

Localización óptima de reconectores en redes de distribución con generación distribuida a partir de un enfoque multi-objetivo



FABIAN MARCELO LOPEZ CHAMORRO

**UNIVERSIDAD DE NARIÑO
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELECTRÓNICA
SAN JUAN DE PASTO
2017**

**Localización óptima de reconectores en redes
de distribución con generación distribuida a
partir de un enfoque multi-objetivo**

FABIAN MARCELO LOPEZ CHAMORRO

**TRABAJO DE GRADO PARA OPTAR POR EL TITULO DE INGENIERO
ELECTRÓNICO**

DIRECTOR

PhD. ANDRES DARIO PANTOJA BUCHELI

INGENIERO ELECTRÓNICO

**UNIVERSIDAD DE NARIÑO
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELECTRÓNICA
SAN JUAN DE PASTO
2017**

NOTA DE RESPONSABILIDAD

“La Universidad de Nariño no se hace responsable por las opiniones o resultados obtenidos en el presente trabajo y para su publicación priman las normas sobre el derecho de autor.”

Acuerdo 1. Artículo 324. Octubre 11 de 1966, emanado del honorable Consejo Directivo de la Universidad de Nariño.

NOTA DE ACEPTACIÓN:

Firma del presidente del jurado

Firma del jurado

Firma del jurado

San Juan de Pasto, 3 de Agosto de 2017

DEDICATORIA

“A mi familia, apoyo incondicional y alegría de mi vida”
“A mis abuelos, efímera felicidad, eterno recuerdo”

FABIAN MARCELO LOPEZ CHAMORRO

AGRADECIMIENTO

“A la fundación CEIBA y a la Gobernación de Nariño, por el apoyo y financiamiento de esta investigación a través del programa “FORTALECIMIENTO DE CAPACIDADES REGIONALES EN INVESTIGACIÓN, DESARROLLO TECNOLÓGICO E INNOVACIÓN EN EL DEPARTAMENTO DE NARIÑO” en su componente de “JÓVENES INVESTIGADORES E INNOVADORES”, una iniciativa de un inmenso valor para aquellos que buscamos un mejor mundo para todos a través de la investigación, mi más profunda y sincera gratitud hacia ustedes. Agradezco también a la Universidad de Nariño y al grupo de investigación GIIEE (Grupo de Investigación en Ingeniería Eléctrica y Electrónica), en especial a mi asesor y director del GIIEE el PhD Andrés Darío Pantoja Bucheli, por el apoyo incondicional a esta investigación y el valioso tiempo dedicado en asesorías y sugerencias para llevar esta investigación a buen final”.

FABIAN MARCELO LOPEZ CHAMORRO

RESUMEN

La ubicación eficiente de dispositivos de protección en redes eléctricas de distribución es necesaria con el fin de lograr un sistema confiable y proporcionar un suministro continuo de energía a los clientes tanto como sea posible. Una estrategia para reducir la energía no suministrada (ENS) incluye la operación en isla de ciertas cargas haciendo uso de la generación distribuida (GD). Sin embargo, es necesaria la ubicación de dispositivos de protección, por ejemplo reconectores, para permitir que el sistema logre este modo de operación.

Este trabajo presenta un método de optimización multi-objetivo para ubicar eficientemente reconectores normalmente cerrados por medio del Algoritmo Genético de Ordenación No-Dominada con restricciones (C-NSGA-II) con el fin de reducir el índice de duración promedio de interrupciones del sistema (SAIDI), la ENS y los costos de inversión. Un enfoque de co-simulación es utilizado de tal modo que el sistema de potencia es modelado en el software PowerFactory, mientras que MATLAB es utilizado en la implementación del C-NSGA-II.

Una red de distribución de prueba es utilizada en casos de estudio para diferentes niveles de penetración de la GD, mostrando la eficiencia del método de optimización propuesto. La metodología desarrollada es aplicada para la ubicación eficiente de reconectores en la red eléctrica de la universidad de Nariño en una estructura de microrred. Finalmente, los resultados muestran la importancia de los dispositivos de protección y la GD en el mejoramiento de la confiabilidad del sistema y la reducción de la energía no suministrada.

ABSTRACT

Efficient placement of protective devices in electric power distribution networks is necessary in order to achieve a reliable system and provide continuous power supply to customers as long as possible. A strategy to reduce the energy not supplied (ENS) includes the isolated operation of certain loads with the use of distributed generation (GD). Nevertheless, it is required the placement of protective devices, such as reclosers, to allow the system to achieve this operation mode.

This work presents a multiobjective optimization method to place efficiently normally closed reclosers by using a constrained non-dominated sorting genetic algorithm (C-NSGA-II) to reduce the System Average Interruption Duration Index (SAIDI), ENS and investment costs. A co-simulation approach is used in such a way that the power system is modeled in PowerFactory, while MATLAB is used to implement the C-NSGA-II.

A test distribution network is probed in simulation cases with different GD penetration levels, showing the efficiency of the proposed optimization method. The proposed methodology is used for the efficient placement of reclosers in the electrical network of the Universidad de Nariño in a microgrid structure. Results show the importance of protective devices and GD in enhancing system reliability and reducing the energy not supplied to customers

