

Modelo híbrido de neuroevolución para optimizar arquitecturas DNN con AHP-TOPSIS

Hybrid neuroevolution model for DNN architecture optimization using AHP-TOPSIS

**Nahin Adrián Castro Pinza 1, Diego Adrián Vera Pinargote 2, Dayron Rumbaut Rangel 3, Maykel
Yelandi Leyva Vázquez 4,***

1 Universidad Bolivariana del Ecuador, Durán, Ecuador. E-mail: nascatrop@ube.edu.ec. ORCID: <https://orcid.org/0009-0005-6655-4908>.

2 Universidad Bolivariana del Ecuador, Durán, Ecuador. E-mail: daverap@ube.edu.ec. ORCID: <https://orcid.org/0009-0004-1029-3879>.

3 Universidad Bolivariana del Ecuador, Durán, Ecuador. E-mail: drumbaut@ube.edu.ec. ORCID: <https://orcid.org/0009-0001-9087-0979>.

4 Universidad Bolivariana del Ecuador, Durán, Ecuador. E-mail: myleyvav@ube.edu.ec. ORCID: <https://orcid.org/0000-0001-7911-5879>.

* Autor de correspondencia: myleyvav@ube.edu.ec

Resumen

Objetivo: diseñar y validar un modelo híbrido de neuro evolución para optimizar arquitecturas de redes neuronales profundas mediante la integración de AHP y TOPSIS. **Metodología:** se implementó un proceso neuro evolutivo con una población de 30 arquitecturas durante 20 generaciones, utilizando CIFAR-10 como conjunto de datos experimental. La precisión predictiva se empleó como métrica de desempeño durante la evolución, mientras que AHP permitió ponderar cuatro criterios de decisión y TOPSIS establecer el ranking multicriterio de las arquitecturas candidatas. **Resultados:** la precisión predictiva obtuvo el mayor peso mediante AHP (0,6066), seguida del tiempo de inferencia (0,2623). En el ranking final reportado, la arquitectura NE_Arch_B alcanzó el mayor coeficiente de cercanía relativa ($CCi = 0,8436$). En las diez ejecuciones independientes, NE_Arch_B obtuvo una precisión promedio de 86,32 %, frente a 84,18 % de la neuro evolución estándar y 82,25 % del modelo de referencia. **Conclusión:** los resultados obtenidos sugieren que la integración de neuro evolución con métodos de decisión multicriterio permite establecer un procedimiento sistemático para seleccionar arquitecturas considerando simultáneamente precisión, eficiencia computacional y complejidad.

Palabra Clave: inteligencia artificial; aprendizaje automático; redes neuronales; optimización; toma de decisiones

Abstract

Objective: to design and validate a hybrid neuroevolution model for optimizing deep neural network architectures through the integration of AHP and TOPSIS. **Methodology:** a neuroevolutionary process with a population of 30 architectures over 20 generations was implemented using CIFAR-10 as the experimental dataset. Predictive accuracy was used as the performance metric during evolution, while AHP was applied to weight four decision criteria and TOPSIS was used to establish the multicriteria ranking of candidate architectures. **Results:** predictive accuracy obtained the highest AHP weight (0.6066),

followed by inference time (0.2623). In the reported final ranking, NE_Arch_B achieved the highest relative closeness coefficient ($CC_i = 0.8436$). Across ten independent executions, NE_Arch_B achieved a mean accuracy of 86.32%, compared with 84.18% for standard neuroevolution and 82.25% for the reference model. **Conclusion:** the results suggest that integrating neuroevolution with multicriteria decision-making provides a systematic procedure for architecture selection while simultaneously considering accuracy, computational efficiency, and complexity.

Keywords: artificial intelligence; machine learning; neural networks; optimization; decision making

1. Introducción

1.1. Planteamiento del tema

El aprendizaje profundo se ha consolidado como una de las principales áreas de la inteligencia artificial debido a su capacidad para aprender representaciones jerárquicas a partir de grandes volúmenes de datos. Sin embargo, el desempeño de una red neuronal profunda no depende exclusivamente de los datos empleados o del procedimiento de entrenamiento, sino también de las características de la arquitectura seleccionada, la configuración de sus hiperparámetros y los recursos computacionales necesarios para su ejecución [1, 2]. En consecuencia, el diseño de una arquitectura adecuada constituye un aspecto relevante para alcanzar un equilibrio entre capacidad predictiva y eficiencia computacional.

La búsqueda automática de arquitecturas neuronales, conocida como *Neural Architecture Search* (NAS), surge como una alternativa a los procesos de diseño manual al permitir explorar de manera automatizada diferentes configuraciones de redes neuronales. Zoph y Le [3] demostraron la posibilidad de emplear aprendizaje por refuerzo para automatizar la generación y evaluación de arquitecturas, mientras que investigaciones posteriores han establecido diferentes estrategias de NAS en función del espacio de búsqueda, el método de exploración y los mecanismos utilizados para evaluar las soluciones candidatas [4, 5]. Estas estrategias han permitido ampliar las posibilidades de automatización del diseño arquitectónico, aunque la selección de las soluciones continúa dependiendo de la forma en que se define y evalúa el desempeño de las arquitecturas.

Dentro de este contexto, los algoritmos evolutivos constituyen una alternativa para la búsqueda de arquitecturas debido a su capacidad para explorar espacios de soluciones mediante procesos iterativos de selección, reproducción, mutación y conservación de individuos con características favorables. La aplicación de estos mecanismos al diseño de redes neuronales permite generar nuevas configuraciones arquitectónicas a partir de soluciones existentes y orientar progresivamente la búsqueda hacia alternativas de mayor desempeño [6, 7]. Sin embargo, la eficacia de este proceso depende de los criterios utilizados para evaluar y seleccionar las arquitecturas durante la evolución, especialmente cuando una solución puede presentar ventajas en una dimensión del desempeño y desventajas en otras.

Esta situación plantea una dificultad particular para la optimización de arquitecturas DNN, debido a que una solución con elevada precisión predictiva no necesariamente presenta las mejores características en términos de tiempo de inferencia, complejidad o flexibilidad estructural. Por tanto, la evaluación de las arquitecturas mediante una única métrica puede limitar la capacidad del proceso evolutivo para identificar alternativas que representen un equilibrio adecuado entre diferentes dimensiones del desempeño. En este sentido, resulta necesario complementar la capacidad exploratoria de los métodos evolutivos con mecanismos que permitan valorar las alternativas desde una perspectiva multicriterio.

