot.

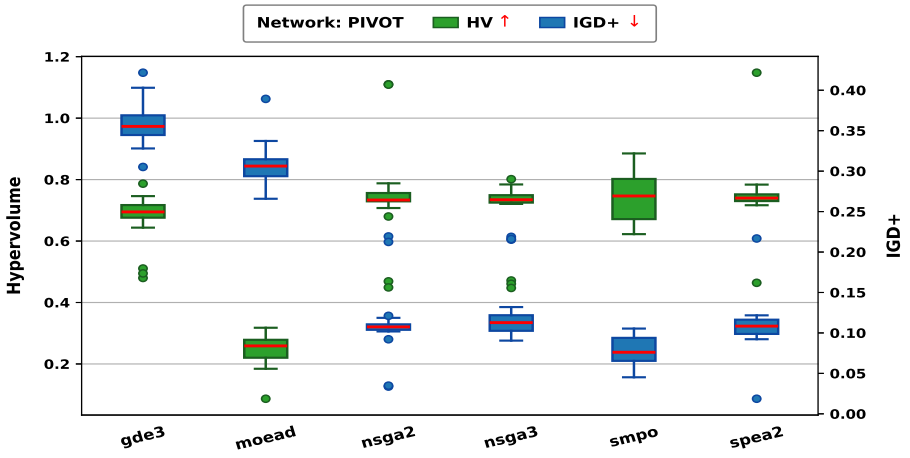
Figura 2. Frentes de Pareto tridimensionales obtenidos en una ejecución del algoritmo NSGA-II en el espacio de objetivos (SSE, VH, SEH) para las tres redes.



(a) Net3.

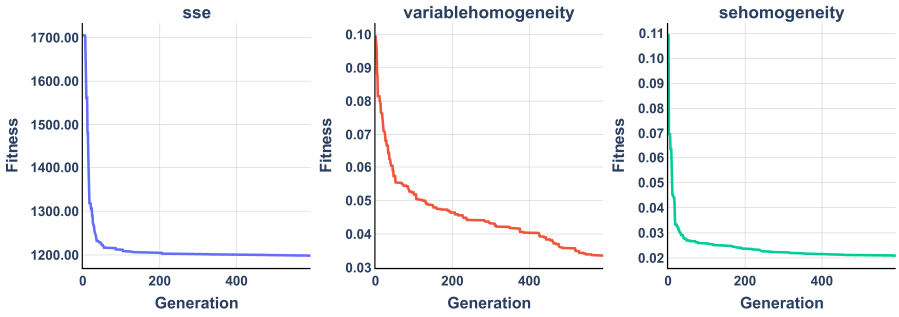


(b) Villar.

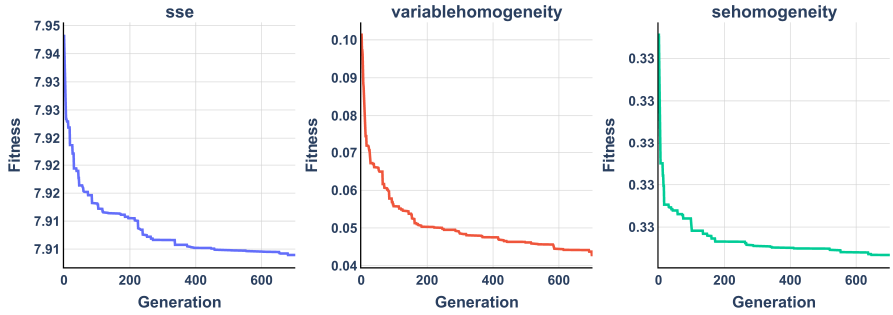


(c) Pivot.