TABLA DE CONTENIDO

INTRODUCCIÓN	15
1. MARCO TEÓRICO	19
1.1. CONFIABILIDAD DE REDES DE DISTRIBUCIÓN	19
1.1.1. DISPONIBILIDAD	20
1.1.2. ÍNDICES DE CONFIABILIDAD	20
1.2. MODO AISLADO DE LA GENERACIÓN DISTRIBUIDA	23
1.3. OPTIMIZACIÓN MULTI-OBJETIVO Y OPTIMALIDAD DE PARETO	24
1.4. METAHEURÍSTICAS	26
2. METODOLOGÍA	28
2.1. FORMULACIÓN DEL MODELO MATEMÁTICO	28
2.2. COMPARACION DE ALGUNAS METAHEURISTICAS	29
2.2.1. NON-DOMINATED SORTING GENETIC ALGORITHM (NSGA-II) ...30	
2.2.2. NON-DOMINATED SORTING DIFFERENTIAL EVOLUTION (NSDE) 31	
2.2.3. MULTI-OBJECTIVE PARTICLE SWARM OPTIMIZATION (MOPSO)	32
2.2.4. COMPARACIÓN DE RESULTADOS	34
2.3. CONSTRAINED NON-DOMINATED SORTING GENETIC ALGORITHM (C-NSGA-II)	43
3. CASOS DE ESTUDIO Y RESULTADOS	47
3.1. CASO DE ESTUDIO 1	47
3.1.1. CIRCUITO DE PRUEBA “Roy Billinton Test System”	47
3.1.2. RESULTADOS CASO DE ESTUDIO 1	48
3.2. CASO DE ESTUDIO 2	52
3.2.1. RED ELECTRICA DEL CAMPUS UNIVERSIDAD DE NARIÑO	52
3.2.2. RESULTADOS CASO DE ESTUDIO 2	54
3.2.3. COMPARACIÓN DE RESULTADOS CON LOS ALGORITMOS NSDE Y PB-MOPSO	57

3.2.4. RESULTADOS CASO DE ESTUDIO 2 CON GENERACIÓN VARIABLE.....	59
4. CONCLUSIONES	68
4.1. RECOMENDACIONES.....	69
4.2. TRABAJO FUTURO.....	69
BIBLIOGRAFÍA.....	70
ANEXOS.....	75
ANEXO 1. ARTICULO DE CONFERENCIA INTERNACIONAL	75
ANEXO 1.1 CARTA DE ACEPTACIÓN.....	81
ANEXO 1.2 CERTIFICADO DE ASISTENCIA Y PRESENTACIÓN DEL ARTICULO DE INVESTIGACION.....	82
ANEXO 2. POSTER ENCUENTRO DEPARTAMENTAL DE CIENCIA, TECNOLOGÍA E INNOVACIÓN.	83

LISTA DE FIGURAS

Figura 1. Ejemplo ilustrativo de un alimentador con generación distribuida.....	24
Figura 2. Frente de Pareto producido por el NSGA-II para el problema de prueba 1	37
Figura 3. Frente de Pareto producido por el NSDE para el problema de prueba 1	37
Figura 4. Frente de Pareto producido por el PB-MOPSO para el problema de prueba 1.....	38
Figura 5. Frente de Pareto producido por el NSGA-II para el problema de prueba 2	40
Figura 6. Frente de Pareto producido por el NSDE para el problema de prueba 2	41
Figura 7. Frente de Pareto producido por el PB-MOPSO para el problema de prueba 2.....	41
Figura 8. Resultados de la evaluación de confiabilidad en PowerFactory	47
Figura 9. Índices de confiabilidad para el Bus 6 del RBTS	48
Figura 10. Red de distribución del bus 6 del circuito RBTS equipada con generación distribuida.....	49
Figura 11. Conjunto de soluciones no dominadas para el caso de estudio 1	50
Figura 12. Red eléctrica del campus de la Universidad de Nariño equipada con generación distribuida.....	52
Figura 13. Conjunto de soluciones no dominadas para el caso de estudio 2	55
Figura 14. Resultados obtenidos para 0% de penetración de GD	57
Figura 15. Resultados obtenidos para 20% de penetración de GD	58
Figura 16. Resultados obtenidos para 60% de penetración de GD	59
Figura 17. Modelo de arreglo de paneles fotovoltaicos en Simulink	60
Figura 18. Irradiancia medida dentro de la Universidad de Nariño durante un año	60
Figura 19. Temperatura medida dentro de la Universidad de Nariño durante un año.....	60
Figura 20. Potencia arreglo de 101.632 kW durante un año.....	61
Figura 21. Potencia arreglo de 101.632 kW durante 7 días	61
Figura 22. Potencia arreglo de 33.96 kW durante un año.....	61
Figura 23. Potencia arreglo 33.96 kW durante 7 días	61
Figura 24. Ilustración curva de demanda anual ordenada.	62
Figura 25. Curva de generación ordenada para el arreglo fotovoltaico de 101.632 kW.....	64
Figura 26. Curva de generación ordenada para el arreglo fotovoltaico de 33.96 kW.....	64
Figura 27. Resultados obtenidos para 20% de GD variable	65
Figura 28. Resultados obtenidos para 60% de GD variable	66

LISTA DE TABLAS

Tabla 1. Resultados de distancia generacional para el problema de prueba 1	38
Tabla 2. Resultados de espaciamento para el problema de prueba 1	39
Tabla 3. Resultados de tiempo computacional en segundos para el problema de prueba 1	39
Tabla 4. Resultados de distancia generacional para el problema de prueba 2	42
Tabla 5. Resultados de espaciamento para el problema de prueba 2	42
Tabla 6. Resultados de tiempo computacional en segundos para el problema de prueba 2	42
Tabla 7. Tiempos de procesamiento: PowerFactory y Co-simulacion	45
Tabla 8. Ejemplos de soluciones no dominadas del proceso de optimización en el caso de estudio 1	51
Tabla 9. Valores promedio de potencia activa, reactiva y aparente para la red del campus de la Universidad de Nariño	53
Tabla 10. Ejemplos de soluciones no dominadas del proceso de optimización en el caso de estudio 2	56
Tabla 11. Valores maximo, minimo y promedio Figuras 18,19,20,21,22,23	62
Tabla 12. Número de horas en que ciertos valores de potencia fueron igualados o superados para el arreglo fotovoltaico de 101.632 kW	63
Tabla 13. Número de horas en que ciertos valores de potencia fueron igualados o superados para el arreglo fotovoltaico de 33.96 kW	63
Tabla 14. Ejemplos de soluciones obtenidas para los casos con 20% de GD (Constante y Variable)	65
Tabla 15. Ejemplos de soluciones obtenidas para los casos con 60% de GD (Constante y Variable)	67

LISTA DE ANEXOS

ANEXO 1. ARTICULO DE CONFERENCIA INTERNACIONAL	74
ANEXO 1.1 CARTA DE ACEPTACIÓN	80
ANEXO 2. POSTER ENCUENTRO DEPARTAMENTAL DE CIENCIA, TECNOLOGÍA E INNOVACIÓN.....	82

GLOSARIO

Contingencia: Un evento inesperado tal como una falla o un circuito abierto. Una contingencia también se conoce como un evento no programado.

