

01-002

PLANNING AND MANAGEMENT OF PHOTOVOLTAIC PLANTS PROJECTS BY ARTIFICIAL INTELLIGENCE.

Gil Ruiz, Jesús ⁽¹⁾; Martínez Torres, Javier ⁽²⁾; González Crespo, Rubén ⁽¹⁾

⁽¹⁾ Universidad Internacional de la Rioja, ⁽²⁾ Universidad de Vigo

Renewable energies have had exponential growth in recent years, as reflected by the international energy agency (IEA), according to its forecasts, the share of renewables in the electricity supply will go from 26% in 2018 to 44% in 2040. Currently, decision-making in project management and management continues to be based on the judgment of experts (based on experience), and this generates a lot of uncertainty in the development of projects, many of which led to failure or partial success. Artificial intelligence is the future of project management and direction, this research opens the way to automation of project management by AI, and specifically, in photovoltaic projects. An evolutionary fuzzy hybrid neural network (EFHNN) is presented, which will have the ability to plan photovoltaic plant projects, said network will have been trained with a total of 15 plans.

Keywords: Photovoltaic plants; planning; Project Management; machine learning; hybrid systems; neural networks.

PLANIFICACIÓN Y GESTIÓN DE PROYECTOS DE PLANTAS FOTOVOLTAICAS APLICANDO INTELIGENCIA ARTIFICIAL.

Las energías renovables han tenido un crecimiento exponencial en los últimos años como queda reflejado por la agencia internacional de energía (AIE), según sus previsiones, la participación de las renovables en el suministro eléctrico pasará del 26% de 2018 al 44% en 2040. Actualmente la toma de decisiones en dirección y gestión de proyectos sigue siendo por juicio de expertos (en base a la experiencia), y esto genera mucha incertidumbre en el desarrollo de los proyectos, derivando muchos de ellos en un fracaso o en un éxito parcial. La inteligencia Artificial es el futuro de la dirección y gestión de proyectos, esta investigación abre el camino hacia la automatización de dirección de proyectos por IA, y en concreto, en proyectos fotovoltaicos. Se presenta una Red neuronal híbrida difusa evolutiva (EFHNN), que tendrá la capacidad de realizar planificaciones de proyectos de plantas fotovoltaicas, dicha red se habrá entrenado con un total de 15 planificaciones.

Palabras claves: Plantas fotovoltaicas; planificación; Dirección de proyectos; aprendizaje automático; sistemas híbridos; redes neuronales.

Correspondencia: Jesús Gil Ruiz jesus.ingeniero@live.com

Agradecimientos: Deseo agradecer a mis tutores de tesis por la gran ayuda que me están brindando. También agradezco a mi familia, en especial a mi padre, Francisco Gil Moreno, un exitoso empresario, sin el cual no hubiera podido llegar a donde estoy hoy, que descanse en paz.



1. Introducción

En las últimas décadas, los proyectos han tenido un desarrollo exponencial pasando a verdaderos retos de la Ingeniería, como puede ser el canal de Panamá o la planta solar más grande del mundo (BEN BAN Solar) de 1.8GW en el desierto de Aswan (Egipto). La adopción de determinadas metodologías de gestión de proyectos (p. Ej., PMI (PMI,2017), IPMA y PRINCE) nos permite gestionar el inicio y la evolución de un proyecto de la forma óptima posible, controlando y respondiendo a cualquier problema que surja durante el proyecto, facilitando su finalización y aprobación antes de que surjan nuevos riesgos. Sin embargo, podría decirse que estas metodologías no son suficientes, ya que los procesos deben estar claramente estructurados con un control completo y claro del proyecto en todas las áreas relevantes.

Según el PMI realiza cada año unos estudios para ver el impacto de fracasar en los objetivos planteado en proyectos, en estudios realizados en 2014, dicen que el 9% de las empresas piensan que sus proyectos han obtenido resultados muy buenos, mientras que el 56% de las iniciativas llegaron a sus objetivos empresariales. Podemos hacernos una idea del coste en términos de presupuestos anuales. Si bien actualmente se están implementando las prácticas deseadas de la metodología de gestión de proyectos (PMP), que permiten la mejor gestión posible de un proyecto, como se señaló anteriormente, los procesos deben estar claramente estructurados y todas las áreas del proyecto deben estar estrictamente controladas, incluso en términos de los sistemas de información (Hartman,2002). Podría decirse que estas metodologías no son suficientes, ya que los procesos deben estar claramente estructurados con un control completo y claro del proyecto en todas las áreas relevantes.

