

MODELO HIPERHEURÍSTICO BASADO EN RAZONAMIENTO CON FUNCIÓN DE SELECCIÓN MULTIRETROPROPAGACIÓN APLICACIÓN PARA RESOLVER EL PROBLEMA DEL VECTOR ÓPTIMO DE INYECCIONES DE POTENCIAS DESDE MICRO-GENERACIÓN FOTOVOLTAICA EN BAJA TENSIÓN

GUSTAVO SCHWEICKARDT¹ RODOLFO RODRIGO² ANDRÉS AGOSTI¹

¹CONICET/Universidad Tecnológica Nacional - FRCU, Entre Ríos, Argentina.

²Dept.Electromecánica, Facultad De Ingeniería UNSJ, San Juan, Argentina.

gustavoschweickardt@conicet.gov.ar rodrigo@unsj.edu.ar

andresagosti@gmail.com

Fechas recepción: junio 2019 - Fecha aprobación: octubre 2019

RESUMEN

El nuevo paradigma de abastecimiento eléctrico, denominado Generación y Micro-Generación Distribuida (GD y MGD, respectivamente), complementario al tradicional referido como Generación Centralizada (GC), constituye una realidad para fomentar la penetración de fuentes primarias de energía renovable en la Matriz Energética. Particularmente, la MGD supone la introducción de una nueva figura como agente del Sistema de Distribución de Energía Eléctrica (SDEE) en Baja Tensión (BT): el usuario prosumidor o micro-generador. Sin embargo, existen aspectos técnicos relativos al funcionamiento del SDEE BT dentro de parámetros de tolerancia específicos y establecidos regulatoriamente que, de no ser resueltos, pueden atentar contra este nuevo paradigma, dado que la planificación y la operación de la red cambian en modo sustancial. En este trabajo se presenta, continuando con líneas de investigación abordadas por los autores, un Modelo HiperHeurístico más eficiente para resolver el Problema de Optimización del Vector de Inyecciones desde Micro-Generación Distribuida Solar Fotovoltaica (PO VIny MGD FV) en los SDEE BT, basado en Razonamiento con Función de Selección Multi-Retropropagación. El Modelo propuesto es aplicado sobre un SDEE BT real, comparando los resultados con otros Modelos HiperHeurísticos similares con Función de Selección Simple-Retropropagación, evidenciándose algunas ventajas que el mismo exhibe.

PALABRAS CLAVE: HiperHeurísticas - Redes Neuronales - Retropropagación Múltiple - Sistemas de Distribución Eléctrica – Micro-Generación Distribuida – Energía Solar Fotovoltaica

ABSTRACT

The new paradigm of electricity supply, called Distributed Generation and Micro-Generation (DG and MDG, respectively), complementary to the traditional one, referred to as Centralized Generation (CG), as a reality to promote the penetration of primary sources of renewable energy in the Energy Matrix. Particularly, the MDG involves the introduction of a new figure as agent

of the Low Voltage (LV) Electric Power Distribution System (EPDS): the prosumer or micro-generator user. However, there are technical aspects related to the operation of the LV EPDS within specific and regulated parameters of tolerance that, if not resolved, may threaten this new paradigm, given that the planning and operation of the network change substantially. This work presents, continuing with lines of research addressed by the authors, a more efficient HyperHeuristic Model Case Based Reasoning with Multi-Backpropagation Selection Function, to solve the Power Injection by Micro-Distributed Generators in a Low Voltage Electric Power Distribution System Optimizing Problem, focusing in Solar Photovoltaic Systems (PI MDG LV EPDS). The proposed Model is applied on a real LV EPDS, comparing the results with other similar HyperHeuristic Models with Simple-Back-Propagation Selection Function, and showing some advantages that it exhibits.

KEYWORDS: HyperHeuristics - Neural Networks – Multiple Backpropagation – Electric Power Distribution System – Neural Networks – Multiple Backpropagation - Distributed Micro-Generation - Photovoltaic Solar Energy

1. INTRODUCCIÓN

El nuevo paradigma de abastecimiento eléctrico, denominado Generación y Micro-Generación Distribuida (GD y MGD, respectivamente), complementario al tradicional, referido como Generación Centralizada (GC), constituye una realidad para fomentar la penetración de fuentes primarias de energía renovable en la Matriz Energética. Particularmente, la MGD supone la introducción de una nueva figura como agente del Sistema de Distribución de Energía Eléctrica (SDEE) en Baja Tensión (BT): el usuario *prosumidor* o micro-generador. Similar situación puede darse en Media Tensión (MT), pero para auto-abastecimiento o instalaciones de generación de pequeña potencia (GD). El usuario micro-generador puede consumir energía desde la red BT (como los clientes del paradigma tradicional GC) o auto-abastecerse (predominantemente mediante paneles solares fotovoltaicos - FV -), con la posibilidad de inyectar sus excedentes al SDEE BT a cambio de una contraprestación, ya sea en energía descontada en su facturación siguiente o monetaria. Sin embargo, existen algunos aspectos que, de no tratar su solución de forma adecuada, pueden atentar contra la aplicación sustentable de este nuevo paradigma MGD. Entre los mismos, se encuentran los aspectos técnicos que involucran el funcionamiento del SDEE BT dentro de los parámetros de tolerancia específicos, y los establecidos regulatoriamente, dado que la planificación y la operación de la red cambian en modo sustancial. El problema, específicamente en los SDEE BT, no está tratado con profundidad en el estado del arte. Sí en en los SDEE MT, como se aborda en Wang, Meskin, Zhao y Grinberg (2018) empleando el concepto de Flujo Óptimo de Potencia. Otro enfoque del problema, para un SDEE BT, desde la Programación Matemática Clásica y empleando el concepto de Despacho Óptimo para determinar el Nivel de Penetración de la GD FV, puede

consultarse en Dall’Anese, Dhople, Giannakis (2014). El presente trabajo aborda el desarrollo de un Modelo HiperHeurístico Basado en Razonamiento que constituye una alternativa más eficiente respecto de las presentadas en trabajos previos publicados por el primer autor Schweickardt (2018) y Schweickardt (2019) para resolver el problema de Optimizar la Inyección de Potencia desde Micro-Generadores Distribuidos en Sistemas de Distribución de Energía Eléctrica (SDEE) de Baja Tensión (BT), focalizándose en los Paneles Solares Fotovoltaicos (MGD FV).

Tomando como referencia los trabajos previos mencionados del primer autor, se detallan los conceptos y desarrollos generales necesarios para la definición de un nuevo Modelo HiperHeurístico basado en Razonamiento con Función de Selección Multi-Retropropagación, cuyo dominio se compone de un conjunto adecuadamente seleccionado de MetaHeurísticas variantes de PSO, Formas (X-FPSO) incorporando, además, la MetaHeurística Cardumen de Peces Artificiales (FAFS), en sus extensiones MultiObjetivo. Este Modelo HiperHeurístico será referido como HY CBR (X-FPSO + FAFS) MRP.

En las dos referencias citadas, el PO VIny MGD FV, fue resuelto mediante tres Algoritmos HiperHeurísticos, cuya breve descripción será proporcionada más adelante, con sustento en los trabajos Schweickardt, Casanova y Giménez (2013), Schweickardt, Casanova y Giménez (2014), Schweickardt y Casanova (2015) y Schweickardt, Casanova y Pérez (2015).