Circuito abierto: Un punto en un circuito que interrumpe el flujo de corriente sin causar flujo de corriente de falla.

Falla: Las fallas son básicamente cortocircuitos. Las fallas son causadas por daños en los dieléctricos de los sistemas de aislamiento y se pueden categorizar como auto-correctibles, temporales y permanentes. Una falla auto-correctible se extinguirá a sí misma sin ninguna intervención externa. Una falla temporal es un cortocircuito que desaparecerá si es desenergizado y después es nuevamente energizado. Una falla permanente es un cortocircuito que persistirá hasta que sea reparado por medio de la intervención humana.

Corte: Un corte ocurre cuando un equipo es desenergizado. Los cortes pueden ser tanto programados como no programados. Los cortes programados son conocidos con anticipación mientras que los cortes no programados son el resultado de contingencias.

Interrupción momentánea: Una interrupción momentánea ocurre cuando un cliente es desenergizado por una cantidad de tiempo menor a unos pocos minutos.

Evento de interrupción momentánea: Un evento de interrupción momentánea consiste de una o más interrupciones momentáneas dentro de un intervalo de tiempo de varios minutos.

Interrupción sostenida: Una interrupción sostenida ocurre cuando un cliente es desenergizado por más de unos cuantos minutos. La mayoría de las interrupciones sostenidas resultan de circuitos abiertos y fallas

INTRODUCCIÓN

Una prioridad de las empresas de distribución es satisfacer los requerimientos de seguridad, confiabilidad y calidad en el suministro de energía eléctrica. Esto se puede lograr a través de algunos subsistemas asociados a la red de distribución, entre los cuales, el sistema de protección es el más importante debido a su capacidad de eliminar y aislar fallas. En lo que respecta a la confiabilidad del sistema, satisfacer la carga demandada por los clientes, con un suministro continuo de energía, es requerido con el objetivo de mejorar los índices de confiabilidad y reducir la energía no suministrada (ENS). Para lograr esto, se hace necesaria la automatización en el sistema de distribución con el fin de aislar las fallas dentro del sistema tan rápido como sea posible, ofreciendo además la posibilidad de que la GD pueda operar en modo aislado, la cual es una importante función requerida para las futuras Smart Grids [1].

Con el objetivo de lograr un adecuado balance entre los recursos financieros y los requerimientos técnicos de la red, se debe considerar un análisis de costo-beneficio del sistema de protecciones. Bajo estas condiciones, la empresa de distribución tiene la tarea de satisfacer dos objetivos en conflicto: minimizar los costos económicos y maximizar la confiabilidad de la red. Sin embargo, la consecución de dichos objetivos depende considerablemente de dos variables: la cantidad de dispositivos de protección a utilizar y la localización de los mismos dentro de la red. De este modo, el propósito de este trabajo es tratar con la planeación de sistemas de protección basados en reconectores normalmente cerrados (RNCs) con el fin de proporcionar esquemas de protecciones con diferente cantidad y ubicación de los dispositivos dentro de la red. Cabe resaltar que los RNCs son dispositivos capaces de aislar secciones afectadas por alguna falla y también pueden ser usados para permitir la operación aislada de redes con GD por medio de acciones automáticas logrando así el restablecimiento del servicio de energía eléctrica a ciertas zonas de la red de distribución.

El problema de ubicación óptima de dispositivos de protección ha sido estudiado desde los enfoques de optimización mono-objetivo y multi-objetivo teniendo en cuenta la capacidad de la generación distribuida para operar en modo aislado. Considerando el enfoque mono-objetivo, el algoritmo de búsqueda tabu reactivo es implementado en [2] para resolver un problema de minimización de costos modelado a través de un problema de programación no lineal entero mixto con variables reales y binarias. Además, en [3] se presenta una nueva estructura para el algoritmo de evolución diferencial convencional para resolver la ubicación óptima de reconectores por medio de la minimización de una función objetivo compuesta por cuatro índices de confiabilidad. Tomando en cuenta la ubicación óptima de generadores distribuidos junto con dispositivos de protección, en [4] los alimentadores de una red son equipados con generadores distribuidos limitados

en capacidad de generación, mientras un algoritmo genético personalizado es usado con el propósito de minimizar un índice de confiabilidad compuesto.

Los estudios mencionados anteriormente tratan los problemas de optimización de la confiabilidad con uno de los siguientes enfoques: i) minimizando los costos de inversión mientras se satisfacen restricciones de confiabilidad y ii) minimizando las interrupciones de energía a los clientes sujeto a restricciones de costos [5]. No obstante, la toma de decisiones en la planeación de sistemas de protección debería ser tratada como un problema de optimización multi-objetivo debido al conflicto que se genera cuando se busca la maximización de la confiabilidad y la minimización de los costos, ya que la mejora de uno de los objetivos conlleva al deterioro del otro.