El objetivo en este siglo tiene que ser revolucionar la experiencia del director de Proyecto con el apoyo de la inteligencia artificial, así evitar errores de planificación o gestión. Los modelos híbridos son el camino para la automatización de Dirección de proyectos por Inteligencia artificial, pero aún están poco desarrollados y hay mucho camino que recorrer. La planificación es una de las áreas, más sensibles dentro de la Dirección de proyectos siendo de vital importancia una adecuada planificación y gestión de los recursos desde el comienzo del Proyecto. En este trabajo presentamos un piloto experimental, una IA capaz de hacer la planificación de manera automática de proyectos de plantas fotovoltaicas (ingeniería, compras, logística, construcción y puesta en marcha), incluyendo la subestación y la línea de transmisión con un total de 100 tareas, lo que sería una planificación básica de un proyecto EPC (Engineering, procurement and construction).

Para este piloto se entrenará al modelo con un total de 15 planificaciones de proyectos de plantas fotovoltaicas. Este proyecto de investigación es un hito a nivel nacional e internacional ya que a día de hoy no nada similar en la bibliografía. Si este estudio es un piloto inicial, para ver las capacidades del modelo con un bajo entreno, (15 planificaciones), ya que el total del entreno serian alrededor de 50 planificaciones, (esto se planteará en trabajos futuros, debido a la gran dificultad para encontrar planificaciones de proyectos de Plantas fotovoltaicas).

Si existen estudios sobre evaluación de riesgos (Hashemi,2013) y costos (Savaş,2012) (Kim, 2004) en dirección de proyectos por inteligencia artificial pero sus resultados son muy

objetivos ya que los riesgos tienen una percepción muy subjetiva.

En estudios previos en inteligencia artificial en la Dirección de proyectos, los autores aplicaron modelos neurales difusos optimizados con Algoritmos Genéticos (llamado “modelo evolutivo de inferencia neuronal difusa” o EFNIM) a varios problemas (Cheng, 2009). El estudio actual combina redes neuronales lineales (NN) y redes neuronales de alto orden (HONN) en una red neuronal híbrida (HNN). Cada conector de capa HNN está dominado por un conector alternativo de capa lineal y de orden superior. La participación de la lógica difusa facilita la evolución del modelo HNN a un modelo de red neuronal híbrida difusa (FHNN), con algunas modificaciones que lo hacen diferente de EFNIM. Dentro del modelo propuesto de red neuronal híbrida difusa evolutiva (EFHNN)(Cheng,2011), este estudio empleó además Algoritmos Genéticos para optimizar las funciones de pertenencia de la Lógica Difusa y los tipos de conexión, topología y coeficientes de HNN (Cheng,2009).

2. Objetivos

- Estado del arte de nuestra investigación en el ámbito internacional.
- Plantear, probar y testear un modelo híbrido en fase de investigación.
- Plantear el piloto inicial de rendimiento a bajo entreno, para la creación de un software para planificación automática de Proyectos de Plantas fotovoltaicas.
- Obtener valores óptimos en relación al nivel de entreno.

3. Caso de estudio

3.1. Metodología:

Los pasos a seguir:

- Conseguir 15 planificaciones de proyectos de plantas fotovoltaicas.
- Establecer la Arquitectura del modelo (EFFHN).
- Establecer las entradas y las salidas del modelo.
- Procesar todos los datos en una hoja Excel y estandarizarlos en 100 tareas.
- Preparar los datos para que la red neuronal pueda leerlos.
- Preparar el modelo computacional en Python.
- Entrenar el modelo con 15 planificaciones.
- Realizar las pruebas y test.
- Presentación de los resultados.

3.2. Arquitectura del modelo

Se propone un modelo de red neuronal híbrida, difusa y evolutiva (EFHNN) este modelo

experimental incorpora cuatro enfoques de inteligencia artificial que son la red neuronal (NN), red neuronal de alto orden (HONN) (Dalhoum, 2019), lógica difusa (FL) y algoritmo genético (GA) (Figura 1). De los cuales, NN y HONN están compuestos para el motor de inferencia, es decir, la red neuronal híbrida propuesta (HNN); La lógica difusa (FL) domina las capas fuzzificadoras y defuzzificadoras; y el algoritmo genético (GA) optimiza el HNN y FL.

De acuerdo con las definiciones de “neuro con entrada-salida difusa” (Hayashi et al. 1998), este estudio propone una red neuronal híbrida difusa (FHNN) que está estructurada de una red neuronal híbrida (HNN) con entradas y salidas difusas (Figura 2). Cada conexión NN puede seleccionar un conector NN lineal o de orden superior.

Secuencialmente, la red neuro-difusa (FHNN) se optimiza mediante el proceso de adaptación de algoritmo genético (GA). El proceso busca simultáneamente las funciones óptimas de pertenencia de la lógica difusa (FL), coeficientes de defuzzificación, topologías HNN y parámetros HNN (incluidos los tipos de conexión lineal / de orden superior) mediante el algoritmo genético (GA).