Estas HiperHeurísticas fueron referidas como: 1era) HY CBR (X-FPSO + FAFS), de procesamiento secuencial y adoptada como referencia en los resultados obtenidos; 2da) HY CBR (X-FPSO + FAFS) MPI V1, con procesamiento paralelo, aplicando la plataforma *Message Passing Interface* o MPI, siguiendo una primera estrategia o variante (V1) denominada MPI NCPN (Número Constante de Partículas por Núcleo); y 3ra) HY CBR (X-FPSO + FAFS) MPI V2, siguiendo una segunda estrategia o variante (V2) denominada MPI NVPN (Número Variables de Partículas por Núcleo).

El PO VIny MGD FV es un Problema de Optimización Combinatoria MultiObjetivo de la Clase de Problemas indicada por el primer autor mediante el acrónimo CP ECRRED por pertenecer a los campos de conocimiento de la Economía Computacional, la Teoría Económica de Regulación, y al de los Sistemas Eléctricos de Distribución.

Sin embargo, a diferencia de otros problemas pertenecientes a la CP ECRRED resueltos mediante Algoritmos HiperHeurísticos, tales como el Balance de Fases en un SDEE BT o la Ubicación Óptima de Equipos de Seccionamiento/Protección en un SDEE MT, que son de *planificación* para un horizonte temporal de Mediano/Corto Plazo, el PO VIny MGD FV es un problema de *operación*, es decir que debe ser resuelto en tiempo *cuasi-real* (≤ 3 min), dependiendo del grado o nivel de penetración de la MGD y la ubicación de los micro-generadores dentro la topología (radial) de la red BT.

De manera que el Modelo HY CBR (X-FPSO + FAFS) MPI V2, fue el que pudo arrojar los mejores resultados en el tiempo *cuasi-real* referido.

No obstante ello, se presentan dos inconvenientes en su aplicación, particularmente al aumentar el número de micro-generadores que inyectan sus excedentes a la red BT: a) en el tiempo de ejecución (demasiado elevado) y b) en una convergencia inconsistente respecto a las soluciones de mejor aptitud, obtenidas en diferentes simulaciones sobre el mismo SDEE BT real en estudio. De modo que el aporte del presente trabajo para superar estos inconvenientes, es el empleo de Modelo aquí propuesto y referido como HY CBR (X-FPSO + FAFS) MRP (CBR: *Case Based Reasoning*, X-FPSO: variante *X Fuzzy Particles Swarm Optimization*, FAFS: variante *Fuzzy de Artificial Fish School* y MRP: Multi-Retropropagación).

El trabajo está organizado como sigue: en la Sección 2, se presenta, en primer lugar, la formulación general del PO VIny MGD FV y su extensión al dominio MultiObjetivo, apto para ser resuelto por un Algoritmo HiperHeurístico tipo HY CBR (X-FPSO + FAFS), en general, mediante el empleo de Conjuntos Difusos (o Borrosos). En la Sección 3, se describen e forma breve, y soportándose en los trabajos más arriba referidos, los tres Modelos HiperHeurísticos utilizados para resolver este problema (HY CBR (X-FPSO + FAFS), HY CBR (X-FPSO + FAFS) NCPN y HY CBR (X-FPSO + FAFS) MPI NVPN), y se desarrolla en detalle en nuevo Modelo propuesto, HY CBR (X-FPSO + FAFS) MRP. En la Sección 4 se presenta una Simulación sobre un SDEE BT con MGD real para resolver el PO VIny MGD FV, comparando los resultados obtenidos desde el nuevo Modelo HiperHeurístico HY CBR (X-FPSO + FAFS) MRP, respecto de los obtenidos mediante los tres anteriores, evidenciándose las ventajas del nuevo Modelo propuesto respecto de las dos limitaciones mencionadas. Finalmente, en la Sección 5 se presentan las conclusiones más relevantes y en la Sección 6 la bibliografía consultada.

2. MODELO GENERAL PARA RESOLVER EL PROBLEMA PO VINY MGD FV SDEE BT

Los desarrollos que siguen son propuestos en Schweickardt (2019).

2.1 Formulación Clásica

El Modelo de Optimización General planteado en términos Clásicos se formula como:

FO →

$$\text{Max} = \text{VP}_{\text{Iny}} = \begin{bmatrix} \text{PFV}_{\text{Iny1}} \\ \text{PFV}_{\text{Iny2}} \\ \dots \\ \text{PFV}_{\text{InyMGD}} \end{bmatrix}$$

$$\text{Min} |I_h| \tag{1}$$

$$\text{Min} [\text{Perd}_{\text{PT}}]$$

Sujeto a:

- 1) $\forall i \in [1 \dots \text{MGD}], \text{PFV}_{\text{Inyi}} \leq \text{PFV}_{\text{InyMax}}^i$
- 2) $\forall n \in [1 \dots nN_{[R,S,T]}], U_{\text{LimMin}} \leq |U_{n[R,S,T]}| \leq U_{\text{LimMax}}$
- 3) $U_{\text{CTLimMin}} \leq |US_{[R,S,T]}| \leq U_{\text{CTLimMax}}$
- 4) $\forall r \in [1 \dots nR_{[R,S,T]}], |I_{r[R,S,T]}| \leq I_{\text{LimMax}}$

Siendo: MGD, el Número de MG FV distribuidos en el SDEE BT considerado;

PFV_{Inyi} , con i en $[1 \dots \text{MGD}]$, la Potencia de Inyección FV del MG i -ésimo; $|I_h|$, el módulo de la Componente Homopolar en el SDEE BT considerado, originada por el desbalance de cargas en cada fase del sistema (las cargas son monofásicas, al igual que las inyecciones, puesto que este es el caso peor); Perd_{PT} , son las Pérdidas Totales de Potencia Activa;

$\forall n \in [1 \dots nN_{[R,S,T]}], U_{\text{LimMin}} \leq |U_{n[R,S,T]}| \leq U_{\text{LimMax}}$ es una Restricción Técnica-Regulatoria, que implica que el módulo de la tensión en cada Fase $[R,S,T]$, de cada nodo n del SEDE BT, $|U_{n[R,S,T]}|$, se mantenga superior/igual a U_{LimMin} e inferior/igual U_{LimMax} ; $U_{\text{CTLimMin}} \leq |US_{[R,S,T]}| \leq U_{\text{CTLimMax}}$ es una Restricción Técnica que refiere lo mismo, pero a la Salida (secundario) del Transformador de Distribución MT/BT que se considera, tal como se plantea en las Simulaciones; y $\forall r \in [1 \dots nR_{[R,S,T]}], |I_{r[R,S,T]}| \leq I_{\text{LimMax}}$ es una Restricción Técnica que establece que la corriente en cada rama r y en cada Fase $[R,S,T]$ no supere el Límite Térmico Máximo I_{LimMax} , según el conductor empleado.

El Vector VP_{Iny} , tiene como componentes las *variables de control* del PO: las PFV_{Inyi} con i en $[1 \dots \text{MGD}]$. El resto de las variables ($|I_h|, \text{Perd}_{\text{PT}}, |U_{n[R,S,T]}|, |US_{[R,S,T]}|, |I_{r[R,S,T]}|$) son *variables de estado*.

Esto implica que, independientemente del Método de Optimización, el Espacio de Búsqueda tendrá MGD dimensiones, sobre valores continuos, acotados en el intervalo $[0, \text{PFV}_{\text{InyMax}}^i]$, según la Restricción 1).