Cuando se trabaja con el enfoque multi-objetivo, se pueden considerar dos formas de tratar con el problema. Por un lado, el problema de optimización multi-objetivo es transformado en un problema de optimización mono-objetivo por medio de métodos tales como “weighted-sum approach” y “ ϵ -constraint method” [6]. Sin embargo, dicha transformación es a menudo subjetiva a quien está encargado de la toma de decisiones y además requiere de información precisa acerca de la relación que tienen las funciones objetivo entre sí. Por otro lado, un enfoque más confiable es primero encontrar un conjunto óptimo de Pareto compuesto de múltiples soluciones y entonces escoger una solución a partir de dicho conjunto utilizando información conveniente o suposiciones sobre el sistema eléctrico.

Considerando este enfoque, existen algunos trabajos que usan el concepto de óptimo de Pareto en la planeación de sistemas de protección. Una metodología para optimización multi-objetivo de la ubicación de dispositivos de protección con el fin de minimizar los índices SAIDI, SAIFI y MAIFI_E simultáneamente es propuesta en [7]. Los autores utilizan el algoritmo genético de ordenamiento no dominado (NSGA II) en la búsqueda de las mejores soluciones, de manera similar como en [8], donde el problema trata con la minimización del costo de instalación de seccionadores al mismo tiempo que mejora los índices SAIDI y ECOST. Utilizando una metaheurística diferente, el sistema multi-objetivo de colonia de hormigas (MACS) es usado en [9] para la ubicación óptima de interruptores y dispositivos de protección en sistemas de distribución a través de la minimización de SAIFI, SAIDI y los costos totales.

En este trabajo, el objetivo general es el desarrollo de un algoritmo de optimización multi-objetivo que encuentre la localización óptima de reconectores dentro de redes de distribución con generadores distribuidos. Para lograr lo anterior, inicialmente se propone un modelo matemático de optimización en función de los índices SAIDI y ENS y los costos de inversión en los dispositivos de protección. Con el fin de resolver el modelo matemático definido se realiza un proceso de optimización basado en el concepto de dominancia de Pareto, el cual proporciona múltiples soluciones no dominadas con diferentes cantidades y

localizaciones de reconectores normalmente cerrados dentro de la red de distribución. Debido a que la ubicación óptima de dispositivos de protección es un problema combinatorio complejo con características de no linealidad, discontinuidad y no diferenciabilidad [4], [9], [10], resolver este tipo de problemas con métodos tradicionales (por ejemplo, programación lineal y no lineal) es difícil. Así, se recurre a la utilización de métodos metaheurísticos, tales como el algoritmo genético de ordenamiento no dominado (NSGA-II) [11], como una alternativa apropiada para lograr soluciones eficientes. Para evaluar el funcionamiento del proceso de optimización desarrollado, este es aplicado a la red eléctrica “Roy Billinton Test System” (RBTS) a través de simulaciones enlazadas entre MATLAB y PowerFactory a partir del procedimiento de intercambio automático de datos presentado en [12], para así obtener un conjunto de soluciones perteneciente a una superficie de Pareto. Una vez comprobado el correcto funcionamiento del proceso de optimización, se lo utiliza para encontrar la ubicación óptima de reconectores normalmente cerrados dentro de la red eléctrica del campus de la Universidad de Nariño en una estructura de microrred. Finalmente, se aplican diferentes técnicas de optimización multi-objetivo con el fin de validar los resultados obtenidos.

El desarrollo de esta investigación tiene como aportes los siguientes aspectos:

- Aunque existen metodologías multi-objetivo para tratar con el problema de planeación óptima de reconectores en redes sin GD, la cantidad de trabajos que incluyan GD con un enfoque multi-objetivo es reducida, por lo cual este trabajo considera estos aspectos de manera simultánea.
- En la mayoría de investigaciones dentro del campo de planeación de redes de distribución se utilizan únicamente sistemas estándar para la prueba de las metodologías. En este trabajo se pretende realizar pruebas en sistemas estándar y posteriormente utilizar la metodología para la ubicación de reconectores dentro de la red eléctrica del campus de la Universidad de Nariño en una estructura de microrred.
- Debido a que en gran parte de la literatura especializada la generación distribuida es tratada como una fuente constante de energía sin tener en cuenta su aleatoriedad, en este trabajo se utilizan medidas de potencial solar dentro del campus de la Universidad de Nariño lo que brinda un tratamiento más real del problema.
- Los resultados obtenidos con el enfoque propuesto pueden servir como valores de referencia para futuros trabajos, con el fin de verificar la validez de nuevas metodologías.

Este documento está compuesto por 4 secciones distribuidas de la siguiente manera: marco teórico, metodología, casos de estudio y resultados, conclusiones. Un breve contenido de cada sección es descrito a continuación:

- En la sección 1 se presenta la revisión bibliográfica y un recorrido conceptual donde se abordan conceptos sobre diferentes temáticas fundamentales para el desarrollo de este trabajo de investigación tales como: confiabilidad de redes eléctricas, modo aislado de la generación distribuida, optimización multi-objetivo y metaheurísticas.
- En la sección 2 se describe la metodología utilizada en donde se formula el modelo matemático de optimización, se compara algunas técnicas metaheurísticas y se describe el algoritmo utilizado en el proceso de optimización.
- En la sección 3 se aplica el proceso de optimización a través de simulaciones de dos casos de estudio y se analizan los resultados obtenidos.