Figura 1: Arquitectura del modelo

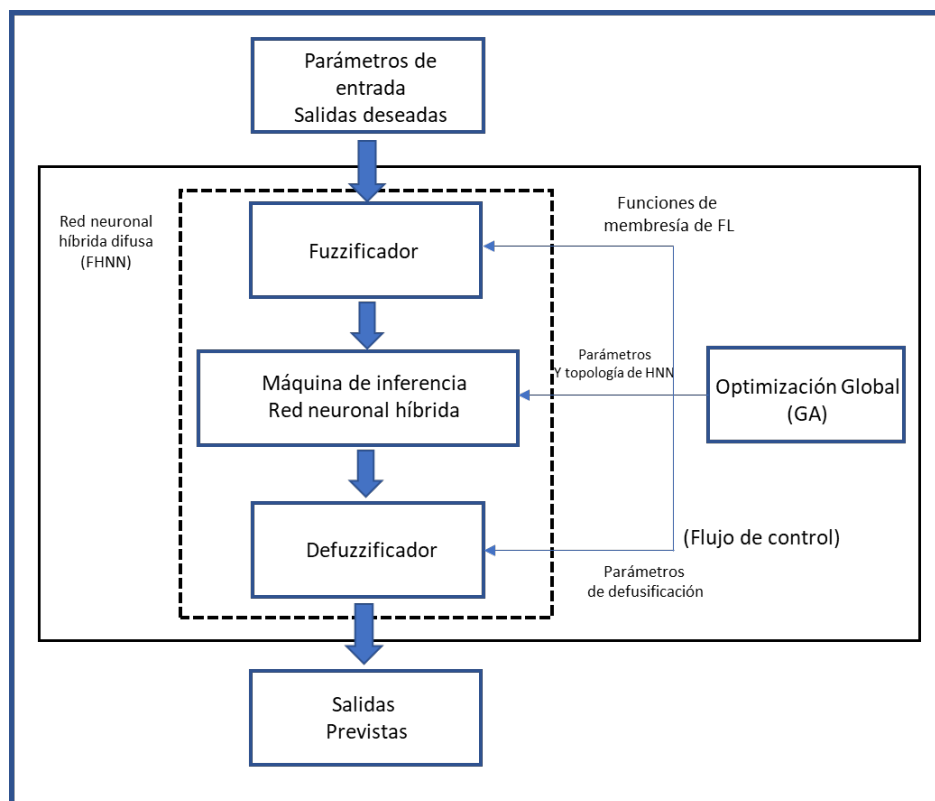
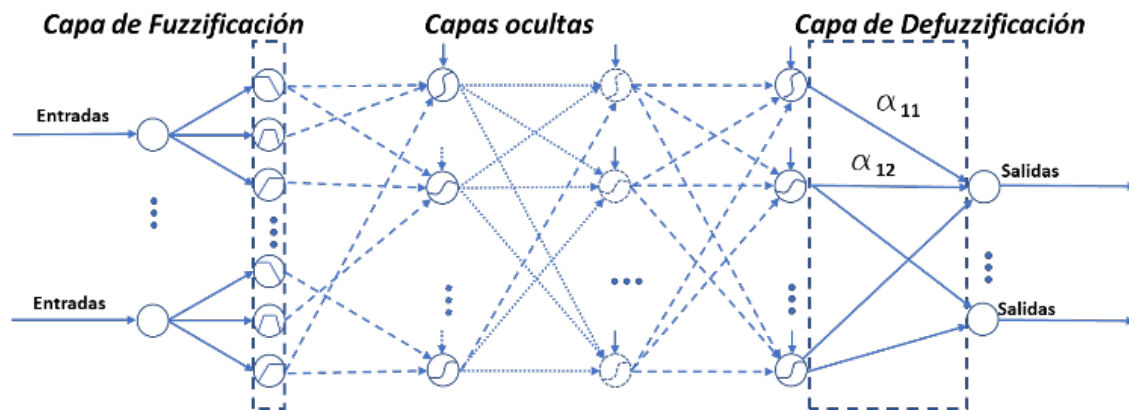


Figura 2: Red neuronal híbrida difusa (FHNN) con (FL) y (HNN)



Selección de conexión NN: L or HO L or HO L or HO

3.2.1. Red neuronal híbrida propuesta

Para la red neuronal híbrida propuesta (HNN), "híbrido" se utiliza para representar la combinación de red neuronal tradicional y red neuronal de alto orden. El orden alto La red neuronal que utiliza este artículo proviene del modelo honest (Abdelbar y Tagliarini, 1996) que se estructuró en tres capas con una conexión de alto orden y una conexión lineal entre la 1^a - 2^a capa y la 2^a - 3^a capa respectivamente.