El límite $\text{PFV}_{\text{InyMax}}^i$, como se verá al abordar las Simulaciones, depende, en general, de cada usuario MG FV ^{i} . Esto es así, porque es establecido según la Potencia Máxima del Panel Fotovoltaico del MG FV ^{i} .

Si esta superara la Potencia Contratada por el mismo a la empresa que

explota el Servicio de Distribución, cuando *no inyecta excedentes de energía* a la red (comportándose como un usuario *consumidor*), el límite PFV_{InyMax}^i vendrá dado, regulatoriamente, por su Potencia Contratada.

Por tal razón, en los Marcos Regulatorios aplicados a un SDEE BT con MG FV (u otra Fuente de Energía Primaria Renovable, en general), se habla de usuario *prosumidor*: *productor* (MG) o *consumidor* de energía eléctrica.

Una situación donde el *usuario generador* es *prosumidor* activo, ocurre en horarios nocturnos, considerando que los sistemas MG FV conectados a redes (es decir, que no operan en forma aislada) no están dotados de medios para acumular energía (banco de baterías), y pasando a ser *consumidor*.

De modo que, conforme se explicará en la propuesta de solución para este PO, localizado un cierto VP_{Iny} en el Espacio de Búsqueda, en cada instancia, se corre una Herramienta *software* para el Análisis de Funcionamiento en Régimen Permanente, denominada Flujo de Potencia Trifásico, la cual, según los datos proporcionados sobre el SDEE MG FV BT, calcula: $(|I_h|, Perd_{PT}, |U_{n[R,S,T]}|, |US_{[R,S,T]}|, |I_{r[R,S,T]}|)$, tomando en consideración todos los límites establecidos, e intenta maximizar cada componente de VP_{Iny} a la vez que intenta minimizar $|I_h|$ y $Perd_{PT}$, cumpliendo las restricciones sobre $|U_{n[R,S,T]}|, |US_{[R,S,T]}|$ y $|I_{r[R,S,T]}|$, iterando hasta lograr la mejor solución.

2.2 Construcción de los Conjuntos Difusos {O+R}

En la FIGURA 1 se presenta el constructo general para los Conjuntos Borrosos $CBorr_{(O+R)}$ solidarios a cada Objetivo-R restricción.




FIGURA 1: Estructura general de los $CBorr_{(O+R)}$ (Fuente: Elaboración Propia)

En esta Figura, se aprecia que la Función de Membresía para cada conjunto $CBorr_{(O+R)}$ es, en principio, *lineal* (recta más oscura).

La variable genérica u_{O+R} es aquella asignada a cada uno de los Objetivos + Restricciones del Conjunto $\{O+R\}$. Se observa que tal variable, presenta una aptitud $\mu(u_{O+R})$, que es *máxima* en $uMin_{O+R}$ y *mínima* en $uMax_{O+R}$. De forma tal que la construcción de cada conjunto $CBorr_{(O+R)}$, supone un cuidadoso análisis.

Adicionalmente, en la misma también se observan dos funciones *no lineales*. Estas provienen de considerar la importancia o peso que cada $CBorr_{(O+R)}$ tiene en la composición del Conjunto Borroso de Decisión, $CBorrD$. El *peso exponencial*, como se lo ha descrito y utilizado en los trabajos referidos, puede ser obtenido de dos formas: 1ro) Método auto-valor/auto-vector a partir de la Matriz de Importancia entre pares de $O+R$, y 2do) Aplicación de Programas Lineales Acoplados sobre los valores consignados como entradas en la Matriz de Importancia entre pares de $O+R$, desarrollado por el primer autor. En la simulación presentada en la Sección 4, y sin pérdida de generalidad, se optó por el 1er) Método, por simplicidad.

Seguidamente se presenta la formulación de la Función de Membresía correspondiente a cada $CBorr_{(O+R)}$, conforme el Modelo formulado en (1).

1) Conjunto Borroso solidario al Vector VP_{Iny}

La variable uVP_{Iny} del siguiente modo:

$$uVP_{Iny} = \left[1 - \left(\frac{\sum_{i=1}^{MGD} PFV_{Iny}^i}{\sum_{i=1}^{MGD} PFV_{InyMax}^i} \right) \right] \quad (2)$$

De manera que si todos los MG FV^i inyectasen su Potencia Máxima, uVP_{Iny} es igual al valor $uVP_{InyMin} = 0$, y debería resultar $\mu(uVP_{InyMin}) = 1$. En cambio, para el límite superior, si todos los MG FV^i inyectasen su Potencia Mínima (0), $uVP_{InyMin} = 1$ y debería obtenerse $\mu(uVP_{InyMin}) = 0$. Luego:

$$\mu(uVP_{Iny}) = (uVP_{Iny})^{YVP_{Iny}} \quad (3)$$

2) Conjunto Borroso solidario a $|I_h|$

Se considera un *límite mínimo* de $|I_h|$, $u|I_h|_{Min}$, dado por el valor de la misma en la mejor condición de balance de cargas que pueda presentar el SDEE BT, determinada, por caso, resolviendo un PO MonoObjetivo que minimiza $|I_h|$. El *límite máximo* vendrá impuesto de manera externa:

$$u|I_h|_{Max} = [1 + (\%|I_h|_{Min}/100)] \times |I_h|_{Min} \quad (4)$$

La Función de Membresía vendrá dada por la expresión condicional:

$$\text{Si } |I_h| < |I_h|_{\text{Min}} \rightarrow \mu(u|I_h) = 1 \quad (5)$$

$$\text{Si } |I_h|_{\text{Min}} \leq |I_h| \leq |I_h|_{\text{Max}} \rightarrow \mu(u|I_h) = \left[\frac{u|I_h|_{\text{Max}} - u|I_h|}{u|I_h|_{\text{Max}} - u|I_h|_{\text{Min}}} \right]^{Y|I_h|} \quad (6)$$

$$\text{Si } |I_h| > |I_h|_{\text{Max}} \rightarrow \mu(u|I_h) = 0 \quad (7)$$

3) Conjunto Borroso solidario a Perd_{PT}

Vale lo mismo que para la construcción del Conjunto Borroso anterior:

Se determina un *límite mínimo* y un *límite máximo*, $\text{Perd}_{\text{PTMin}} \equiv$

$u\text{Perd}_{\text{PTMin}}$ (resolviendo un PO MonoObjetivo que minimiza Perd_{PT}) y

$$u\text{Perd}_{\text{PTMax}} \equiv \text{Perd}_{\text{PTMin}} = [1 + (\% \text{Perd}_{\text{PTMin}})/100] \times \text{Perd}_{\text{PTMin}} \quad (8)$$

Luego, la Función de Membresía resulta:

$$\text{Si } \text{Perd}_{\text{PT}} < \text{Perd}_{\text{PTMin}} \rightarrow \mu(u\text{Perd}_{\text{PT}}) = 1 \quad (9)$$

$$\text{Si } \text{Perd}_{\text{PTMin}} \leq \text{Perd}_{\text{PT}} \leq \text{Perd}_{\text{PTMax}} \rightarrow$$

$$\mu(u\text{Perd}_{\text{PT}}) = \left[\frac{\text{Perd}_{\text{PTMax}} - \text{Perd}_{\text{PT}}}{\text{Perd}_{\text{PTMax}} - \text{Perd}_{\text{PTMin}}} \right]^{Y\text{Perd}_{\text{PT}}} \quad (10)$$

$$\text{Si } \text{Perd}_{\text{PT}} > \text{Perd}_{\text{PTMax}} \rightarrow \mu(u\text{Perd}_{\text{PT}}) = 0 \quad (11)$$

4) Conjunto Borroso solidario a $|U_{n[R,S,T]}|$

Como el Modelo 1) impone que en todo nodo n del SDEE BT considerado, con nN nodos, se satisfagan los límites establecidos regulatoriamente, se sigue la misma estrategia que en las referencias citadas.