Finalmente, en la sección 4 se presenta las conclusiones de esta investigación, además se menciona el posible trabajo a futuro y algunas recomendaciones importantes

1. MARCO TEÓRICO

1.1. CONFIABILIDAD DE REDES DE DISTRIBUCIÓN

La confiabilidad de una red de distribución está relacionada principalmente con fallas en los equipos e interrupciones en el suministro de energía hacia los clientes. En condiciones normales de operación, todos los equipos deberían estar energizados y todos los clientes deberían contar con un suministro de energía continuo. Eventos programados y no programados desestabilizan las condiciones normales de operación y pueden conducir a cortes o interrupciones del servicio, lo cual deteriora la confiabilidad de la red de distribución. Algunas definiciones claves relacionadas con la confiabilidad de la distribución incluyen [5]:

- **Contingencia:** Un evento inesperado tal como una falla o un circuito abierto. Una contingencia también se conoce como un evento no programado.
- **Circuito abierto:** Un punto en un circuito que interrumpe el flujo de corriente sin causar flujo de corriente de falla.
- **Falla:** Las fallas son básicamente cortocircuitos. Las fallas son causadas por daños en los dieléctricos de los sistemas de aislamiento y se pueden categorizar como auto-correctibles, temporales y permanentes. Una falla auto-correctible se extinguirá a sí misma sin ninguna intervención externa. Una falla temporal es un cortocircuito que desaparecerá si es desenergizado y después es nuevamente energizado. Una falla permanente es un cortocircuito que persistirá hasta que sea reparado por medio de la intervención humana.
- **Corte:** Un corte ocurre cuando un equipo es desenergizado. Los cortes pueden ser tanto programados como no programados. Los cortes programados son conocidos con anticipación mientras que los cortes no programados son el resultado de contingencias.
- **Interrupción momentánea:** Una interrupción momentánea ocurre cuando un cliente es desenergizado por una cantidad de tiempo menor a unos pocos minutos.
- **Evento de interrupción momentánea:** Un evento de interrupción momentánea consiste de una o más interrupciones momentáneas dentro de un intervalo de tiempo de varios minutos.

- **Interrupción sostenida:** Una interrupción sostenida ocurre cuando un cliente es desenergizado por más de unos cuantos minutos. La mayoría de las interrupciones sostenidas resultan de circuitos abiertos y fallas.

En un sentido estricto los clientes no experimentan cortes de energía. Los clientes experimentan interrupciones de energía. La máxima duración de una interrupción momentánea varía de empresa a empresa, pero esta típicamente entre uno y cinco minutos.

1.1.1. DISPONIBILIDAD

La disponibilidad es la probabilidad de que algo se encuentre energizado. Este es el aspecto más básico de la confiabilidad y es generalmente medido en porcentaje o en por unidad. El complemento de la disponibilidad es la indisponibilidad.

La indisponibilidad puede ser calculada directamente de la información relacionada con la duración de las interrupciones. Por ejemplo, si un cliente experimenta 15 horas de energía interrumpida en un año (8760 horas), la indisponibilidad es igual a $15 \div 8760 = 0.17\%$. De lo anterior, la disponibilidad es igual a $100\% - 0.17\% = 99.83\%$.

1.1.2. ÍNDICES DE CONFIABILIDAD

Los índices de confiabilidad son agregaciones estadísticas de datos de confiabilidad para un conjunto de cargas, componentes o clientes bien definidos. La mayoría de los índices de confiabilidad son valores promedio de alguna característica en particular de la confiabilidad para un sistema completo, una región de operación, un territorio de servicio de una subestación o un alimentador.

A continuación se proporciona la definición de algunos índices de confiabilidad con base en el estándar IEEE 1366-2003 [15].

1.1.2.1. Índices de confiabilidad basados en el cliente

Son los índices de confiabilidad más ampliamente utilizados, los cuales son valores promedio que ponderan a cada cliente de igual manera. Estos índices tienen ciertas limitaciones pero generalmente son considerados buenas medidas agregadas de confiabilidad y son a menudo utilizados como punto de referencia en cuanto a confiabilidad y objetivos de mejora. Las fórmulas para algunos de estos índices se muestran a continuación (interrupciones se refiere a interrupciones sostenidas):

- System Average Interruption Frequency Index:

$$SAIFI = \frac{\text{Numero total de clientes interrumpidos}}{\text{Numero total de clientes atendidos}} \quad \text{interrupciones/año}$$

$$SAIFI = \frac{\sum N_i}{N_T} \quad (1)$$

- System Average Interruption Duration Index:

$$SAIDI = \frac{\sum \text{Duracion de las interrupciones a los clientes}}{\text{Numero total de clientes atendidos}} \quad \text{horas/año}$$

$$SAIDI = \frac{\sum (r_i * N_i)}{N_T} \quad (2)$$

- Customer Average Interruption Duration Index:

$$CAIDI = \frac{\sum \text{Duracion de las interrupciones a los clientes}}{\text{Numero total de clientes interrumpidos}} \quad \text{horas}$$

$$CAIDI = \frac{\sum (r_i * N_i)}{\sum N_i} \quad (3)$$

donde:

N_i = Número total de clientes con interrupción del servicio.

N_T =Número total de clientes atendidos.

r_i =Tiempo de restauración del servicio.

SAIFI es una de medida del número promedio de veces que un cliente del sistema experimenta una interrupción sostenida durante un año (o el periodo de tiempo bajo estudio). Para un numero constante de clientes, la única manera de mejorar SAIFI es reduciendo el número de interrupciones sostenidas experimentadas por los clientes.

SAIDI es una medida de la cantidad de horas de interrupción que un cliente experimenta sobre el curso de un año (o el periodo de tiempo bajo estudio). Para un número fijo de clientes, SAIDI puede ser mejorado reduciendo el número de interrupciones sostenidas o reduciendo la duración de dichas interrupciones.

Puesto que estos dos factores reflejan mejoras en la confiabilidad, una reducción en SAIDI indica un mejoramiento de la confiabilidad.

CAIDI es una medida del tiempo promedio requerido para restaurar el servicio, es decir el tiempo promedio que dura una interrupción y es utilizado como una medida del tiempo de respuesta por parte de la empresa de distribución a contingencias en el sistema. CAIDI puede ser mejorado reduciendo la duración de las interrupciones o también por medio del incremento del número de interrupciones de corta duración. Por consiguiente, una reducción en CAIDI no necesariamente refleja una mejora en la confiabilidad del sistema.