Este estudio amplía los usos de la conexión de orden superior para todas las alternativas de conexión, es decir, todas las conexiones de capa pueden cambiar al tipo lineal o de orden superior (Figura 2). Una neurona HNN es dominado por una alternativa de las siguientes ecuaciones:

Conexión lineal:

$$y_j = a_0 + f(\sum w_{ji} + b_{j0} \times 1) \quad (1)$$

Conexión de alto orden:

$$y_j = f\left(\prod x_i^{p_{ji}} \times 1^{b_{j0}}\right) \quad (2)$$

Función de activación:

$$f(x) = \frac{1}{1+e^{-ax}} \quad (3)$$

Donde y_j (2) es una salida de neurona HNN calculada por las entradas de la neurona x_i (1). c_{ji} representa un coeficiente de una interconexión, que puede ser un formato lineal o de alto

orden relacionado con un peso w_{ji} o un exponente p_{ji} respectivamente. Una función de activación f (3) usa una función sigmoidea con un coeficiente de pendiente de a . Por lo tanto, cada conexión de capa tiene un tipo de conexión adjunta para representar su selección de operación (Figura 2). Todos los parámetros de la red neuronal híbrida (HNN) serán optimizados por el algoritmo genético (GA).

Como se menciona anteriormente, una red neuronal híbrida (HNN) con 2 capas puede seleccionar una conexión de capa lineal (L) o una conexión de orden superior (HO); los modelos de redes neuronales híbridas con 3 capas, según los tipos de conexión, existen cuatro escenarios posibles de LL, L-HO, HO-L y HO-HO. En resumen, la propuesta de la red neuronal híbrida (HNN) incluye todas las redes neuronales lineales y de orden superior según tipo de conexión que se seleccione.

3.2.2. Lógica Difusa

En la Figura 2, La red neuronal híbrida (HNN) está compuesta por una capa de fuzzificación y una capa de defuzzificación. Todos ellos componen la red neuronal híbrida difusa. En la capa de defuzzificación, una entrada se transfiere en primer lugar a varios grados de funciones de pertenencia (MF). En este estudio, se utiliza MF trapezoidal. Una forma general de describir las formas de MF es representar las posiciones de la cumbre (s_{mi}) y los anchos (w_{di}) de MF (Ishigami et al., 1995; Hayashi et al., 1998).

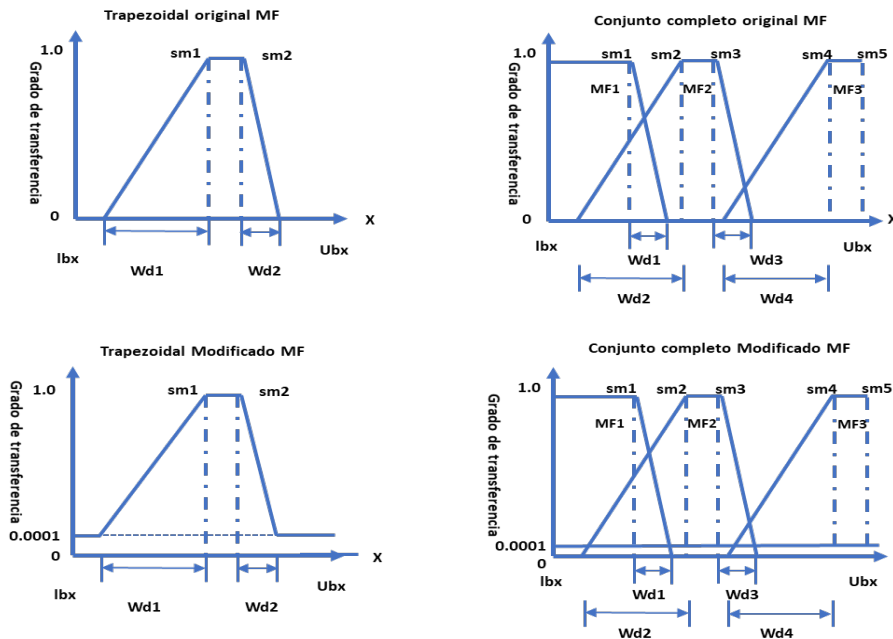
Una entrada se puede transferir a varios grados transferencia con las funciones de transferencias. Originalmente, las entradas de la función de pertenencia de están limitadas entre el rango de entradas de la capa y las entradas de la función de pertenencia generalmente se establecen dentro de $[0,1]$.