Se definen tantos Conjuntos Borrosos como nodos tenga el SDEE BT bajo estudio, donde $u|U_{n[R,S,T]}| = |U_{n[R,S,T]}|$, con la Función de Membresía expresada en forma condicional del modo siguiente:

$$\text{Si } |U_{n[R,S,T]}| < U_{\text{LimMin}} \rightarrow \mu(u|U_{n[R,S,T]}) = 0 \quad (12)$$

$$\text{Si } U_{\text{LimMin}} \leq |U_{n[R,S,T]}| \leq U_{\text{LimMax}} \rightarrow$$

$$\mu(u|U_{n[R,S,T]}) = \left[\frac{U_{LimMax} - |U_{n[R,S,T]}|}{U_{LimMax} - U_{LimMin}} \right]^{Y|U_{nN[R,S,T]}} \quad (13)$$

$$\text{Si } |U_{n[R,S,T]}| > U_{LimMax} \rightarrow \mu(u|U_{n[R,S,T]}) = 0 \quad (14)$$

Y para el conjunto de nodos del SDEE BT, con n en [1...nN], se tendrá la Función de Membresía dada por:

$$\mu(u|U_{nN[R,S,T]}) = \sqrt[nN]{\prod_{n=1}^{nN} \mu(u|U_{n[R,S,T]})} \quad (15)$$

5) Conjunto Borroso solidario a $|US_{[R,S,T]}|$

Este Conjunto Borroso es totalmente análogo al anterior, por lo que la Función de Membresía tendrá la misma característica que (12)-(15), considerando $u(|US_{[R,S,T]}|) = |US_{[R,S,T]}|$ y los límites en la Salida del Transformador de Distribución MT/BT, $U_{CTLimMin}$ y $U_{CTLimMax}$, que son fijados por el regulador de tensión.

6) Conjunto Borroso solidario a $|I_{nR[R,S,T]}|$

Para la construcción de este Conjunto Borroso, se requiere que en cada rama r en [1...Nr[R, S, T]] del SDEE BT, la $|I_{r[R,S,T]}| \leq I_{LimMax}$ dada por el conductor empleado. El *límite mínimo* puede definirse de varias formas. La propuesta aquí, sigue la expresión:

$$I_{LimMin} = [1 - (\% I_{LimMax} / 100)] \times I_{LimMax} \quad (16)$$

Entonces, adoptando $u(|I_{r[R,S,T]}|) = |I_{r[R,S,T]}|$, las Funciones de Membresía del r-ésimo Conjunto Borroso con r en [1... nR], serán:

$$\text{Si } |I_{r[R,S,T]}| < I_{LimMin} \rightarrow \mu(u|I_{r[R,S,T]}) = 1 \quad (17)$$

$$\text{Si } I_{LimMin} \leq |I_{r[R,S,T]}| \leq I_{LimMax} \rightarrow$$

$$\mu(u|I_{r[R,S,T]}) = \left[\frac{|I_{r[R,S,T]}| - I_{LimMax}}{I_{LimMax} - U_{LimMin}} \right]^{Y|nR[R,S,T]} \quad (18)$$

$$\text{Si } |I_{r[R,S,T]}| > I_{\text{LimMin}} \rightarrow \mu(u|I_{r[R,S,T]}) = 0 \quad (19)$$

$$\mu(u|I_{nR[R,S,T]}) = \sqrt[nR]{\prod_{r=1}^{nR} \mu(u|I_{r[R,S,T]})} \quad (20)$$

Una vez obtenidos los Conjuntos Borrosos solidarios a cada variable del Modelo 1), los mismos deben someterse a un Operador de Confluencia, <C>, para componer el Conjunto Borroso de Decisión, CBorrD, que interviene en la toma de decisiones en entornos borrosos. Es decir:

$$\begin{aligned} \text{CBorrD} &= \text{CBorr}(VP_{iny}) <C> \text{CBorr}(|I_h|) <C> \text{CBorr}(\text{Perd}_{pT}) \\ &<C> \text{CBorr}(|U_{nN[R,S,T]}|) <C> \text{CBorr}(|US_{[R,S,T]}|) <C> \text{CBorr}(|I_{nR[R,S,T]}|) \end{aligned} \quad (21)$$

Como se explica en las referencias citadas, a cada operador, <C>, entre los Conjuntos Borrosos solidarios a las variables del Modelo 1) (en este caso <C> $\equiv \cap$), corresponde un conjunto de t-uplas, <t>, aplicadas sobre los valores de sus Funciones de Membresía para obtener el valor de la Función de Membresía de CBorrD (Decisión Maximizante en esta instancia). Es decir:

$$\begin{aligned} \mu D &= \mu(uVP_{iny}) <t> \mu(u|I_h) <t> \mu(u\text{Perd}_{pT}) <t> \mu(u|U_{nN[R,S,T]}) <t> \\ &\mu(u|U_{nN[R,S,T]}) <t> \mu(u|I_{nR[R,S,T]}) \end{aligned} \quad (22)$$

En los trabajos previos a Schweickardt (2019), se utilizó la t-upla Producto de Einstein, $t \equiv PE$, definida como, para dos valores μ_1, μ_2 :

$$PE(\mu_1, \mu_2) = [(\mu_1 \times \mu_2)/(2-(\mu_1 + \mu_2 - \mu_1 \times \mu_2))] \quad (23)$$

Por las propiedades de una t-upla, introduciendo un tercer valor, μ_3 , la operación continúa aplicando (23): $PE(\mu_1, \mu_2, \mu_3) = PE(PE(\mu_1, \mu_2), \mu_3)$, y así siguiendo el cálculo hasta integrar la m Funciones de Membresía (en este caso, $m = 6$). En la referencia (Schweickardt, 2019), es introducida una variante el PE, que se denominó Producto de Einstein Exponencial, PE^{YPE} . La razón estriba en que, por la estructura de cálculo observada en (23), a medida que aumenta m la μD dada por el último cálculo al introducir μm tiende asintóticamente a 0 en la medida que m aumenta, no proporcionando un valor representativo de la aptitud en la solución final alcanzada (μD máxima), y pudiendo, si m un es número elevado, generar problemas de cómputo.

Para resolver tales inconvenientes, PE^{YPE} es definida como:

$$PE^{YPE}(\mu_1, \mu_2) = [(\mu_1 \times \mu_2)/(2-(\mu_1 + \mu_2 - \mu_1 \times \mu_2))]^{(1/m)} \quad (24)$$

Y es la t-upla empleada la simulación que se presenta en Sección 4.