1.1.2.2. Índices de confiabilidad basados en la energía del sistema

- Energy Not Supplied:

$$ENS = \sum_{i=1}^{N_T} P_i * U_i \quad \frac{MWh}{año} \quad (4)$$

- Average Energy Not Supplied:

$$AENS = \frac{ENS}{N_T} \quad \frac{MWh}{Cliente - año} \quad (5)$$

donde:

P_i = Carga promedio conectada al punto de consumo i .

U_i = Tiempo de interrupción promedio por cliente.

ENS representa la cantidad total de energía promedio no suministrada a las cargas del sistema. ENS es un índice de gran importancia debido a que los sistemas de potencia son en realidad sistemas de energía y es de gran utilidad para propósitos de planeación de sistemas tanto en la valoración económica como en la evaluación de confiabilidad.

AENS es la cantidad promedio de energía no suministrada para todos los clientes.

1.2. MODO AISLADO DE LA GENERACIÓN DISTRIBUIDA

La capacidad de operación en isla es una de las propiedades más sobresalientes de una red de distribución equipada con generación distribuida debido a que esta característica puede ofrecer un suministro de energía confiable e ininterrumpido a ciertas cargas. Esta propiedad permite al sistema la creación de microrredes con la capacidad de operar en modo “off-grid” cuando surgen fallas en la red de distribución principal. Esto puede hacerse posible por medio del uso de interruptores y dispositivos de protección (por ejemplo reconectores normalmente cerrados). Aunque el modo isla aun no es ampliamente aceptado, la implementación de islas intencionales con generación distribuida es un área de investigación actual tratada continuamente por estándares tales como el IEEE 1547-2003 [16], los cuales están bajo consideración para futuras revisiones.

En lo que respecta a perturbaciones, cuando una falla se presenta en una red de distribución equipada con generación distribuida, dicha falla puede ser energizada tanto desde el transformador de la subestación como desde los generadores distribuidos y por lo tanto se hace necesaria una coordinación precisa entre los dispositivos de protección. Las fallas en coordinación incrementan la dificultad en la evaluación de confiabilidad de la red por lo que este trabajo supone que, en condiciones normales de operación, la red de distribución funciona como una red radial típica y la generación distribuida únicamente suministra energía cuando una falla ocurre en la red. Esta suposición es establecida debido a que en este estudio se realiza el análisis de las mejoras que puede proveer la generación distribuida en la confiabilidad del sistema, más no en la reducción del consumo de la red principal que puede lograrse al tener generadores adicionales. En consecuencia, para una falla en cualquier parte de la red, únicamente puede operar el reconector más cercano aguas arriba.

Para ilustrar la operación en modo isla con la suposición anterior, se presenta el alimentador radial equipado con generación distribuida mostrado en la Figura 1. En condiciones normales, la red de distribución principal es la única fuente que suministra energía a las cargas $L1$, $L2$ y $L3$, mientras que la generación distribuida no proporciona energía. Ahora, se asume que una falla surge entre las barras $B1$ y $B2$ causando la apertura del reconector (**R**). Después de esto, las cargas $L2$ y $L3$ son aisladas de la red principal formando una isla junto con la unidad de generación distribuida (**DG**). La generación distribuida debería ser capaz de proporcionar energía a la carga total $LT = L2 + L3$, mientras la red retorna a condiciones normales. Cuando la isla es establecida, uno de los siguientes casos puede ocurrir:

- i) La potencia suministrada por la generación distribuida (P_{DG}) es igual a la potencia consumida por LT (P_T), lo cual no necesita acciones y es el caso más eficiente.

- ii) P_{DG} no es suficiente para satisfacer P_T ($P_{DG} < P_T$), por lo que un deslastre de carga es requerido con el fin de mantener el balance de suministro-demanda, causando así un incremento en la energía no suministrada (ENS).
- iii) P_{DG} excede P_T ($P_{DG} > P_T$), por lo que deben considerarse acciones como el almacenamiento o eliminación (“dumping”) del exceso de energía o la regulación automática de la generación.

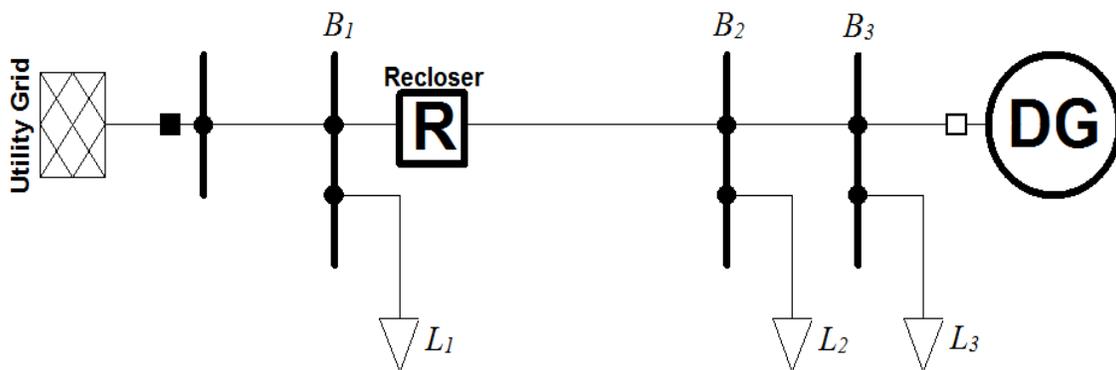


Figura 1. Ejemplo ilustrativo de un alimentador con generación distribuida.

Teniendo en cuenta lo anterior, una inadecuada ubicación de reconectadores puede resultar en la formación de islas ineficientes ya sea con excesiva o insuficiente generación, por lo que el aporte a la confiabilidad proporcionada por la generación distribuida no es aprovechada de la mejor manera. Por consiguiente, la ubicación eficiente de reconectadores es requerida con el fin de asegurar islas eficientes y en consecuencia maximizar los beneficios de usar generación distribuida.