Sin embargo, debido a la ecuación adoptada (2), mientras que una de las salidas de la función de pertenencia tiene valor cero, las neuronas HNN relacionadas generarán valores cero a través del operador sigma-pi Π . Para evitarlo, este estudio modificó el MF original al rango de salida de $[0.0001,1]$ (Figura. 3). Siguiendo las descripciones antes mencionadas, todas las funciones de pertenencia son características de los valores de s_m y w_d . Además, en la capa de defuzzificación (Figura 2), este estudio adopta la fórmula de promedio ponderado:

$$y_i = \psi(x) = \frac{\sum \alpha_{ji} x_i}{\sum \alpha_{ji}} \quad (4)$$

donde ψ (4) es una función de defuzzificación; α representan pesos de defuzzificación; x denota las posibles salidas de la red neuronal híbrida (HNN); y_i son las salidas finales de la red neuronal híbrida difusa (FHNN). En consecuencia, todos los s_m , w_d y α estarán dominados por el algoritmo genético (GA).

Figura 3. Ejemplos de Funciones de pertenencia (FL)



3.2.3. Implementación del algoritmo genético

Para aplicar el algoritmo genético (GA) para la optimización del problema, se deben identificar todos los parámetros esenciales para determinar la longitud del cromosoma. Un cromosoma (un individuo) en este estudio debe representar parámetros de HNN y FL. Los parámetros de la red neuronal híbrida HNN tienen coeficientes de interconexión c (w y p), los tipos de conexión (CT: L o HO), coeficiente de pendiente de la función de activación a ($1 \sim 6$) y topología de red (número de capas y número de neuronas de capa). Los parámetros del sistema de lógica difusa (FL) incluyen puntos de cumbre de MF (sm), anchos de MF (w_d) y pesos de defuzzificación α . Merece mencionarse que se puede utilizar un coeficiente de interconexión c para la alternativa de w o p . Sin embargo, w y p funcionan de manera totalmente diferente, deben registrarse en diferentes subcadenas. Por lo tanto, la c antes mencionada debería ser una combinación de w y p . A medida que se identifica el cromosoma de un individuo, la red neuronal híbrida difusa (FHNN) se puede optimizar mediante el proceso de adaptación con mecanismos de cruce, mutación y selección.

3.3. Implementación del modelo

En la etapa de planificación de proyectos cuando se ha elaborado la ingeniería básica del diseño del Proyecto, obtenemos los patrones necesarios para establecer los valores de entrada que requerirá el modelo.

Se establecen 29 parámetros de entrada a nuestro modelo de red neuronal híbrida difusa evolutiva (EFHNN), y saldrán 200 parámetros de salida que serán el total de las duraciones de cada y del factor de intervalo de comienzo entre dos tareas (son 100 tareas, 2 parámetros por tarea) con estos valores obtenemos toda la planificación del Proyecto.

Se establece, 5 tipos de trabajos principales, Ingeniería, compras, logística, construcción y puesta en marcha.

El rango de datos de proyectos de construcción abarca los años 2017 a 2020. No se tendrá en cuenta para este piloto experimental, ni los rendimientos de obra, ni los costos del Proyecto.

Los 15 proyectos son plantas fotovoltaicas de ámbito nacional e internacional con un rango de potencia entre 10MW y 330MW, y con una duración menor a 2 años.

Para la simulación se harán 3 test, los valores de entrada serán los siguientes:

Tabla 1: Valores de entrada del modelo computacional.

Valores de Diseño del proyecto (Planta Fotovoltaica +Subestación+Línea de transmisión).									
Características Generales				Sistema de distribución Eléctrica					
				Tipo 1 Transformador de distribución					
Numero de pruebas	TEST1	TEST2	TEST3	Numero de pruebas	TEST1	TEST 2	TEST3		
Nombre del proyecto	PV Solar 50MW	PV SOLAR 146 MW	PV SOLAR 185MW	Numero de Transformadores	23	5	33	Transformadores	
Fecha de Inicio	25/10/2019	20/01/2018	06/10/2018	Potencia del Transformador	2,17	30	5,62	MVA	
Potencia Total	49,91	146,0	185,7	Tipo 2 Transformador de distribución					
Localización	34	34	34	Numero de Transformadores	0	0	0	Transformadores	
PLANTA FOTOVOLTAICA				Potencia del Transformador	0	0	0	MVA	
1.-Características de Ingeniería Civil				Tipo 1 Inversores					
Area	80	255,32	373,9	Numero de Inversores	23	5	178,3	Inversores	
Perimetro	3,58	6,391	7,7	Potencia del Inversor	2,17	30	1,0	MVA	
Numero de cimentaciones	23	5	33,4	Tipo 2 Inversores					
2.-Características de Ingeniería Mecánica				Numero de Inversores	0	0	0	Inversores	
Tracker Tipo 1				Potencia del Inversor	0	0	0	MVA	
Number of panel/tracker	30	45	60	SUBESTACION ELECTRICA					
Number of trackers	617	9845	9379	Numero de Equipos	22	22	22	Equipos	
Vertical modules	1	2	2	Numero de T.potencia	2	2	2	Transformadores de potencia	
Tracker Tipo 2				Voltaje de entrada	30	30	30	kV	
Number of panel/tracker	90	0	0	Voltaje de Salida	132	132	132	kV	
Number of trackers	1353	0	0	LINEA DE TRANSMISION					
Vertical modules	1	0	0	Distancia	0,581	0,6	4,1	km	
3.-Características de Ingeniería Eléctrica				Numero de torres	11,62	12	82	Torres de alta tensión	
Paneles Solares				Voltaje de salida	132	132	132	kV	
Numero total de paneles	140280	443030	562740	Paneles					
Potencia Unitaria	350	330	330	W					