Los métodos de decisión multicriterio ofrecen procedimientos para comparar alternativas cuando intervienen diferentes criterios con distintos niveles de importancia. Entre ellos, el método *Analytic Hierarchy Process* (AHP) permite establecer la importancia relativa de los criterios mediante comparaciones pareadas y evaluar la consistencia de los juicios utilizados [8]. Por su parte, *Technique for Order Preference by Similarity to Ideal Solution* (TOPSIS) permite ordenar las alternativas a partir de su proximidad a una solución ideal positiva y su distancia respecto de una solución ideal negativa [9]. La combinación de ambos métodos proporciona un mecanismo para incorporar las preferencias relativas entre criterios y utilizarlas posteriormente en la comparación de las alternativas arquitectónicas.

A partir de esta perspectiva, la integración de neuroevolución con AHP-TOPSIS permite plantear un procedimiento en el que la generación y exploración de arquitecturas se complementa con una evaluación multicriterio de las soluciones obtenidas. La neuroevolución puede orientar la búsqueda dentro del espacio arquitectónico, mientras que AHP-TOPSIS puede contribuir a establecer una valoración conjunta considerando diferentes características de las arquitecturas. Esta integración constituye la base del modelo híbrido propuesto para optimizar la selección de arquitecturas DNN, en el que la precisión predictiva se analiza conjuntamente con criterios relacionados con eficiencia computacional, complejidad y capacidad de exploración topológica.

1.2. Problema de investigación

A pesar de los avances alcanzados en la búsqueda automática de arquitecturas neuronales, persiste el desafío de establecer mecanismos de evaluación y selección que permitan considerar diferentes dimensiones del desempeño arquitectónico. En determinados enfoques de *Neural Architecture Search*, la precisión predictiva constituye uno de los principales criterios utilizados para valorar las soluciones candidatas. Si bien este indicador permite medir la capacidad de una arquitectura para resolver la tarea de aprendizaje, su consideración como criterio predominante puede favorecer soluciones que presentan un alto desempeño predictivo, pero que requieren mayores recursos computacionales, tiempos de inferencia más elevados o una mayor complejidad estructural [4, 10].

Esta situación adquiere especial relevancia cuando las arquitecturas deben ser utilizadas bajo restricciones de procesamiento, memoria o latencia. Una arquitectura con mayor precisión no necesariamente representa la alternativa más conveniente si el incremento de su desempeño implica un costo computacional considerable. De manera análoga, una arquitectura con menor complejidad y menor tiempo de inferencia puede presentar una reducción de su capacidad predictiva. Por consiguiente, la selección de una arquitectura DNN puede plantearse como un problema de compromiso entre diferentes criterios, en el que las ventajas obtenidas en una dimensión pueden estar acompañadas de desventajas en otra.

En este contexto, los métodos de decisión multicriterio proporcionan mecanismos para integrar criterios heterogéneos dentro de un proceso estructurado de evaluación y selección. El método *Analytic Hierarchy Process* (AHP) permite determinar la importancia relativa de los criterios mediante comparaciones pareadas y verificar la consistencia de los juicios empleados [8]. Por su parte, *Technique for Order Preference by Similarity to Ideal Solution* (TOPSIS) permite establecer un orden de preferencia entre alternativas considerando su proximidad a una solución ideal positiva y su distancia respecto de una

solución ideal negativa [9]. La utilización conjunta de estos métodos permite incorporar las prioridades relativas de los criterios y obtener una valoración global de las alternativas.

A partir de esta problemática, surge la necesidad de integrar la capacidad exploratoria de la neuroevolución con un mecanismo formal de decisión multicriterio que permita valorar las arquitecturas considerando simultáneamente diferentes dimensiones de su desempeño. En este sentido, se plantea el desarrollo de un modelo híbrido de neuroevolución con AHP-TOPSIS, orientado a la optimización de arquitecturas DNN mediante la generación y exploración evolutiva de alternativas y su posterior evaluación multicriterio. El modelo busca determinar aquellas arquitecturas que, además de presentar un desempeño predictivo competitivo, mantengan un equilibrio favorable respecto del tiempo de inferencia, la complejidad y la capacidad de exploración topológica.

1.3. Objetivo

Diseñar, desarrollar y validar un modelo híbrido de neuroevolución para la optimización de arquitecturas de redes neuronales profundas, integrando AHP y TOPSIS para seleccionar alternativas considerando precisión predictiva, tiempo de inferencia, complejidad y capacidad de exploración topológica.

1.4. Justificación e importancia

La investigación se justifica por la necesidad de disponer de un procedimiento sistemático para optimizar la selección de arquitecturas de redes neuronales profundas considerando que su desempeño no puede valorarse únicamente a partir de la precisión predictiva. En este sentido, el modelo híbrido propuesto busca integrar la capacidad de exploración de la neuroevolución con un mecanismo de decisión multicriterio que permita analizar conjuntamente diferentes características de las arquitecturas candidatas.

La integración propuesta permite que el proceso de optimización considere criterios con diferente naturaleza y sentido de preferencia. La precisión predictiva permite valorar el desempeño de la arquitectura en la tarea de clasificación, mientras que el tiempo de inferencia y la complejidad permiten incorporar aspectos relacionados con la eficiencia computacional. A estos criterios se añade la capacidad de exploración topológica, utilizada para representar las posibilidades de modificación estructural de las arquitecturas dentro del proceso evolutivo. De esta manera, la selección de una arquitectura puede realizarse considerando un conjunto de propiedades y no únicamente el valor máximo de una métrica individual.

La utilización de AHP y TOPSIS dentro del proceso proporciona además una estructura formal para la toma de decisiones. AHP permite establecer la importancia relativa de los criterios mediante comparaciones pareadas y verificar la consistencia de los juicios empleados, mientras que TOPSIS permite ordenar las arquitecturas candidatas de acuerdo con su proximidad a una solución ideal. Esta combinación permite que la selección realizada por el proceso neuroevolutivo pueda ser respaldada mediante criterios explícitos, pesos cuantificados y un procedimiento matemático de comparación [8, 9].

Desde el punto de vista metodológico, el modelo híbrido busca articular la generación y exploración de arquitecturas con su evaluación multicriterio. La neuroevolución permite explorar diferentes configuraciones dentro del espacio arquitectónico, mientras que AHP-TOPSIS aporta un mecanismo para valorar las alternativas considerando simultáneamente sus características de desempeño

y eficiencia. Esta articulación permite orientar la optimización hacia arquitecturas que representen un compromiso favorable entre los criterios establecidos.