3. MODELOS HIPERHEURÍSTICOS. SOLUCIÓN DEL PO VINY MGD FV

3.1 Antecedentes. Modelos HiperHeurísticos Aplicados

Como se mencionó en la Sección 1, para resolver el PO VIny MGD FV en Schweickardt (2019), fueron aplicados y comparados en sus resultados tres Modelos HiperHeurísticos: 1ero) HY CBR (X-FPSO + FAFS), de procesamiento secuencial (y adoptada como referencia de comparación); 2do) HY CBR (X-FPSO + FAFS) MPI V1, con procesamiento paralelo, aplicando la plataforma *Message Passing Interface* o MPI, siguiendo una primera estrategia o variante (V1) denominada MPI NCPN (Número Constante de Partículas por Núcleo); y 3ro) HY CBR (X-FPSO + FAFS) MPI V2, siguiendo una segunda estrategia o variante (V2) denominada MPI NVPN (Número Variables de Partículas por Núcleo).

Los desarrollos relativos a estos Modelos HiperHeurísticos, se explican en Schweickardt *et al* (2013) y Schweickardt *et al* (2014), para el HY CBR (X-FPSO + FAFS), y en Schweickardt y Casanova (2015), para las dos variantes HY CBR (X-FPSO + FAFS) MPI NCPN y HY CBR (X-FPSO + FAFS) MPI NVPN. Por ello no se abordarán sus detalles.

En los tres Modelos, al tratarse de HiperHeurísticas basadas en Razonamiento, la Función de Selección, FS, se compone de una Red Neuronal Artificial tipo Retropropagación Simple (RNAR), cuyo dominio es un conjunto de MetaHeurísticas MultiObjetivo (X-FPSO + FAFS) seleccionadas conforme su capacidad complementaria de satisfacer los 5 Principios de Inteligencia de Grupo (PIG), también descriptos en tales trabajos.

Respecto del Dominio de la FS, el mismo se compone considerando las MetaHeurísticas: 1) FPSO con Factor de Constricción; 2) FEPSO (FPSO Evolucionaria); 3) FEPSO con Topología Global-Individual Estocástica; y 4) FAFS.

Para el caso de los Modelos HY CBR (X-FPSO + FAFS) (de procesamiento secuencial y adoptado sólo a los efectos de tener un caso de referencia en los resultados) y HY CBR (X-FPSO + FAFS) MPI V1 (de procesamiento paralelo con un Número Constante de Partículas por Núcleo – NCPN-), el Dominio de la FS está definido por las MetaHeurísticas {1), 2), 3), 4)}, como se explica en Schweickardt (2018). La estructura de los Patrones de Entrada a la y de Salida de la RNAR, es la misma: 15 Entradas y 7 Salidas. Igual su Diseño: 1 Capa de Entrada, 1 Oculta (con 10 Neuronas) y 1 de Salida. En ambos Modelos las Entradas y Salidas son números binarios, cuya significación para que la FS seleccione la MetaHeurística más apta a ser aplicada en la instancia siguiente de decisión (iteración algorítmica) explorando el Espacio de Soluciones en búsqueda de la μD máxima, es explicada en Schweickardt *et al* (2014) y Schweickardt y Casanova (2015). Lo mismo con respecto al Entrenamiento y Validación del Modelo, utilizando un Método de Validación Cruzada (Cross Validation), específicamente el *Multifold Cross Validation* Haykin (1999), o Método K-fold, para la validar la RNAR Schweickardt *et al* (2015). Tal como es utilizado en esta última referencia, es

utilizado aquí. En cambio, para el Modelo HY CBR (X-FPSO + FAFS) MPI V2 (procesamiento paralelo con un Número Variable de Partículas por Núcleo – NVPN-), se tienen dos modificaciones, explicadas en detalle en los trabajos previo, y que aquí serán mencionadas en forma breve.

1ra) El Dominio de la FS se compone de 5 MetaHeurísticas, debido a que el número de núcleos es igual al número de PIG's. Así, el mejor conjunto queda definido por las MetaHeurísticas {1), 2), 3), 3), 4)}, asignando a dos núcleos la MetaHeurística FEPSO con Topología Global-Individual Estocástica;

2da) Si bien el Diseño y el número de Patrones de Entrada y Salida de la RNAR no se modifican respecto a los dos Modelos anteriores, difiere en el tipo de Patrones de Salida empleados tanto para su entrenamiento como para su simulación con fines predictivos (FS de la HiperHeurística). Los Patrones de Entrada son idénticos (números binarios) que los propuestos en las dos HiperHeurísticas anteriores. Pero la codificación de los Patrones de Salida se modifica. De las 7 salidas, las primeras 5 son números enteros, que corresponden al tamaño de las subpoblaciones asignadas para cada núcleo-PIG en la siguiente iteración algorítmica, como se detalla en Schweickardt y Casanova (2015). Las 2 restantes, codificadas en binario, tienen una significación diferente: representan un efecto que se refiere como Saturación de X-Forma (MetaHeurística asignada a cierto núcleo), explicado también en detalle en la misma referencia bibliográfica.

Como se mencionó Sección 1, para resolver el PO VIny MGD FV la mejor performance (y única respecto al tiempo de ejecución *cuasi-real*), la proporcionó el Modelo Modelo HY CBR (X-FPSO + FAFS) MPI V2 (NVPN).

Sin embargo, se vuelve sobre los dos inconvenientes observados:

a) Un tiempo de ejecución demasiado elevado respecto al requerido, a medida que aumenta el número de micro-generadores en el SDEE BT considerado y

b) Una convergencia inconsistente respecto a las soluciones de mejor aptitud, obtenidas en diferentes simulaciones sobre el mismo SDEE BT en estudio. Esto puede ocurrir aún con el SDEE BT real considerado para la simulación presentada en la Sección 4, si bien es de un impacto poco significativo. Pero al aumentar el número de micro-generadores, el impacto es notorio.

Por tal razón, la propuesta en este trabajo, es reemplazar la RNAR (FS de Retropropagación Simple) por una RNAMR (FS de Retropropagación Múltiple), concibiendo el nuevo Modelo HiperHeurístico indicado como HY CBR (X-FPSO + FAFS) MRP descrito a continuación.

3.2 Modelo HY CBR (X-FPSO + FAFS) MRP

Este tipo de Red Neuronal Artificial (se omite a partir de aquí el término

Artificial), fue utilizado y se describe en Schweickardt *et al* (2015). Se extraen de tal trabajo algunos conceptos con la finalidad de contextualizar su empleo para resolver los inconvenientes mencionados.

3.2.1 Aprendizaje en Redes de Retropropagación Simple

Las Redes Neuronales de Retropropagación Simple (RNRS) constituyen sistemas de regresión no paramétricos que permiten resolver relaciones complejas de múltiples variables, muy a menudo difíciles de expresar matemáticamente o mediante reglas proposicionales. En general, cualquier problema que requiera de una función que caracterice a un sistema, asociando patrones de entrada con otros de salida, exhibe, como alternativa, una solución en base a RNRS. La limitación en el tipo de función así aproximada, viene impuesta por el conocido Teorema de Funahashi, para el cual puede consultarse la referencia Haykin (1999).