El modelo híbrido será entrenado con un total de 3450 datos, cada tarea está compuesta por 4 valores (fecha de inicio, fecha final, duración, e intervalo de comienzo entre tarea y tarea).

Como comentamos anteriormente el modelo dará en su salida la duración por tarea y el intervalo de comienzo entre una tarea y su siguiente, con estos dos valores, y con la fecha inicio de proyecto, se montará toda la planificación completa.

Planteamiento del modelo híbrido:

Figura 4: Fenotipo del modelo FHNN de predicción de planificaciones de proyecto de plantas fotovoltaicas.




Tabla 2: Parámetros de configuración de EFFHN

EFFHN	Valores
a.-características Globales	
No de neuronas de entrada	Numero de factores de influencia
Neuronas de salida	2
b.-Red neuronal de alto orden	
Búsqueda de dominio para w y p	0-1
Nº de Capas ocultas máximas	4
Nº de neuronas máximas por capa	5
función de activación seleccionada.	Función sigmoidea logística
Pendiente de la función de activación	1-6
2.-Logica Difusa	
Búsqueda de dominio sm y wd	Within 0-1
Forma de la función de pertenencia	Trapezoidal
Numero de funciones de pertenencia	3
3.-Características del algoritmo genético	
Ratio de cruzamiento	1
Ratio de mutación	0.15
Tamaño de la población	16
Tasa de interacción	100

4. Resultados y Comparaciones:

Según los autores (Cheng, 2019), una conexión de alto orden siempre aparece en la segunda capa HNN en conjuntos de resultados (Figura 4). Tal resultado destaca que las conexiones NN de alto orden son bastante aplicables a este aprendizaje de planificaciones de proyecto. Además, el algoritmo genético (GA) optimiza las funciones de pertenencia del sistema de lógica difusa (FL) (Figura 3). Los estimadores utilizados en este documento lograron altos niveles de precisión en términos de predicción de las tareas y los intervalos teniendo en cuenta el bajo entreno de la red neuronal, (solo 15 planificaciones de 50/60).

En la tabla 3 muestra los resultados de las pruebas de nuestro modelo. Haremos 3 test, con planta solar de 50MW, 185MW y 150MW. Obtendremos la duración total del proyecto y un total de 100 tareas. Para poder analizar y valorar la calidad de los resultados se han establecido unos parámetros mínimos y máximos, de la duración de cada tarea y de intervalo de inicio entre 2 tareas.

El objetivo es establecer unos márgenes para poder estudiar con mayor precisión los resultados del modelo. Para poder medir correctamente los resultados de nuestro análisis, los test, los compararemos con los valores reales, de cada planta fotovoltaica y también con los límites teóricos.

Esto se debe a que, que haya desviación en una tarea con respecto a su valor real, no significa que el resultado tenga un error, puede que se halla planificado de otra manera, siendo otra solución válida, o incluso mejor que la real.

Para realizar nuestro análisis tendremos 4 parámetros, 2 valores lógicos (SI O NO) que básicamente nos dirán si ese valor está dentro de los límites teóricos y dos valores porcentuales que será el error relativo de las duraciones de las tareas y de los intervalos entre dos tareas.

Veremos a continuación el resultado de los 3 test:

Tabla 3: Resultados de la simulación

datos básicos para la construcción de sus fechas (fecha inicio, fecha final).