La propuesta también resulta relevante desde la perspectiva de la reproducibilidad, debido a que las decisiones involucradas en el proceso pueden ser documentadas mediante parámetros evolutivos, criterios de evaluación, pesos AHP, matrices de decisión y resultados TOPSIS. Asimismo, la realización de ejecuciones independientes permite analizar la estabilidad del desempeño obtenido y determinar si las diferencias observadas frente a métodos de comparación se mantienen bajo diferentes semillas experimentales.

En términos prácticos, el modelo híbrido puede contribuir a seleccionar arquitecturas DNN más adecuadas para escenarios en los que, además del desempeño predictivo, resulte necesario controlar los costos asociados con la ejecución del modelo. La incorporación de criterios de eficiencia permite considerar desde la etapa de selección características que pueden adquirir importancia durante el despliegue de las redes neuronales.

Finalmente, la investigación se justifica porque propone una forma estructurada de integrar neuroevolución y decisión multicriterio para la optimización de arquitecturas DNN. El aporte se centra en el procedimiento de integración y selección, mediante el cual las arquitecturas son generadas, evaluadas y comparadas bajo criterios explícitos. La validación experimental permitirá determinar la utilidad del modelo híbrido bajo las condiciones establecidas y aportar evidencia sobre su comportamiento frente a una estrategia de neuroevolución estándar y un modelo de referencia.

2. Metodología

2.1. Tipo, enfoque y nivel de investigación

El proyecto consiste en el desarrollo e implementación de un modelo híbrido de neuroevolución diseñado para automatizar y optimizar la selección de arquitecturas de redes neuronales profundas (DNN). A diferencia de los enfoques convencionales que se basan casi exclusivamente en maximizar la precisión predictiva, este modelo innova al integrar algoritmos evolutivos con métodos formales de toma de decisiones multicriterio (AHP-TOPSIS). Esta sinergia permite que, mientras la neuroevolución explora de forma autónoma el espacio de posibles arquitecturas, AHP y TOPSIS evalúen y clasifiquen las soluciones generadas considerando simultáneamente su precisión, tiempo de inferencia, complejidad estructural y capacidad de exploración topológica.

Como resultado, el sistema supera la limitación de crear redes muy precisas pero demasiado pesadas o lentas. Al aplicar pesos rigurosos a cada criterio, el modelo garantiza la selección de alternativas (como la arquitectura élite NE_Arch_B) que ofrecen un equilibrio óptimo entre un alto rendimiento predictivo y una excelente eficiencia computacional. Esto convierte al proyecto en una solución metodológica altamente viable y escalable para desplegar inteligencia artificial en entornos del mundo real donde los recursos, la memoria y la latencia son factores críticos.

2.2. Procedimiento del modelo híbrido

El modelo híbrido propuesto se estructuró en tres fases principales: **exploración neuro evolutiva, ponderación multicriterio y selección de arquitecturas**. Su propósito es integrar la capacidad de exploración de la neuro evolución con los métodos AHP y TOPSIS para evaluar y seleccionar arquitecturas de redes neuronales profundas considerando de manera conjunta su desempeño predictivo, eficiencia computacional y características estructurales.

En la primera fase se implementó el proceso de neuro evolución, orientado a generar y evaluar diferentes configuraciones arquitectónicas dentro del espacio de búsqueda definido. La población inicial estuvo conformada por 30 arquitecturas y el proceso evolutivo se desarrolló durante 20 generaciones. Para generar nuevas alternativas se empleó selección por torneo binario ($k=2$), cruce de un punto con una probabilidad de ($p_c=0,8$) y mutación por reemplazo de nodo con una probabilidad de ($p_m=0,2$).

Cada arquitectura candidata fue sometida a un entrenamiento proxy de 15 épocas sobre CIFAR-10, utilizando el optimizador Adam, una tasa de aprendizaje de 0,001 y un tamaño de lote de 64. La precisión de validación se utilizó como indicador del desempeño predictivo durante esta etapa, permitiendo valorar la capacidad de cada arquitectura para resolver la tarea de clasificación.

De manera complementaria, se registraron métricas relacionadas con la eficiencia y las características estructurales de las arquitecturas. El tiempo de inferencia se estimó mediante el promedio de 100 ejecuciones consecutivas sobre lotes de 32 imágenes, utilizando una CPU Intel Core i7 con 16 GB de RAM y sin aceleración mediante GPU. La complejidad se representó mediante el número de parámetros de cada arquitectura.

Asimismo, se incorporó como cuarto criterio la capacidad de exploración topológica, definida como la relación entre el número de mutaciones topológicas válidas disponibles para una arquitectura y el máximo número de mutaciones válidas observado en la población:

$$C_4 = \frac{M}{M_{max}}$$

donde (M) representa el número de mutaciones topológicas válidas disponibles para una arquitectura y (M_{max}) corresponde al máximo número de mutaciones topológicas válidas observado en la población evaluada. El resultado se encuentra normalizado entre 0 y 1, de modo que valores superiores representan una mayor capacidad relativa de exploración topológica.

Al finalizar las 20 generaciones, se seleccionaron las cuatro arquitecturas con mejor desempeño para conformar el conjunto de alternativas que posteriormente fue evaluado mediante el procedimiento multicriterio.

En la segunda fase se aplicó el método **AHP (Analytic Hierarchy Process)** para determinar la importancia relativa de los cuatro criterios considerados:

- **C1**, precisión predictiva;
- **C2**, tiempo de inferencia;
- **C3**, complejidad;

- **C4**, capacidad de exploración topológica.

La valoración se realizó mediante comparaciones pareadas efectuadas por cinco expertos con experiencia académica y profesional relacionada con inteligencia artificial y toma de decisiones multicriterio.

A partir de los juicios obtenidos se construyó la matriz de comparación pareada $A = [a_{ij}]_{n \times n}$ utilizando la escala fundamental de Saaty, y se determinaron los pesos relativos mediante el cálculo del eigenvector principal normalizado. Los pesos obtenidos fueron:

- $w_1 = 0,6066$
- $w_2 = 0,2623$
- $w_3 = 0,0674$
- $w_4 = 0,0636$

correspondientes a precisión, tiempo de inferencia, complejidad y exploración topológica, respectivamente. Adicionalmente, se empleó el coeficiente V de Aiken para evaluar la pertinencia de los criterios y la razón de consistencia (CR) para verificar la coherencia de los juicios utilizados en la matriz de comparación.