El algoritmo entrenamiento (o aprendizaje) de (por) retropropagación, es un algoritmo supervisado que ha sido aplicado de manera exitosa en la resolución de problemas de muy diferentes tipos. Es el más utilizado y conocido en el entrenamiento de Perceptrones Multicapa. Puede encontrarse una explicación muy detallada en Haykin (1999). Se formula sintéticamente como sigue:

Dado un vector de entradas $[x]$, un vector de salidas $[y]$, y un patrón actual de entrenamiento p , la salida para una determinada neurona k , (y_k^p), con N conexiones de entrada, cuando tal patrón p es presentado a la red, está dada por una función de activación $F(a_k^p)$, siendo a_k^p su activación, expresada mediante:

$$y_k^p = F(a_k^p) = F_k \left(\sum_{j=1}^N \omega_{jk} y_j^p + \theta_k \right) \quad (25)$$

Donde: ω_{jk} representa el peso asociado a la conexión entre la neurona j y la neurona k y θ_k el *bias*. Nótese que en el caso de la capa de entrada, y_k^p es igual a x_k^p . La regla del Gradiente Descendente, propuesta originalmente como método, minimiza el error cuadrático medio dado por la función:

$$E^p = \frac{1}{2} \times \sum_{o=1}^{N_o} (d_o^p - y_o^p)^2 \quad (26)$$

Donde d_o^p es la salida deseada para cuando el patrón p es presentado a la red y y_o^p es la salida de la neurona. Siguiendo el proceso de minimización, los pesos de la red son ajustados mediante la expresión:

$$\Delta_p \omega_{jk} = \gamma \times \delta_k^p \times y_j^p + \alpha \times \Delta_q \omega_{jk} \quad (27)$$

Donde: $\Delta_p \omega_{jk}$ es el ajuste resultante sobre el peso ω_{jk} , γ es la *tasa de aprendizaje*, parámetro fijado externamente, δ_k^p es el gradiente local de la neurona k , $\Delta_q \omega_{jk}$ es el cambio logrado en el peso ω_{jk} respecto del anterior patrón, q , presentado a la red, y α se denomina el *factor de momento*.

3.2.2 Aprendizaje en Redes de Retropropagación Múltiple

Cuando el mapeo de una función f , correspondiente a un determinado dominio de entrada y su imagen, presenta discontinuidades, el algoritmo de retropropagación clásico o simple falla. Este tiene un buen desempeño con funciones suaves. Para generalizarlo a funciones suaves a trozos, es utilizada una partición del espacio en cuyas divisiones la función resulta suave. Se mejora en forma notable la capacidad predictiva mediante una mejor interpolación (mejora en las capacidades de generación y aproximación de funciones) en el rango de entrenamiento de la red, con un menor tiempo de aprendizaje respecto de la Retropropagación Simple. Consiste en activar las neuronas selectivamente, a fin lograr que parte de lo aprendido se comparta entre las particiones del dominio de entrada. La contribución de una neurona genérica k en la salida de la red, cuando cierto patrón p es presentado, se modifica introduciendo un *factor o coeficiente de activación*, $m_k^p \geq 0$, en la ecuación de salida (25):

$$y_k^p = m_k^p \times F(a_k^p) = m_k^p \times F_k \left(\sum_{j=1}^N \omega_{jk} y_j^p + \theta_k \right) \quad (28)$$

Se observa que en la medida que mayor resulte m_k^p , más importante resulta contribución de la neurona k . En el caso que su valor sea 0, el resultado de la contribución de dicha neurona resultará nulo.

En la estructura se combinan una *red neuronal principal* conteniendo neuronas con activación selectiva y una *red secundaria (space network)* responsable de la determinación de los *factores de activación* m_k^p , permitiendo la división del espacio de entrada.

Estas redes, entrenadas con el algoritmo de Retropropagación Múltiple (RM), muestran tener mejores propiedades de generalización respecto de las redes *feed-forward* (o de propagación hacia adelante clásica, concepto opuesto a *recurrente*, donde la información fluye o se propaga en ambos sentidos), entrenadas con el algoritmo de Retropropagación Simple (RS). El RM ajusta los pesos de ambas redes y, mediante la modificación de los pesos de la *red secundaria*, cambia la importancia atribuida a cada neurona de la *red principal*, logrando la activación selectiva de las mismas. Así, las dos redes funcionan complementándose, componiendo una nueva arquitectura referida como Red de Retropropagación Múltiple (RNRM). La *red principal*, puede calcular sus salidas una vez calculada la salida de la *red secundaria*.

Los pesos de la *red principal* son ajustados mediante (27), pero con formulaciones distintas para los gradientes de las capas ocultas ($h = hidden$) y de salida ($o = output$).

Gradiente para la capa de salida:

$$\delta_o^p = (d_o^p - y_o^p) \times m_o^p \times F_o'(a_o^p) \quad (29)$$

Gradiente para las capas ocultas:

$$\delta_h^p = m_h^p \times F_h'(a_h^p) \times \sum_{o=1}^{N_o} \delta_o^p \times \omega_{ho} \quad (30)$$

Los pesos en la *red secundaria* deben ajustarse a fin de minimizar los errores de salida de la *red principal*:

$$\Delta_p m_k^p = - \frac{\partial E^p}{\partial m_k^p} \tag{31}$$

$$\Delta_p m_o^p = (d_o^p - y_o^p) \times F_o \times (a_o^p) \tag{32}$$

$$\Delta_p m_h^p = \sum_{o=1}^{N_o} \delta_o^p \times \omega_{ho} \times F_h(a_h^p) \tag{33}$$

Basándose en (32) y (33) es posible encontrar la salida deseada para la red secundaria, $m_k^p + \Delta_p m_k^p$.

En las FIGURA 2 y 3 se presentan las estructuras de una Red Neuronal de Retropropagación Simple y Múltiple. Se omite la representación de los *biases* o “pesos propios” de cada neurona.




FIGURA 2: Arquitectura de una Red Neuronal de Retropropagación Simple (RNRS) con 5 entradas, 1 capa oculta – 5 neuronas - y 4 salidas (Fuente: Elaboración Propia)

En la FIGURA 3, se observa una *red principal* (superior) y una *secundaria* (inferior). En la *red principal* existen dos contribuciones para el error de salida: (i) los pesos de las conexiones en la *red principal*; y (ii) los *factores de activación* de cada neurona, desde las conexiones de la *red secundaria*, m_k^p . Los círculos con X, representan *multiplicadores* de m_k^p (según (28)).

El algoritmo de Retropropagación Múltiple (MBP, en inglés, debido a cómo se lo adquiere) empleado en el presente trabajo, se encuentra disponible como una librería *Open Source*, para ser utilizado con procesamiento paralelo masivo. El *hardware* necesario para correrlo, es una PC de escritorio (o *notebook* de características avanzadas), que cuente con una placa gráfica que brinde la capacidad de procesamiento de su GPU. Esta librería, llamada

GPUMLib, implementa los algoritmos de Retropropagación Simple (BP), Retropropagación Múltiple (MBP), Factorización Matricial No Negativa (NMF) y Redes de Base Radial (RBF).