Después de obtener todos los datos por tarea, (límites teóricos, datos reales, datos del test, error relativo, etc.), se presentarán los resultados finales:

Tabla 4 Resultado final

Resultado Final	
Error del modelo computacional en función al nivel de entreno (R^2 SCORE)	66,10 %
Análisis con respecto a los Límites Teóricos	
Media porcentual de tareas que cumplen con la duración de los límites teóricos	99,96 %
Media porcentual de la duración de los Intervalos entre dos tareas, que cumplen con los límites teóricos	99,98 %
Análisis con respecto a los valores reales	
Error relativo medio (Duración de las tareas)	49 %
Error relativo medio (Intervalo entre dos tareas)	61 %
Análisis sobre la duración total del proyecto	
Duración media real de proyecto	519 días
Duración media de proyecto test	1299 días
Error relativo Porcentual sobre la duración media del proyecto	150 %
¿Cumple con los límites teóricos?	NO

Como se puede ver en la tabla 4 tanto la duración de las tareas como la duración de los intervalos el resultado es excelente (casi el 100%), es decir podemos apreciar que el modelo a bajo entreno ha sido capaz de cumplir con los límites necesarios que tiene que cumplir las tareas, para que cumplan con las fechas reales que se suelen plantear en proyectos de plantas fotovoltaicas. Con respecto a análisis de la comparativa de los valores reales (duración de las tareas y duración de intervalo) con respecto a la simulación podemos ver que tenemos un error menor en los datos con respecto al error que muestra la red neuronal híbrida a causa de su bajo entreno. Lo cual es un dato interesante ya que tenemos un mejor rendimiento con respecto al error del modelo computacional, aunque desde luego sigue siendo alto el error obtenido (49% y 61%). Y por último se analiza la duración media total del proyecto real (519 días), con respecto a la media de los test (1299 días), según observamos la desviación es bastante alta del 150%, se debe básicamente a que error se va acumulando en cada tarea, este valor era previsible ya que como bien hemos comentado la red está entrenada a un 30% (15 planificaciones) del total de entreno (50 planificaciones).

Como hemos podido ver en los resultados el modelo presenta un rendimiento muy interesante a nivel general con un bajo nivel de entreno, ya que como hemos podido ver ha podido pronosticar las duraciones de las tareas y los intervalos entre tareas conforme a los límites con una precisión de casi el 100%, los límites se han basado en los valores máximos y mínimos de las planificaciones que se usaron en el entreno.

5. Conclusiones

Este documento presenta una red neuronal difusa y evolutiva (EFHNN) y su aplicación al desarrollo de planificaciones de plantas fotovoltaicas en el mundo de la dirección de proyectos. El modelo EFHNN integró varias metodologías de inteligencia artificial, como redes neuronales tradicionales (lineales) y de alto orden (HONN), Lógica difusa (FL) creando capas de fuzzificación y defuzzificación para la red neuronal híbrida HNN propuesta, y algoritmos genéticos (GA) para optimizar la red híbrida neuro-difusa (FHNN).

Por lo tanto, el modelo presentado descrito puede abordar problemas con mayor profundidad en comparación con el uso de estas técnicas de manera independiente. Cabe mencionar que la arquitectura HNN propuesta es capaz de realizar mapeo entradas-salidas con conexiones de capa NN lineales y no lineales.

Los resultados obtenidos del modelo (EFHNN) para el diseño de planificaciones de proyectos son bastante buenos sobre todo teniendo en cuenta el bajo entreno del modelo.

Para futuros trabajos de investigación se entrenará el modelo completamente (un total de 50 a 60 planificaciones de proyecto), y se implementará un modulo de optimización para poder modificar la fecha final del proyecto en función de las necesidades el director de proyecto.