La razón de consistencia se determinó mediante:

$$CI = \frac{\lambda_{max} - n}{n - 1}$$

$$CR = \frac{CI}{RI}$$

Donde λ_{max} representa el valor propio máximo de la matriz de comparación, n corresponde al número de criterios, CI es el índice de consistencia y RI es el índice aleatorio. Se consideró aceptable la matriz cuando $CR < 0,10$.

En la tercera fase se aplicó TOPSIS (*Technique for Order Preference by Similarity to Ideal Solution*) sobre las cuatro arquitecturas seleccionadas. La precisión predictiva (C_1) y la capacidad de exploración topológica (C_4) se consideraron criterios de beneficio, mientras que el tiempo de inferencia (C_2) y la complejidad (C_3) se consideraron criterios de costo.

Inicialmente, los valores correspondientes a las cuatro arquitecturas y los cuatro criterios se organizaron en una matriz de decisión $X = (x_{ij})_{m \times n}$. Posteriormente, para homogeneizar las escalas y unidades de medición, dicha matriz fue normalizada mediante la transformación Max-Min orientada. Para los criterios de beneficio (B), la normalización se calculó mediante:

$$r_{ij} = \frac{x_{ij} - x_j^{\min}}{x_j^{\max} - x_j^{\min}}, \quad \forall j \in B$$

Por su parte, para los criterios de costo (C), se empleó la transformación inversa para convertir el costo en una escala de beneficio donde 1,0000 representa la solución más eficiente (menor tiempo de inferencia o menor complejidad):

$$r_{ij} = \frac{x_j^{\max} - x_{ij}}{x_j^{\max} - x_j^{\min}}, \quad \forall j \in C$$

donde x_{ij} representa el valor original de la alternativa i respecto del criterio j , r_{ij} corresponde al valor normalizado, y $x_j^{\max}$ y $x_j^{\min}$ representan los valores máximo y mínimo observados para el criterio j , respectivamente.

A continuación, se construyó la matriz de decisión ponderada $V = (v_{ij})_{m \times n}$ multiplicando los valores normalizados por los pesos AHP (w_j) obtenidos previamente:

$$v_{ij} = r_{ij} \cdot w_j$$

donde w_j representa el peso asignado al criterio j .

Dado que los criterios de costo fueron previamente invertidos en el paso de normalización, todas las variables en la matriz ponderada operan bajo un sentido de maximización. A partir de esta matriz se determinaron la solución ideal positiva (V^+) y la solución ideal negativa (V^-):

$$V^+ = (v_1^+, v_2^+, \dots, v_n^+) = \left(\max_i v_{ij} \right)$$

$$V^- = (v_1^-, v_2^-, \dots, v_n^-) = \left(\min_i v_{ij} \right)$$

Posteriormente, se calcularon las distancias euclidianas de cada arquitectura respecto de ambas soluciones ideales:

$$D_i^+ = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^+)^2}$$

$$D_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2}$$

Finalmente, se obtuvo el coeficiente de cercanía relativa (CC_i) mediante:

$$CC_i = \frac{D_i^-}{D_i^+ + D_i^-}$$

El valor de CC_i permitió establecer el ranking de las arquitecturas, donde valores superiores representan una mayor proximidad relativa a la solución ideal positiva y, por tanto, una mayor preferencia dentro del conjunto de alternativas evaluadas.

De esta forma, el modelo híbrido integra el proceso de exploración neuroevolutiva con la evaluación multicriterio mediante AHP-TOPSIS, permitiendo que la selección de la arquitectura no dependa exclusivamente de la precisión predictiva, sino del equilibrio entre desempeño predictivo, eficiencia computacional, complejidad y capacidad de exploración topológica.

Finalmente, la arquitectura que obtuvo la primera posición en el ranking TOPSIS fue seleccionada como la alternativa final y sometida a un entrenamiento extendido de 100 épocas sobre CIFAR-10. Los resultados obtenidos en esta etapa fueron utilizados para la validación experimental y para la comparación con la neuroevolución estándar y el modelo de referencia.

2.3. Técnicas e instrumentos

Para la implementación del modelo híbrido se utilizaron scripts desarrollados en Python y PyTorch, empleados en la generación, entrenamiento y evaluación de las arquitecturas neuronales durante las diferentes etapas del proceso evolutivo.

La evaluación de las arquitecturas se realizó mediante un conjunto de métricas cuantitativas que permitieron caracterizar tanto su desempeño predictivo como sus condiciones de eficiencia y estructura. Las métricas registradas fueron:

- **Precisión predictiva (C1):** utilizada para valorar el desempeño de cada arquitectura en la tarea de clasificación.
- **Tiempo de inferencia (C2):** utilizado para caracterizar el costo temporal asociado a la ejecución de las arquitecturas.
- **Número de parámetros (C3):** empleado como indicador de la complejidad de las arquitecturas.
- **Capacidad de exploración topológica (C4):** utilizada para representar la capacidad relativa de cada arquitectura para generar modificaciones topológicas válidas dentro del espacio de búsqueda.

Estos cuatro criterios constituyeron la base de la evaluación multicriterio mediante AHP-TOPSIS. De acuerdo con su naturaleza, la precisión predictiva y la capacidad de exploración topológica fueron consideradas criterios de beneficio, mientras que el tiempo de inferencia y el número de parámetros fueron considerados criterios de costo.

A partir de los valores obtenidos para las arquitecturas seleccionadas, el procedimiento TOPSIS permitió calcular indicadores derivados para establecer el orden de preferencia de las alternativas. Entre estos indicadores se consideraron la **distancia respecto de la solución ideal positiva (D_i^+)**, la cual representa la separación de cada alternativa respecto de la solución que reúne los valores más favorables

de los criterios, y la **distancia respecto de la solución ideal negativa** (D_i^-), que representa su separación respecto de la solución menos favorable.

Finalmente, se calculó el **coeficiente de cercanía relativa** (CC_i), utilizado como indicador de preferencia para establecer el ranking de las arquitecturas. Un valor superior de (CC_i) representa una mayor proximidad relativa a la solución ideal positiva y, por tanto, una mayor preferencia dentro del conjunto de alternativas evaluadas.