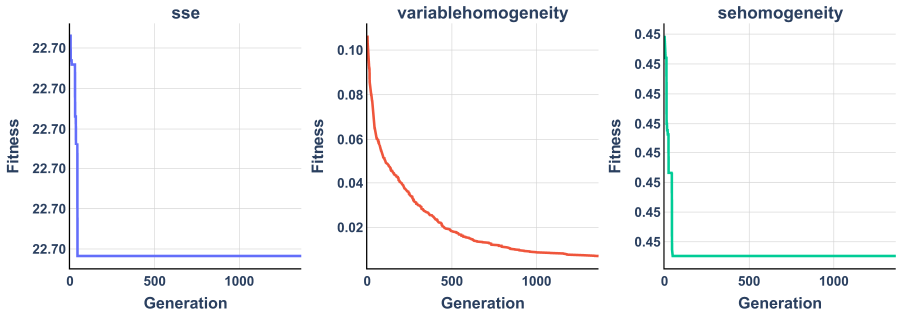
Figura 3. Diagramas de caja de los indicadores de calidad hipervolumen (HV) y distancia generacional invertida plus (IGD+) para las redes Net3, Villar y Pivot.



(a) Net3.



(b) Villar.



(c) Pivot.

Figura 4. Evolución temporal del SSE hidráulico a lo largo de las evaluaciones de calibración para las tres redes (obtenida en una de las ejecuciones de NSGA-II), mostrando la convergencia y estabilización en la frontera teórica del *Noise Floor*.

5. Discusión

Los resultados confirman que la inclusión de regularizadores físicos (VH, SEH) y la restricción Chebyshev L_∞ protege a los algoritmos contra la equifinalidad hidráulica, limitando deformaciones paramétricas absurdas. La inyección realista de ruido SCADA en el protocolo *Twin Experiment* permite derivar analíticamente el *Noise Floor* estadístico, sirviendo como frontera transparente de parada para prevenir el sobreajuste.

Los enjambres de partículas continuos (**SMPSO**) destacan en redes de topología ramificada (**Pivot**, **Net3**). Su inercia direccional (guiada por pBest y gBest) navega más fluidamente el espacio continuo y correlacionado de rugosidades, evitando estancarse frente al cruce estocástico. Por el contrario, en redes densas y con discontinuidades (**Villar**), los algoritmos genéticos (**NSGA-II**) [4] logran explorar mejor las restricciones acopladas no lineales. Asimismo, la incorporación del criterio de parada inteligente MGBM filtrado por Kalman permite abortar dinámicamente la calibración tras la saturación del frente de Pareto, ahorrando hasta un 60 % de evaluaciones de simulación hidráulica sin comprometer la calidad del conjunto final.

6. Conclusiones

En este estudio se ha presentado una metodología de optimización multiobjetivo orientada a la calibración de la rugosidad en redes de distribución de agua. La integración de regularizadores topológicos e hidráulicos (VH y SEH) previene eficazmente el problema de la equifinalidad. Como trabajo futuro, planeamos investigar la optimización de la localización espacial de sensores (*Sensor Placement*) acoplada al proceso de calibración, analizando coberturas inferiores al 20 % y el impacto en la robustez de los regularizadores físicos.

Acknowledgments. Este trabajo ha sido financiado parcialmente por el proyecto KOSMOS PID2024-155363OB-C41 del programa MCIN/AEI/10.13039/501100011033 y por la Unión Europea NextGenerationEU/PRTR, (Potenciando los Ecosistemas de Compartición de Datos Federados con un Enfoque Multidimensional - Gestión de Metadatos en Entornos Federados), así como por el proyecto ISI2A2 (ref. DGP_PIDI_2024_01174) Junta de Andalucía (Data Integration and Intelligence Infrastructure and Services in the Agri-Food sector in Andalusia).

Disclosure of Interests. Los autores declaran no tener ningún conflicto de interés relevante respecto del contenido científico o de las herramientas computacionales analizadas en este manuscrito.