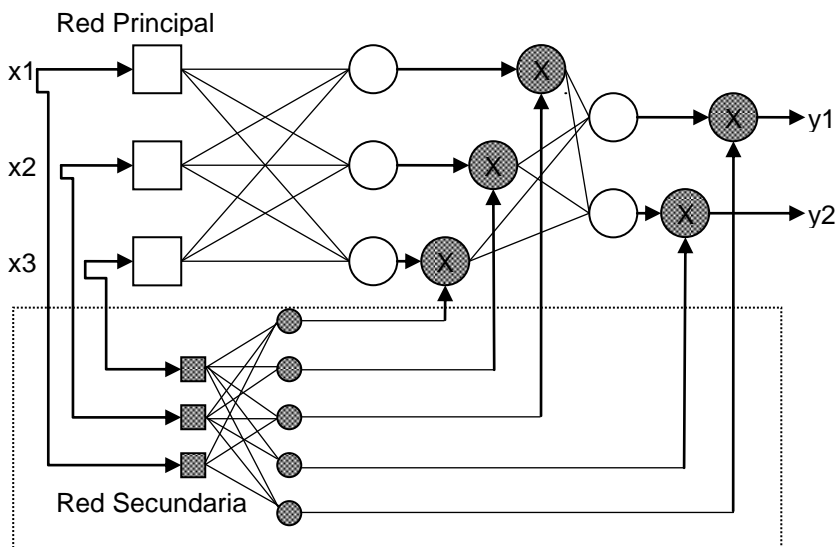


FIGURA 3: Arquitectura de Retropropagación Múltiple (RNRM) (Fuente: Elaboración Propia)

3.2.3 Implementación del Modelo HY CBR (X-FPSO + FAFS) MRP

Explicados los conceptos relativos al funcionamiento de una RNRM, se pasa a la implementación del Modelo HY CBR (X-FPSO + FAFS) MRP, describiendo primero las ventajas de esta estrategia para resolver el PO VIny MGD FV, en términos de los dos inconvenientes observados al aplicar el Modelo HY CBR (X-FPSO + FAFS) MPI V2 (NVPN).

Las RNRM presentan la capacidad de *fraccionar el espacio de entrada, utilizando neuronas selectivas*. Con ello, se presentan dos ventajas respecto a las RNRS: 1ra) Se disminuye el tiempo de entrenamiento y se logra aproximar mejor características no lineales en regiones localizadas, y 2do) Se mejora la capacidad de interpolación dentro del rango de entrenamiento. En rigor, la 2da) es consecuencia de la segunda parte de la 1era).

Empleando el mismo *hardware* que en la solución presentada en (Schweickardt, 2019), y considerando que en su implementación para resolver un PO de alta complejidad en *tiempo real* (< 20 s) -como lo es la Evaluación de la Seguridad Dinámica de un Sistema de Potencia En Línea, Schweickardt *et al* (2015)-, el tiempo de ejecución *cuasi-real* para obtener una solución muy satisfactoria y estable para el PO VIny MGD FV, está más que garantizado. Aún aumentando el número de micro-generadores conectados a la red BT.

De modo que la implementación del Modelo HY CBR (X-FPSO + FAFS) MRP aquí propuesto, es idéntica a la empleada en los Modelos HY CBR (X-FPSO + FAFS) y HY CBR (X-FPSO + FAFS) MPI V1 (NCPN), tanto en el Dominio de MetaHeurísticas para la FS de Retropropagación Múltiple, como en la Estructura y Diseño de la RNRM que la soporta, al descrito en la Subsección 3.1: Dominio \equiv MetaHeurísticas {1), 2), 3), 4)}; Nro. de Entradas (Patrones de Entrada) = 15, codificados en binario y con la misma significación; 1 Capa Oculta con 10 neuronas; y Nro. de Salidas (Patrones de Salida) = 7, codificados en binario y con la misma significación.

4. SIMULACIÓN

La red considerada, perteneciente al SDEE BT de la ciudad de Bariloche, Argentina, corresponde a una Salida (de las seis) de un Transformador de Distribución MT/BT (13.2 kV/0.38 kV) cuya Potencia Aparente es 315 kVA. Es la misma que la adoptada como Estudio de Caso en Schweickardt (2019), a los efectos de comparar las soluciones obtenidas por el Modelo HY CBR (X-FPSO + FAFS) MPI V2 (NVPN), que resultó el más eficiente, y por el Modelo HY CBR (X-FPSO + FAFS) MRP aquí propuesto.

El Esquema Trifilar de la red BT considerada, se presenta en la FIGURA 4. Las flechas en color negro (salientes de cada nodo) indican usuarios consumidores de energía desde la red. Las flechas en color rojo (entrantes en cada nodo) indican usuarios micro-generadores, inyectores de energía a la red (MG FV). El Sistema tiene, entonces, 115 usuarios prosumidores: 84 consumidores y 31 productores/inyectores (MG FV). Se observa un alimentador principal (Pr), cinco alimentadores secundarios (SI, SII, SIII, SIV y SV) y cuatro terciarios (TI, TII, TIII y TIV). Los números indican los prosumidores conectados a cada uno de ellos. Las Cargas tienen un signo positivo, mientras que las Inyecciones son negativas, ambas expresadas en kW. El Flujo de Potencia para Sistemas Desbalanceados con MG FV empleado, es una variante del utilizado para resolver el PO de Balance de Cargas Monofásicas en Redes de SDEE BT. La modificación estriba en que los MG FV pueden ser considerados *consumos negativos*, con un Factor de Potencia $fP_{Iny} = 1$, debido al funcionamiento de un Generador FV. Para las Potencias de consumo, se adopta un Factor de Potencia $fP_{Con} = 0.85$. Tratándose de una zona residencial, los usuarios consumidores tienen un Factor de Consumo Simultáneo (o Factor de Simultaneidad) $fConS = 0.6$, mientras que para los usuarios inyectores, su Factor de Inyección Simultánea resulta $fInyS = 1$ (todos están inyectando P_{Iny} a la red, en la misma franja horaria, como se desprende de la observación de todos los SDEE BT en el Segmento Residencial). No es posible presentar, por cuestiones de espacio, todos los datos y cálculos realizados. De modo que, sin pérdida alguna de generalidad, los valores de los consumos e inyecciones pueden ser consultados en Schweickardt (2019).

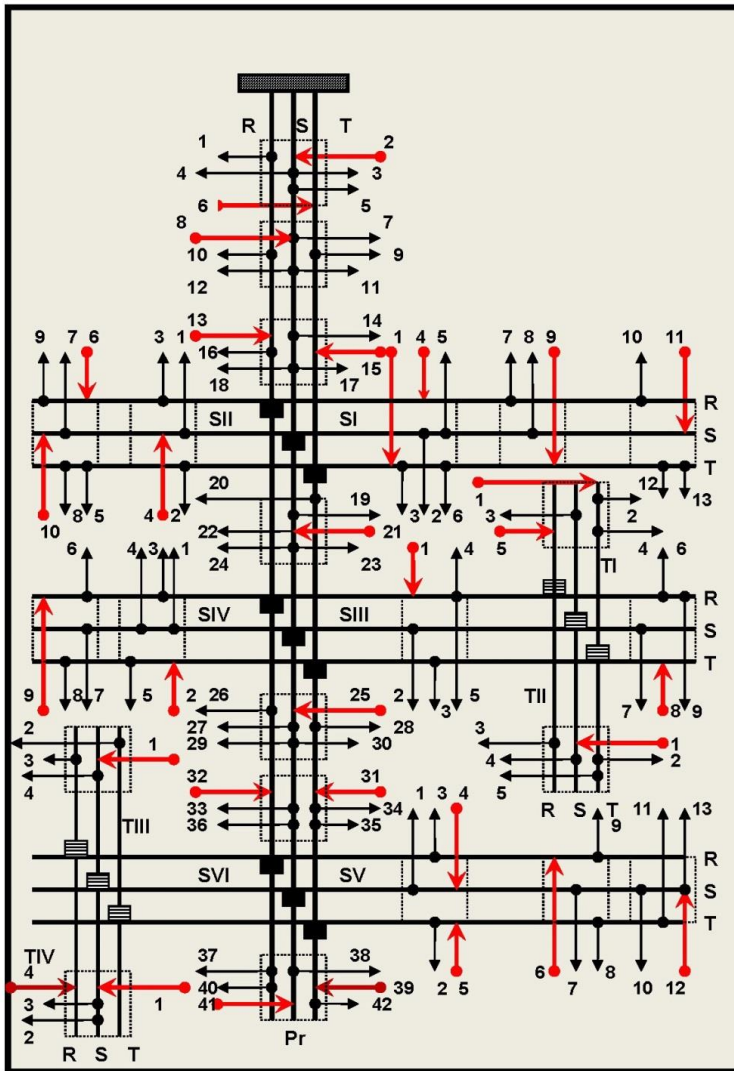


FIGURA 4: Red BT adoptada como Estudio de Caso (Fuente: Elaboración Propia)

La Potencia Contratada (e instalada en los Paneles Solares FV) por los usuarios consumidores puros y prosumidores no supera los 2 kW.