Para la obtención de los pesos de los criterios mediante AHP se empleó un instrumento de comparación pareada basado en la escala fundamental de Saaty. Este instrumento fue aplicado a cinco expertos con experiencia académica y profesional relacionada con inteligencia artificial y toma de decisiones multicriterio. Los juicios obtenidos permitieron construir la matriz de comparación pareada y determinar los pesos relativos de los cuatro criterios. Adicionalmente, se verificó la consistencia de las valoraciones mediante la razón de consistencia (CR), considerando el criterio de aceptación establecido para este procedimiento.

Los pesos obtenidos mediante AHP fueron:

$$W = (0,6066; 0,2623; 0,0674; 0,0636)$$

correspondientes a los criterios de precisión predictiva, tiempo de inferencia, número de parámetros y capacidad de exploración topológica, respectivamente.

2.4. Técnicas de análisis de datos

Para el análisis de los resultados experimentales se emplearon técnicas de estadística descriptiva, análisis comparativo y procedimientos de inferencia estadística, con el propósito de determinar las diferencias de desempeño entre el modelo híbrido propuesto, la neuro evolución estándar y el modelo de referencia.

En primer lugar, se calcularon medidas de estadística descriptiva para cada método a partir de las diez ejecuciones independientes realizadas bajo condiciones experimentales equivalentes. Se consideraron la media, desviación estándar, valores mínimo y máximo, con el fin de caracterizar el comportamiento central y la variabilidad de los resultados obtenidos.

Debido a que las tres técnicas fueron evaluadas utilizando las mismas particiones de datos y bajo condiciones experimentales equivalentes en cada una de las diez ejecuciones, los resultados presentan una estructura pareada. En consecuencia, se utilizó un análisis de varianza de medidas repetidas (ANOVA) para determinar si existían diferencias estadísticamente significativas entre los tres métodos evaluados.

Cuando el análisis global mostró diferencias significativas, se realizaron comparaciones por pares entre los métodos. Para estas comparaciones se empleó la prueba t de Student para muestras pareadas, considerando un nivel de significancia de ($\alpha=0,05$). La utilización de pruebas pareadas permitió considerar la correspondencia existente entre los resultados obtenidos por los tres métodos en cada ejecución experimental.

Adicionalmente, se analizaron las diferencias relativas de desempeño entre las alternativas mediante medidas de eficiencia multicriterio. En particular, se examinó el comportamiento de las

arquitecturas respecto de la precisión predictiva, el tiempo de inferencia, el número de parámetros y la capacidad de exploración topológica, así como el coeficiente de cercanía relativa obtenido mediante TOPSIS.

Los resultados estadísticos fueron utilizados como complemento del análisis multicriterio, permitiendo determinar no solo qué alternativa obtuvo un mejor resultado promedio, sino también si las diferencias observadas entre los métodos presentaron evidencia estadística suficiente para considerarse significativas.

Finalmente, se reportaron los resultados de cada ejecución junto con sus correspondientes medidas descriptivas y estadísticas, con el propósito de favorecer la reproducibilidad del experimento y proporcionar evidencia cuantitativa sobre la estabilidad del comportamiento del modelo híbrido frente a la neuro evolución estándar y al modelo de referencia.

3. Resultados

3.1. Ponderación de criterios mediante AHP

La pertinencia de los cuatro criterios fue evaluada por cinco expertos mediante el coeficiente V de Aiken. Se obtuvieron valores de 0,88 para C1, 0,85 para C2, 0,80 para C3 y 0,82 para C4.

La matriz de comparación pareada presentó una razón de consistencia de:

$$CR=0,0127$$

Este resultado se encuentra por debajo del valor de referencia de 0,10, por lo que los juicios utilizados para la ponderación presentan un nivel de consistencia aceptable.

Criterio	Tipo	Peso
C1. Precisión predictiva	Beneficio	0,6066
C2. Tiempo de inferencia	Costo	0,2623
C3. Complejidad	Costo	0,0674
C4. Exploración topológica	Beneficio	0,0636

Tabla 1. Pesos obtenidos mediante AHP. Fuente: elaboración propia.

La precisión predictiva constituye el criterio de mayor importancia, con 60,66 % del peso total, seguida por el tiempo de inferencia, con 26,23 %. Los criterios estructurales presentan pesos inferiores, pero permiten evitar que la decisión final dependa exclusivamente del rendimiento predictivo.

3.2. Métricas brutas de las arquitecturas evaluadas

La Tabla 2 presenta las métricas obtenidas para las arquitecturas élite y el modelo de referencia después del entrenamiento extendido.

Arquitectura	Precisión de test (%)	Tiempo de inferencia (ms)	Parámetros (M)	C4
NE_Arch_B	95,80	760,00	1,40	54,26
Modelo de referencia	94,90	880,00	1,60	51,35
NE_Arch_A	94,10	820,00	1,20	56,08
NE_Arch_C	93,60	690,00	0,90	60,94

Tabla 2. Métricas de desempeño de las arquitecturas evaluadas. Fuente: elaboración propia.

El análisis muestra que NE_Arch_B presenta la mayor precisión predictiva, mientras que NE_Arch_C presenta el menor tiempo de inferencia y el menor número de parámetros. NE_Arch_A presenta una combinación intermedia de precisión y complejidad.

Estas diferencias justifican la utilización de un procedimiento multicriterio, debido a que ninguna alternativa presenta simultáneamente el mejor valor en todos los criterios.

Nota aclaratoria: La Tabla 2 reporta el desempeño alcanzado tras un entrenamiento extendido de 100 épocas sobre la arquitectura seleccionada (NE_Arch_B). Por su parte, los valores presentados en las Tablas 4 y 5 corresponden a la validación estadística de 10 ejecuciones independientes bajo un esquema de entrenamiento proxy con semillas aleatorias.

3.3. Ranking mediante TOPSIS

A partir de los pesos obtenidos mediante AHP se construyó la matriz normalizada y posteriormente la matriz ponderada de decisión. Los criterios de beneficio fueron orientados hacia valores mayores y los criterios de costo hacia valores menores.

El coeficiente de cercanía relativa se calculó mediante:

$$CC_i = \frac{D_i^-}{D_i^+ + D_i^-}$$

donde (D_i^+) representa la distancia de la alternativa respecto de la solución ideal positiva y (D_i^-) representa su distancia respecto de la solución ideal negativa.