1.3. OPTIMIZACIÓN MULTI-OBJETIVO Y OPTIMALIDAD DE PARETO

Cuando un problema de optimización involucra más de una función objetivo (como por ejemplo la minimización de índices de confiabilidad y la reducción de costos de inversión en equipos en la red), la labor de encontrar una o más soluciones óptimas al problema se conoce como optimización multi-objetivo. La mayoría de los problemas de búsqueda y optimización reales involucran múltiples objetivos de manera natural en donde cada uno de los objetivos es tratado con la misma

importancia. Diferentes soluciones al problema pueden producir escenarios de conflicto entre los diferentes objetivos, es decir, una solución que represente un valor extremo (óptimo) con respecto a un objetivo puede requerir el deterioro en los demás objetivos. Esto no permite la selección de una solución que sea óptima para solo uno de los objetivos.

Aunque muchos de los problemas relacionados con la toma de decisiones son tratados como problemas mono-objetivo, incluir todos los aspectos del problema en un solo objetivo es en muchas ocasiones una tarea difícil. Así, un enfoque diferente implica definir un problema de optimización con múltiples objetivos a través de un vector de funciones que incluya un determinado número de objetivos en conflicto a ser maximizados o minimizados. Sin pérdida de generalidad, se asume que dichos objetivos van a ser minimizados, de tal manera que el problema de optimización puede ser expresado en su forma general como [6]

$$\begin{aligned}
 & \text{Min} && f_m(X), && m = 1, 2, \dots, M; \\
 & \text{subject to} && g_j(X) \geq 0, && j = 1, 2, \dots, J; \\
 & && h_k(X) = 0, && k = 1, 2, \dots, K; \\
 & && x_i^{(L)} \leq x_i \leq x_i^{(U)}, && i = 1, 2, \dots, n.
 \end{aligned} \tag{6}$$

donde M , J y K son el número de funciones objetivo, restricciones de desigualdad y restricciones de igualdad, respectivamente, y $X = (x_1, x_2, \dots, x_n)^T$ es un vector de n variables de decisión. Los valores $x_i^{(L)}$ y $x_i^{(U)}$ definen los límites inferior y superior del espacio de decisión que restringe las variables de decisión.

En problemas de optimización multi-objetivo donde los objetivos están en conflicto entre sí, no existe una única solución que simultáneamente optimice todas las funciones objetivo. En cambio, el concepto más comúnmente adoptado para este tipo de problemas es la optimalidad de Pareto [17], en donde, para problemas de minimización (como el tratado en este trabajo), un vector factible de variables de decisión X^* es óptimo de Pareto si no existe otro X tal que $f_i(X) \leq f_i(X^*)$ para todo $i = 1, 2, \dots, M$ y $f_j(X) < f_j(X^*)$ para al menos un j . Casi siempre, este enfoque proporciona un conjunto de múltiples soluciones en lugar de una sola solución. Ese conjunto de soluciones es llamado el conjunto óptimo de Pareto y los vectores X^* que pertenecen a este conjunto son llamados soluciones no dominadas. Además, la imagen del conjunto óptimo de Pareto bajo las funciones objetivo conforma el frente de Pareto.

Puesto que en un problema de optimización multi-objetivo surgen múltiples soluciones, se debe establecer un mecanismo para evaluar una función de optimalidad o *fitness relativa*. De esta manera, el concepto de dominancia de Pareto ha sido ampliamente utilizado para cumplir con esta tarea y guiar la búsqueda hacia el frente de Pareto. Las condiciones que deben cumplirse para que una solución $X^{(1)}$ domine a otra solución $X^{(2)}$ están definidas por [6]

1. La solución $X^{(1)}$ no es peor que la solución $X^{(2)}$ en todos los objetivos.
2. La solución $X^{(1)}$ es estrictamente mejor que $X^{(2)}$ en al menos un objetivo.

Puesto que la dominancia de Pareto es un método utilizado para comparar soluciones en problemas de optimización multi-objetivo, este concepto es utilizado en la mayoría de algoritmos con el propósito de buscar soluciones no dominadas y alcanzar el frente de Pareto.

1.4. METAHEURÍSTICAS

Un gran número de problemas de optimización reales en ciencia, ingeniería, economía y negocios son complejos y difíciles de resolver. En muchas ocasiones, dichos problemas no pueden ser resueltos de manera exacta en un tiempo razonable. Así, el uso de algoritmos aproximados es la principal alternativa para resolver esta clase de problemas.

Los algoritmos aproximados se pueden descomponer en dos clases: heurísticas específicas y metaheurísticas. Las heurísticas específicas dependen del problema y son diseñadas y aplicables a un problema en particular. Las metaheurísticas en cambio, representan algoritmos aproximados más generales que pueden ser aplicables a una gran variedad de problemas de optimización. Las metaheurísticas resuelven casos de problemas que se cree son difíciles, en general, explorando un espacio de búsqueda generalmente grande de soluciones. Estos algoritmos logran esa tarea reduciendo el tamaño efectivo del espacio de búsqueda y explorando ese espacio de manera eficiente.

Las metaheurísticas tienen tres propósitos generales [18]:

- Solucionar problemas con mayor rapidez.
- Solucionar problemas complejos.
- Obtener algoritmos robustos.

Además, el diseño y la implementación de las metaheurísticas es simple y los algoritmos son muy flexibles. Las metaheurísticas pueden ser basadas en una única solución o basadas en una población de soluciones.

Las metaheurísticas basadas en una única solución mejoran una sola solución durante todo el proceso de optimización por medio de trayectorias a través del espacio de búsqueda del problema tratado. Dichas trayectorias son ejecutadas mediante procedimientos iterativos que se mueven de una solución actual a otra. Algunos de los principales algoritmos basados en una única solución son la búsqueda local (local search - probablemente uno de los métodos metaheurísticos más antiguos y simples [19]), “Simulated Annealing” que surge de los trabajos de S. Kirkpatrick et al. [20] and V. Cerny [21] y “Tabu Search” propuesto por Glover en 1989 [22].