En la Tabla 1, se presentan los resultados específicos pretendidos en el presente trabajo: para cada CBorr, el valor de la Función de Membresía obtenido en la solución, μ_i , donde cada número indica el Objetivo-R restricción

Borroso, en el orden presentado en la Subsección 2.2, el valor de la Decisión Maximizante, μ_D , y el Tiempo de Computación requerido, para cada Modelo HiperHeurístico mencionado para Resolver el PO VIny MGD FV.

Modelo	μ_1	μ_2	μ_3	μ_4	μ_5	μ_6	μ_D	TC
HY CBR (X-FPSO + FAFS)	0.95	0.90	0.95	0.92	0.85	0.82	0.87	20 min
HY CBR (X-FPSO + FAFS) MPI V1	0.95	0.90	0.95	0.92	0.85	0.82	0.87	8 min
HY CBR (X-FPSO + FAFS) MPI V2	0.95	0.90	0.95	0.92	0.85	0.82	0.87	3 min
HY CBR (X-FPSO + FAFS) MRP	0.95	0.90	0.95	0.92	0.85	0.82	0.87	57 seg

Tabla 1: Resultados: Valores de las Funciones de Membresía o Pertenencia para cada $CBorr\{O+R\}$, $CBorrD$ al aplicar el Operador Producto de Einstein Exponencial, y Tiempos de Computación requeridos por cada Algoritmo HiperHeurístico (Fuente: Elaboración Propia)

En gris, se resaltan los Modelos HiperHeurísticos que no satisfacen el requisito de obtener una solución en tiempo *cuasi-real* Schweickardt (2019). Y en blanco, se presenta la comparación entre los dos Modelos que sí lo hacen, observándose una notable disminución de tiempo para el HY CBR (X-FPSO + FAFS) MRP. Más allá de que los valores de μ_i resultan iguales para la comparación de los dos últimos Modelos (producto de que red no es de gran tamaño), la ventaja a favor del Modelo HY CBR (X-FPSO + FAFS) MRP sobre el HY CBR (X-FPSO + FAFS) MPI V2, es que los valores para el primero *siempre resultaron estables en cuanto a su convergencia*, para diferentes instancias de simulación del mismo PO (misma red BT real y mismos datos). Esta situación no se presenta en el segundo.

Por otra parte, para esta red aún considerando un número mayor (hasta 60 inyectores), no se observaron modificaciones en el tiempo de cómputo, dada la robustez del Algoritmo HiperHeurístico propuesto.

5. CONCLUSIONES

Se han presentado los desarrollos de un nuevo Modelo HiperHeurístico basado en Razonamiento con Función de Selección Multi-Retropropagación referido como HY CBR (X-FPSO + FAFS) MRP, para resolver el problema indicado como PO VIny MGD FV, continuando con líneas de investigación previa en busca de mejoras en la solución obtenida.

Se observa una clara ventaja al aplicar el Modelo aquí propuesto sobre el de mejor performance presentado en trabajos previos (HY CBR (X-FPSO + FAFS) MPI V2 –NVPN-) en cuanto al tiempo de computación requerido (empleando en ambos casos una *notebook* con 5 núcleos y placa de video que soporta la librería GPULib) y la estabilidad en la convergencia de la solución. Por otro lado, el diseño de la RNRM, es más sencillo.

6. REFERENCIAS

- HAYKIN S. (1999). "Neural Networks and Learning Machine". Third Edition. Prentice Hall.
- DALL'ANESE, E., DHOPE, S., GIANNAKIS, G. (2014). "Optimal Dispatch of Photovoltaic Inverters in Residential Distribution Systems". IEEE Transactions on Sustainable Energy, Volume: 5, Issue: 2, págs. 487 - 497. doi: 10.1109/TSTE.2013.2292828.
- SCHWEICKARDT, G. (2018). "Optimización de la Inyección de Potencia desde Microgeneración Distribuida en Sistemas Eléctricos de Distribución de Baja Tensión. Desarrollos Teóricos de un Modelo HiperHeurístico". Lámpsakos, no. 20, págs.. 55-67.
- SCHWEICKARDT, G. (2019). "Modelo Hiperheurístico y Simulación para la Optimización de la Inyección de Potencia desde Microgeneración en Sistemas Eléctricos de Distribución de Baja Tensión". Lámpsakos, no. 21, págs.. 13-25.
- SCHWEICKARDT, G., CASANOVA, C. (2015). "Modelos HiperHeurísticos basados en Razonamiento con Procesamiento Paralelo y Dominio en Metaheurísticas X-PSO y AFS MultiObjetivo". Revista de la Escuela de Perfeccionamiento en Investigación Operativa, Vol. 23, (37), págs. 7-27.
- SCHWEICKARDT, G., CASANOVA, C., GIMENEZ ALVAREZ, J. M. (2013). "HiperHeurística basada en Razonamiento con Dominio en MetaHeurísticas X-PSO MultiObjetivo HY X-FPSO CBR. Aplicación sobre una Optimización Dinámica Posibilística. Parte 1)". Revista de la Escuela de Perfeccionamiento en Investigación Operativa, Vol. 21, (34), págs. 8-29.
- SCHWEICKARDT, G., CASANOVA, C., PÉREZ E. (2015). "Modelo de Simulación Soft-Computing para la Selección de Contingencias Críticas en la Seguridad Dinámica de Sistemas de Potencia Soportado en Redes Neuronales de Retropropagación Simple y Múltiple". Revista de la Escuela de Perfeccionamiento en Investigación Operativa, Vol. 23, (38), págs. 26-46.
- SCHWEICKARDT, G., CASANOVA, C., y GIMENEZ ALVAREZ, J. M. (2014). "HiperHeurística basada en Razonamiento con Dominio en MetaHeurísticas X-PSO MultiObjetivo HY X-FPSO CBR. Aplicación sobre una Optimización Dinámica Posibilística. Parte 2)". Revista de la Escuela de Perfeccionamiento en Investigación Operativa, Vol. 22, (35), págs. 128-148.
- WANG, T., MESKIN, M., ZHAO Y., GRINBERG, I. (2018). "Optimal Power Flow in Distribution Networks with High Penetration of Photovoltaic Units". 2017 IEEE Electrical Power and Energy Conference (EPEC), Saskatoon, SK, págs. 1-6. doi: 10.1109/EPEC.2017.8286231.