De acuerdo con los cálculos reportados:

$$\text{NE_Arch_B: } CC_i = \frac{0,6294}{0,1167+0,6294} = \frac{0,6294}{0,7461} = \mathbf{0,8436}$$

$$\text{Modelo de referencia: } CC_i = \frac{0,3584}{0,3677+0,3584} = \frac{0,3584}{0,7261} = \mathbf{0,4936}$$

$$\text{NE_Arch_C: } CC_i = \frac{0,2781}{0,6066+0,2781} = \frac{0,2781}{0,8847} = \mathbf{0,3143}$$

$$\text{NE_Arch_A: } CC_i = \frac{0,1681}{0,5080+0,1681} = \frac{0,1681}{0,6761} = \mathbf{0,2486}$$

Arquitectura	D+	D-	CCi	Ranking
NE_Arch_B	0,1167	0,6294	0,8436	1°
NE_Arch_C	0,6066	0,2781	0,3143	3°
NE_Arch_A	0,5080	0,1681	0,2486	4°
Modelo de referencia	0,3677	0,3584	0,4936	2°

Tabla 3. Ranking final de alternativas mediante AHP-TOPSIS. Fuente: elaboración propia.

NE_Arch_B obtuvo el mayor coeficiente de cercanía relativa del ranking final, con **CCi = 0,8436**, por lo que fue seleccionada como la alternativa con mejor equilibrio global según los pesos y criterios establecidos.

Aunque NE_Arch_C presentó ventajas en tiempo de inferencia y cantidad de parámetros, su menor precisión predictiva redujo su posición relativa bajo la ponderación definida mediante AHP.

3.4. Validación estadística

Para evaluar la robustez del desempeño obtenido, se realizaron diez ejecuciones independientes, utilizando las semillas 1 a 10, para cada uno de los tres métodos:

1. NE_Arch_B, correspondiente al modelo híbrido;
2. neuroevolución estándar, basada principalmente en precisión predictiva;
3. modelo de referencia.

Cada semilla fue aplicada bajo las mismas condiciones experimentales para los tres métodos, conformando un diseño pareado.

Los resultados descriptivos fueron:

Método	Precisión promedio (%)	Desviación estándar (%)
NE_Arch_B	86,32	0,15
Neuroevolución estándar	84,18	0,14
Modelo de referencia	82,25	0,11

Tabla 4. Estadísticos descriptivos de las diez ejecuciones independientes. Fuente: elaboración propia.

NE_Arch_B obtuvo una precisión promedio superior en comparación con los otros dos métodos. La diferencia promedio fue de 2,14 puntos porcentuales respecto de la neuroevolución estándar y de 4,04 puntos porcentuales respecto del modelo de referencia.

3.4.1. Comparación estadística

Debido al carácter pareado de las observaciones a través de las diez ejecuciones independientes (Tabla 5), se aplicó un análisis de varianza (ANOVA) de medidas repetidas considerando la ejecución (semilla) como factor intra-sujeto. Previamente, se verificó el supuesto de esfericidad mediante la prueba de Mauchly ($\chi^2(2) = 1,42; p = 0,491$), confirmando que no se violaron los supuestos del modelo.

El análisis de varianza reveló un efecto principal altamente significativo del método utilizado sobre la precisión predictiva, $F(2,18) = 2381,52, p < 0,0001, \eta_p^2 = 0,996$ (Tabla 4B). El tamaño del efecto parcial eta cuadrado ($\eta_p^2 = 0,996$) indica que el 99,6 % de la variabilidad observada en el rendimiento es explicada por la estrategia de diseño y selección empleada.

Tabla 4B. Resultado del ANOVA de medidas repetidas para el desempeño de precisión.

Fuente de Variación	Suma de Cuadrados (SS)	Grados de Libertad (df)	Media Cuadrática (MS)	Estadística F	Valor p	η_p^2 (Efecto)
Método (Tratamiento)	82,314	2	41,157	2381,52	< 0,0001	0,996
Error (Residuo)	0,311	18	0,017	—	—	—
Total	82,625	20	—	—	—	—

Fuente: elaboración propia.

Posteriormente, se realizaron comparaciones por pares mediante pruebas t de Student pareadas con ajuste de Bonferroni. La comparación entre el modelo híbrido (NE_Arch_B) y el modelo de referencia confirmó una diferencia media de 4,07 puntos porcentuales a favor del modelo híbrido ($S_d = 0,082\%$), obteniendo $t(9) = 156,43; p < 0,0001; d_{\text{Cohen}} = 49,47$, lo que evidencia una ventaja altamente consistente y reproducible bajo las condiciones experimentales utilizadas.

Asimismo, la comparación entre NE_Arch_B y la neuroevolución estándar presentó una diferencia media favorable al modelo híbrido de 2,14 puntos porcentuales ($t(9) = 84,12; p < 0,0001$), mientras que la comparación entre la neuroevolución estándar y el modelo de referencia mostró una diferencia media de 1,93 puntos porcentuales ($t(9) = 72,15; p < 0,0001$).

3.4.2. Resultados individuales

Ejecución	NE_Arch_B (%)	Neuroevolución estándar (%)	Referencia (%)
1	86,12	84,03	82,21
2	86,45	84,28	82,38
3	86,30	84,15	82,10
4	86,55	84,40	82,45
5	86,20	84,05	82,20
6	86,38	84,22	82,33
7	86,10	84,00	82,15
8	86,48	84,35	82,40
9	86,25	84,12	82,25
10	86,35	84,18	82,30

Tabla 5. Resultados individuales de las diez ejecuciones independientes. Fuente: elaboración propia.

NE_Arch_B presentó la mayor precisión en las diez ejecuciones. La diferencia respecto de los métodos comparativos se mantuvo positiva en todos los casos, lo que evidencia un comportamiento consistente bajo las condiciones experimentales establecidas.

3.4.3. Analisis de Convergencia

La evolución del proceso neuroevolutivo se analizó durante las 20 generaciones. Los resultados fueron:

Evaluación	Precisión promedio (%)	Desv. estándar (%)	CCi promedio	CCi máximo
Generación 1	53,74	8,88	0,3329	0,5141
Generación 5	73,18	6,86	0,5302	0,6808
Generación 10	81,26	5,09	0,6235	0,6992
Generación 15	83,57	3,91	0,6545	0,6965
Generación 20	84,23	3,12	0,6648	0,6991

Tabla 6. Historial de convergencia del proceso evolutivo. Fuente: elaboración propia.

La precisión promedio aumentó de 53,74 % en la primera generación a 84,23 % en la generación 20. Paralelamente, la desviación estándar disminuyó de 8,88 % a 3,12 %, lo que indica una reducción progresiva de la dispersión de las arquitecturas exploradas.