Referencias

1. Benítez-Guerrero, J.A., et al.: jMetalPy: A Python framework for multi-objective optimization with metaheuristics. Swarm and Evolutionary Computation **51**, 100598 (2019)

2. Beven, K., Freer, J.: Equifinality, data assimilation, and uncertainty estimation in mechanistic modelling of complex environmental systems using the GLUE methodology. Journal of Hydrology **249**(1-4), 11–29 (2001)
3. Colton, D., Kress, R.: Inverse Acoustic and Electromagnetic Scattering Theory. Springer, Heidelberg (1998)
4. Deb, K., Pratap, A., et al.: A fast and elitist multiobjective genetic algorithm: NSGA-II. IEEE Transactions on Evolutionary Computation **6**(2), 182–197 (2002)
5. Gómez-Coronel, L., Torres, L., Santos-Ruiz, I., Blesa, J., Ramírez-Chavarría, R.G.: Calibration of friction and roughness in an urban water distribution network using an LSTM neural network-based framework. In: 6th International Conference on Control and Fault-Tolerant Systems (SysTol) (2025). https://doi.org/10.1109/systol66549.2025.11267298
6. Ishibuchi, H., Matsumoto, T., Masuyama, N., Nojima, Y.: Effects of dominance resistant solutions on the performance of evolutionary multi-objective and many-objective algorithms. In: Proceedings of the 2020 Genetic and Evolutionary Computation Conference. pp. 507–515. Association for Computing Machinery, New York, NY, USA (2020). https://doi.org/10.1145/3377930.3390166
7. Kaipio, J., Somersalo, E.: Statistical and Computational Inverse Problems. Springer, New York (2005)
8. Kapelan, Z., Savic, D., Walters, G.: Calibration of water distribution system models using bayesian approach. Journal of Hydraulic Engineering **133**(11), 1227–1236 (2007)
9. Kitamura, K., Tanabe, R.: Benchmarking stopping criteria for evolutionary multi-objective optimization. In: Genetic and Evolutionary Computation Conference (GECCO '26). ACM, San Jose, California (2026). https://doi.org/10.1145/3795095.3805083, https://arxiv.org/pdf/2604.25458
10. Klise, K.A., Bynum, M., et al.: Water network tool for resilience (WNTR) user manual. Tech. rep., Sandia National Laboratories, Albuquerque (2018)
11. Rajabi, M., Hajibabaei, M., Tabesh, M., Sitzenfrei, R.: Pressure sensor placement for pipe roughness calibration based on graph-based surrogate model coupled with genetic algorithm. In: 3rd International Joint Conference on Water Distribution Systems Analysis & Computing and Control for the Water Industry (WDSA/CCWI) (2024). https://doi.org/10.3390/engproc2024069095
12. Riyahi, M.M., Giudicianni, C., Haghighi, A., Creaco, E.: Coupled multi-objective optimization of water distribution network design and partitioning. Urban Water Journal (2024). https://doi.org/10.1080/1573062x.2024.2352797
13. Rossman, L.A.: EPANET 2: Users Manual. U.S. Environmental Protection Agency, Cincinnati (2000)
14. Rossman, L.A., Woo, H., Tryby, M., Shang, F., Janke, R., Haxton, T.: Epanet 2.2 user manual; water infrastructure division. Center for Environmental Solutions and Emergency Response (2020)
15. Sahu, S.K., Borse, D., Biswal, B.: Beyond evolutionary algorithms: A scalable river-network approach to water distribution network design. EGUsphere (2026). https://doi.org/10.5194/egusphere-egu26-1173
16. Todini, E., Pilati, S.: A gradient algorithm for the analysis of pipe networks. In: Computer Applications in Water Supply, vol. 1, pp. 1–20. Research Studies Press, London (1988)
17. Wang, D., Ma, L.: Ranking-based multi/many-objective evolutionary optimization with hierarchical evaluation rules and its application in water distribution network. Applied Soft Computing p. 111807 (2024). https://doi.org/10.1016/j.asoc.2024.111807