REFERENCIAS BIBLIOGRÁFICAS

- Abdelbar, A., & Tagliarini, G. (1996). HONEST: a new high order feedforward neural network. *IEEE International Conference on Neural Networks - Conference Proceedings*, 2. <https://doi.org/10.1109/icnn.1996.549078>
- Cheng, M. Y., Tsai, H. C., & Hsieh, W. S. (2009). Web-based conceptual cost estimates for construction projects using Evolutionary Fuzzy Neural Inference Model. *Automation in Construction*, 18(2), 164–172. <https://doi.org/10.1016/j.autcon.2008.07.001>
- Cheng, M. Y., Tsai, H. C., & Sudjono, E. (2011). Evaluating subcontractor performance using evolutionary fuzzy hybrid neural network. *International Journal of Project Management*, 29(3), 349–356. <https://doi.org/10.1016/j.ijproman.2010.03.005>
- Cheng, M. Y., Tsai, H. C., & Sudjono, E. (2009). Evolutionary fuzzy hybrid neural network for conceptual cost estimates in construction projects. *2009 26th International Symposium on Automation and Robotics in Construction, ISARC 2009*, 512–519. <https://doi.org/10.22260/isarc2009/0040>
- Dalhoun, A. L. A., & Al-Rawi, M. (2019). High-Order Neural Networks are Equivalent to Ordinary Neural Networks. *Modern Applied Science*, 13(2), 228. <https://doi.org/10.5539/mas.v13n2p228>
- Hartman, F., & Ashrafi, R. A. (2002). Project Management in the Information Systems and Information Technologies Industries. *Project Management Journal*, 33(3), 5–15. <https://doi.org/10.1177/875697280203300303>
- Hashemi, H., Mousavi, S. M., Tavakkoli-Moghaddam, R., & Gholipour, Y. (2013). Compromise Ranking Approach with Bootstrap Confidence Intervals for Risk Assessment in Port Management Projects. *Journal of Management in Engineering*, 29(4), 334–344. [https://doi.org/10.1061/\(asce\)me.1943-5479.0000167](https://doi.org/10.1061/(asce)me.1943-5479.0000167)
- Hayashi, I., Umamo, M., Maeda, T., Bastian, A., & Jain, L. C. (1998). Acquisition of fuzzy knowledge by NN and GA. *International Conference on Knowledge-Based Intelligent Electronic Systems, Proceedings, KES, 1*, 69–78.
- Ishigami, H., Fukuda, T., Shibata, T., & Arai, F. (1995). Structure optimization of fuzzy neural network by genetic algorithm. *Fuzzy Sets and Systems*, 71(3), 257–264. [https://doi.org/10.1016/0165-0114\(94\)00283-D](https://doi.org/10.1016/0165-0114(94)00283-D)
- Kim, G. H., An, S. H., & Kang, K. I. (2004). Comparison of construction cost estimating models based on regression analysis, neural networks, and case-based reasoning. *Building and Environment*, 39(10), 1235–1242. <https://doi.org/10.1016/j.buildenv.2004.02.013>
- PMI. (2017). PMBOK Guide | Project Management Institute. In *PMBOK Guide*. <https://www.pmi.org/pmbok-guide-standards/foundational/pmbok>

Savaş Bayram, Mehmet Emin Öcal, E. L. O. (2012). Analysis of Cost and Schedule Variances in Construction Works with Artificial Intelligence Approaches: The Case of Turkey. *International Students' Conference of Civil Engineering, ISCCE*, 10–11.

Comunicación alineada con los Objetivos de Desarrollo Sostenible



7.-ENERGIA ASEQUIBLE Y NO CONTAMINANTE: El mundo está avanzando hacia la consecución del Objetivo 7 con indicios alentadores de que la energía se está volviendo más sostenible y ampliamente disponible. El acceso a la electricidad en los países más pobres ha comenzado a acelerarse, la eficiencia energética continúa mejorando y la energía renovable está logrando resultados excelentes en el sector eléctrico. A pesar de ello, es necesario prestar una mayor atención a las mejoras para el acceso a combustibles de cocina limpios y seguros, y a tecnologías para 3000 millones de personas, para expandir el uso de la energía renovable más allá del sector eléctrico e incrementar la electrificación en el África subsahariana. El informe de progreso en materia de energía proporciona un registro mundial del progreso relativo al acceso a la energía, la eficiencia energética y la energía renovable. Evalúa el progreso conseguido por cada país en estos tres pilares y ofrece una panorámica del camino que nos queda por recorrer para conseguir las metas de los Objetivos de Desarrollo Sostenible 2030.

11.-CIUDADES Y COMUNIDADES SOSTENIBLES: El mundo cada vez está más urbanizado. Desde 2007, más de la mitad de la población mundial ha estado viviendo en ciudades, y se espera que dicha cantidad aumente hasta el 60 % para 2030. Las ciudades y las áreas metropolitanas son centros neurálgicos del crecimiento económico, ya que contribuyen al 60 % aproximadamente del PIB mundial. Sin embargo, también representan alrededor del 70 % de las emisiones de carbono mundiales y más del 60 % del uso de recursos. La rápida urbanización está dando como resultado un número creciente de habitantes en barrios pobres, infraestructuras y servicios inadecuados y sobrecargados (como la recogida de residuos y los sistemas de agua y saneamiento, carreteras y transporte), lo cual está empeorando la contaminación del aire y el crecimiento urbano incontrolado. El impacto de la COVID-19 será más devastador en las zonas urbanas pobres y densamente pobladas, especialmente para el millón de personas que vive en asentamientos informales y en barrios marginales en todo el mundo, donde el hacinamiento también dificulta cumplir con las medidas recomendadas, como el distanciamiento social y el autoaislamiento. El organismo de las Naciones Unidas para los alimentos, la FAO, advirtió de que el hambre y las muertes podrían aumentar de manera significativa en las zonas urbanas que no cuentan con medidas para garantizar que los residentes pobres y vulnerables tengan acceso a alimentos.