El CCI promedio también presentó una tendencia ascendente, pasando de 0,3329 en la primera generación a 0,6648 en la generación 20.

Debe aclararse que el CCI obtenido durante el proceso evolutivo no es directamente comparable con el CCI del ranking final, debido a que TOPSIS determina las soluciones ideales en función del conjunto de alternativas utilizado en cada aplicación.

Por tanto, el CCI máximo de 0,6991 registrado en la generación 20 corresponde al conjunto de 30 individuos de dicha generación, mientras que el valor de 0,8436 corresponde al ranking final calculado sobre las cuatro arquitecturas élite. El valor preliminar de 0,7842 corresponde igualmente a una aplicación diferente del procedimiento TOPSIS y no debe utilizarse como resultado final.




Figura 1. Historial de convergencia de la población (Precisión promedio y coeficiente CCI). Fuente: elaboración propia.




Figura 2. Frontera de eficiencia (Pareto) de las arquitecturas evaluadas. Fuente: elaboración propia.

3.5. Análisis de sensibilidad mediante extensión neutrosófica

Con el propósito de evaluar la estabilidad de los pesos obtenidos mediante AHP frente a la incertidumbre de los juicios de los expertos, se realizó una extensión neutrosófica del procedimiento.

Los pesos obtenidos fueron:

- $C1 = 0,5985$;
- $C2 = 0,2642$;
- $C3 = 0,0691$;
- $C4 = 0,0682$.

La comparación con los pesos clásicos mostró variaciones reducidas. La mayor diferencia correspondió a C1, cuya variación fue inferior a dos puntos porcentuales.

Al aplicar los pesos neutrosóficos al procedimiento TOPSIS, el orden de las alternativas se mantuvo. Este resultado proporciona evidencia de estabilidad de la decisión frente a variaciones en la valoración subjetiva de los expertos.

4. Discusión

Los resultados muestran que la integración de neuroevolución y decisión multicriterio permite abordar la selección de arquitecturas desde una perspectiva diferente a la optimización basada exclusivamente en precisión predictiva [4], alineándose con la necesidad de equilibrar metas contrapuestas en la búsqueda de arquitecturas neuronales [10].

La arquitectura NE_Arch_B fue seleccionada como la mejor alternativa del ranking final debido a su equilibrio entre las dimensiones consideradas. Aunque NE_Arch_C obtuvo ventajas en términos de tiempo de inferencia y cantidad de parámetros, presentó una precisión inferior. Por tanto, la utilización de TOPSIS [9] permitió considerar simultáneamente dichas diferencias en lugar de seleccionar automáticamente la alternativa con el mejor valor en una única métrica.

Los resultados también muestran una evolución favorable de la población durante las 20 generaciones. El incremento de la precisión promedio y del CCI, acompañado por la disminución de la dispersión, sugiere que el proceso evolutivo logró orientar progresivamente la población hacia soluciones de mayor calidad dentro del espacio de búsqueda definido [6, 7].

La validación mediante ejecuciones independientes mostró además que NE_Arch_B mantuvo una ventaja sobre la neuroevolución estándar y el modelo de referencia en las diez semillas evaluadas. Este comportamiento constituye evidencia favorable de estabilidad experimental, aunque el número de ejecuciones sigue siendo limitado para establecer conclusiones generales sobre diferentes escenarios.

La extensión neutrosófica aportó un análisis adicional de sensibilidad de los pesos AHP [11]. El mantenimiento del orden de las alternativas ante la modificación de los pesos constituye evidencia de robustez del proceso de decisión.

No obstante, los resultados deben interpretarse dentro de las condiciones experimentales utilizadas. El estudio se desarrolló sobre CIFAR-10, con un espacio de búsqueda arquitectónico específico y un protocolo computacional determinado. En consecuencia, no puede afirmarse que el comportamiento observado se generalice automáticamente a otros conjuntos de datos, dominios o dispositivos de despliegue.

5. Conclusiones

La investigación permitió diseñar y validar un modelo híbrido de neuroevolución integrado con AHP-TOPSIS para la selección multicriterio de arquitecturas de redes neuronales profundas. El modelo combina la capacidad exploratoria del proceso evolutivo con un mecanismo de decisión que permite considerar simultáneamente diferentes dimensiones del desempeño arquitectónico.

La aplicación de AHP permitió identificar la precisión predictiva como el criterio de mayor importancia, con un peso de **0,6066**, seguida del tiempo de inferencia, con **0,2623**. La complejidad y la capacidad de exploración topológica obtuvieron pesos de **0,0674** y **0,0636**, respectivamente. La razón de consistencia de **CR = 0,0127** se mantuvo por debajo del umbral de 0,10, respaldando la coherencia de los juicios empleados en la ponderación.

El procedimiento TOPSIS permitió establecer un ranking considerando simultáneamente criterios de beneficio y de costo. De acuerdo con el cálculo reportado, **NE_Arch_B obtuvo un CCI = 0,8436**, ocupando la primera posición del ranking final. Este resultado evidencia que la alternativa seleccionada no necesariamente debe ser aquella que presenta el mejor comportamiento en una única métrica, sino aquella que alcanza el mejor equilibrio respecto de los criterios considerados y sus correspondientes pesos.

El análisis de convergencia mostró una evolución favorable de la población durante las 20 generaciones. La precisión promedio aumentó de **53,74 % a 84,23 %**, mientras que la desviación estándar disminuyó de **8,88 % a 3,12 %**. Asimismo, el CCI promedio aumentó de **0,3329 a 0,6648**, lo que sugiere una mejora progresiva de la calidad multicriterio de las alternativas exploradas.

La validación mediante diez ejecuciones independientes mostró que NE_Arch_B alcanzó una precisión promedio de **86,32 %**, frente a **84,18 %** de la neuroevolución estándar y **82,25 %** del modelo de referencia. La diferencia promedio fue de **2,14 puntos porcentuales** respecto de la neuroevolución estándar y de **4,04 puntos porcentuales** respecto del modelo de referencia. Además, NE_Arch_B presentó una precisión superior en las diez ejecuciones consideradas.

El análisis de sensibilidad mediante la extensión neutrosófica mostró modificaciones reducidas en los pesos de los criterios y mantuvo el orden de las alternativas. Este resultado aporta evidencia adicional sobre la estabilidad del proceso de decisión frente a la incertidumbre asociada a los juicios de los expertos.

En conjunto, los resultados obtenidos sugieren que la integración de neuroevolución con AHP-TOPSIS constituye una estrategia metodológica pertinente para la selección multicriterio de arquitecturas DNN bajo las condiciones experimentales analizadas. Sin embargo, la evidencia debe interpretarse de acuerdo con el conjunto de datos, el espacio de búsqueda y el protocolo experimental utilizados, por lo que no se establece una generalización automática hacia otros dominios.

Como trabajo futuro se propone ampliar el espacio de búsqueda arquitectónica e incorporar criterios adicionales, como consumo energético, memoria requerida, latencia específica del dispositivo, robustez frente a ruido y costo de entrenamiento. También se plantea evaluar el modelo sobre diferentes conjuntos de datos y plataformas de hardware, así como compararlo con métodos contemporáneos de Neural Architecture Search multiobjetivo. Estas extensiones permitirán analizar con mayor profundidad la capacidad de generalización y aplicabilidad del enfoque propuesto.

Referencias

- [1] I. Goodfellow, Y. Bengio, and A. Courville. Deep Learning. MIT Press, Cambridge, 2016.
- [2] Y. LeCun, Y. Bengio, and G. Hinton. Deep learning. Nature, 521 (2015), 436-444.
- [3] B. Zoph and Q. V. Le. Neural architecture search with reinforcement learning. In: International Conference on Learning Representations, 2017.

-
- [4] T. Elsken, J. H. Metzen, and F. Hutter. Neural architecture search: a survey. *Journal of Machine Learning Research*, 20(55) (2019), 1-21.
- [5] M. Wistuba, A. Rawat, and T. Pedapati. A survey on neural architecture search. *arXiv preprint arXiv:1905.01392*, 2019.
- [6] K. O. Stanley and R. Miikkulainen. Evolving neural networks through augmenting topologies. *Evolutionary Computation*, 10(2) (2002), 99-127.
- [7] E. Real, A. Aggarwal, Y. Huang, and Q. V. Le. Regularized evolution for image classifier architecture search. In: *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(1) (2019), 4780-4789.
- [8] T. L. Saaty. *The Analytic Hierarchy Process*. McGraw-Hill, New York, 1980.
- [9] C. L. Hwang and K. Yoon. *Multiple Attribute Decision Making: Methods and Applications*. Springer-Verlag, Berlin, 1981.
- [10] C. White, B. Nardi, and F. Hutter. Multi-objective neural architecture search: A comprehensive survey. *Journal of Machine Learning Research*, 24(12) (2023), 1-45.
- [11] D. A. Vera-Pinargote and D. Rumbaut-Rangel. Selección de Herramientas de Business Intelligence mediante AHP-TOPSIS Neutrosófico con Cadena de Expertos basada en Modelos de Lenguaje de Gran Escala. *Neutrosophic Computing and Machine Learning*, 41 (2025), 30-43.
- [12] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2) (2002), 182-197.
- [13] M. Tan and Q. V. Le. EfficientNet: Rethinking model scaling for convolutional neural networks. In: *Proceedings of the 36th International Conference on Machine Learning*, 2019, 6105-6114.
- [14] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama. Optuna: A next-generation hyperparameter optimization framework. In: *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2019, 2623-2631.

Contribución de los autores

Conceptualización, N. A. C. P. y M. Y. L. V.; metodología, N. A. C. P., D. A. V. P. y M. Y. L. V.; software y experimentación, N. A. C. P. y D. A. V. P.; validación, D. R. R. y M. Y. L. V.; redacción del borrador original, N. A. C. P. y D. A. V. P.; revisión y edición, D. R. R. y M. Y. L. V.; supervisión, M. Y. L. V. Todos los autores leyeron y aprobaron la versión final del manuscrito.

Agradecimientos

Los autores expresan su agradecimiento a la Universidad Bolivariana del Ecuador (UBE) por el apoyo institucional para el desarrollo de esta investigación, así como a los expertos del panel por sus invaluable valoraciones.



Declaración de conflicto de intereses

Los autores declaran que no existe ningún conflicto de intereses en relación con este artículo.

Disponibilidad de datos y código

Los scripts de neuroevolución, los registros de las 600 evaluaciones de fitness y las matrices AHP-TOPSIS están disponibles a solicitud del autor de correspondencia.

Received: Month Day, Year. Accepted: Month Day, Year

Anexos

Anexo A. Procedimiento AHP y consistencia

El panel de expertos evaluó la importancia de los cuatro criterios mediante la escala de Saaty. La matriz pareada resultante se presenta a continuación:

Criterio	C1 (Precisión)	C2 (Tiempo)	C3 (Complejidad)	C4 (Optimización)
C1 precisión	1,000	3,000	9,000	8,000
C2 tiempo	0,333	1,000	4,000	5,000
C3 complejidad	0,111	0,250	1,000	1,000
C4 topología	0,125	0,200	1,000	1,000
Suma columnas	1,569	4,450	15,000	15,000

Tabla A1. Matriz AHP y pesos de prioridad. Fuente: elaboración propia.

A partir de esta matriz agregada, se determinó: $\lambda_{\max} = 4,0342$; $CI = 0,0114$; y la razón de consistencia $CR = 0,0127$. Debido a que $CR < 0,10$, la matriz cumple estrictamente con el criterio de consistencia lógica.

Anexo B. Procedimiento TOPSIS - Matrices Intermedias

Para que los lectores puedan reproducir los resultados obtenidos en TOPSIS, la Tabla 6 presenta la matriz normalizada Max-Min y la matriz ponderada obtenidas en el paso intermedio:

Alternativa	C1 (Norm Pond)	C2 (Norm Pond)	C3 (Norm Pond)	C4 (Norm Pond)
NE_Arch_B	1,0000 0,6066	0,6316 0,1657	0,2857 0,0193	0,3034 0,0193
Modelo referencia	0,5909 0,3584	0,0000 0,0000	0,0000 0,0000	0,0000 0,0000
NE_Arch_A	0,2273 0,1379	0,3158 0,0828	0,5714 0,0385	0,4932 0,0314
NE_Arch_C	0,0000 0,0000	1,0000 0,2623	1,0000 0,0674	1,0000 0,0636

Tabla B1. Matrices de normalización Max-Min y ponderación intermedia de las alternativas. Fuente: elaboración propia.

Las distancias euclidianas a la solución ideal positiva (D+) y negativa (D-), así como el coeficiente CCi resultante, se muestran en la Tabla 3 en la sección 3.3 del cuerpo del artículo.