Con respecto a las metaheurísticas basadas en una población de soluciones, estas pueden ser vistas como un proceso de mejoramiento iterativo dentro de una población de soluciones. Aquí se genera una población inicial y después se produce una nueva población de soluciones a partir de la población inicial, para finalmente integrar la nueva población dentro de la población actual usando algún procedimiento de selección. El proceso de búsqueda es detenido cuando un criterio de parada es satisfecho. Algoritmos tales como algoritmos evolutivos [23], [24], [25], [26], [27], búsqueda dispersa (“Scatter search”) [28], optimización por enjambre de Partículas (PSO, por sus siglas en inglés) [29], pertenecen a esta clase de metaheurísticas.

2. METODOLOGÍA

2.1. FORMULACIÓN DEL MODELO MATEMÁTICO

Uno de los propósitos de los dispositivos de protección es contribuir a la mejora de ciertos índices de confiabilidad, procurando un suministro continuo de energía a las cargas. Para lograr esta meta, deben realizarse inversiones económicas dependiendo del funcionamiento que la empresa de distribución de energía desea tener en la red. En este trabajo se propone la minimización de los índices SAIDI y ENS dentro del problema de optimización junto con una función que incluye los costos de inversión y operación del sistema de protecciones. El índice SAIDI es seleccionado debido a que, además de ser el índice de confiabilidad más comúnmente usado por las empresas de energía, la realización de inversiones en confiabilidad basadas únicamente en este índice han mostrado también mejoras en los índices SAIFI y MAIFI_E [5]. Además, puesto que índices tales como SAIFI dependen de las interrupciones que los clientes perciben, al trabajar con la conformación de islas con generación distribuida, los clientes siguen percibiendo interrupciones mientras las islas son establecidas. Luego, el índice de frecuencia no es considerado apropiado en esta investigación.

El problema tratado tiene funciones objetivo en conflicto debido a que mejoras en la confiabilidad de la red usualmente requieren de una alta inversión económica, mientras que por otro lado un sistema de protección de bajo costo puede conducir a inadecuados índices de confiabilidad. De esta manera, no existe una única solución que simultáneamente minimice las tres funciones objetivo por lo que un enfoque de optimización basado en el concepto de dominancia de Pareto es utilizado. Esto con el fin de encontrar un conjunto de múltiples soluciones no dominadas entre sí. El problema de optimización multi-objetivo es definido basado en la forma general mostrada en (6) y esta descrito por

$$\begin{aligned} & \min && SAIDI(X), ENS(X), EUAC(X) \\ & \text{subject to} && 1 - \frac{EUAC(X)}{EUAC_{max}} \geq 0, \quad (7) \\ & && x_i \in \{0, 1\} \end{aligned}$$

donde,

$$SAIDI = \frac{\sum_{i=1}^k ACIT_i C_i}{\sum_{i=1}^k C_i} \quad (8)$$

$$ENS = \sum_{i=1}^k ACIT_i Pd_i \quad (9)$$

$$EUAC = AOC + \left[\frac{d_r(1 + d_r)^{l_t}}{(1 + d_r)^{l_t} - 1} \right] R_p N_r \quad (10)$$

Aquí, $ACIT_i$ es el tiempo de interrupción por cliente promedio del punto de carga i , C_i es el número de clientes en el punto de carga i , Pd_i es la cantidad de energía no suministrada cuando el punto de carga i es desconectado y k es el número total de cargas en la red de distribución. Con respecto a la función de costos, $EUAC$ es el costo anual uniforme equivalente, donde AOC es el costo anual de operación, R_p es el costo de un solo reconectador, N_r es el número de reconectores ubicados en la red de distribución y la expresión dentro de los corchetes representa un factor de anualización que esta compuesto por una tasa de descuento d_r y el tiempo de vida útil de los reconectores l_t . Además, $EUAC_{max}$ es el máximo $EUAC$ que la empresa de distribución está dispuesta a invertir en el mejoramiento de la confiabilidad de la red. Por último, las n variables de decisión que componen el vector $X = (x_1, x_2, \dots, x_n)^T$ son variables binarias las cuales representan la existencia ($x_i = 1$) o ausencia ($x_i = 0$) de un reconectador en la i – ésima rama de la red de distribución.

2.2. COMPARACION DE ALGUNAS METAHEURISTICAS

Como se mencionó en el Capítulo 1.3, cuando se trabaja con problemas de optimización multi-objetivo utilizando el concepto de dominancia de Pareto, es común que al buscar soluciones al problema se obtenga un grupo de múltiples soluciones (conjunto óptimo de Pareto) en lugar de una sola solución. Debido a lo anterior, el uso de técnicas metaheurísticas basadas en una población de soluciones es un enfoque adecuado para tratar con este tipo de problemas ya que con una única ejecución del algoritmo, el resultado o salida es un conjunto de múltiples soluciones. Esto representa una gran ventaja con respecto a los algoritmos basados en una única solución, con los que se debería ejecutar el algoritmo varias veces con el fin de encontrar diferentes soluciones al problema.

Ahora, analizando el problema de optimización formulado en la Sección 2.1 se puede ver que las variables de decisión ($X = (x_1, x_2, \dots, x_n)^T$) están codificadas utilizando variables discretas, más concretamente variables binarias, que representan la existencia o ausencia de un reconector en una determinada rama de la red de distribución. Por lo tanto, la formulación propuesta es un problema de optimización combinatoria multi-objetivo (POCMO) en donde se busca encontrar un conjunto de diferentes arreglos o soluciones (cantidad de reconectores y ubicación) que brinden un equilibrio entre los múltiples objetivos simultáneamente. Cabe resaltar que el espacio de búsqueda en POCMOs es finito [30] y para el problema descrito por (7),(8),(9) y (10), el espacio de búsqueda está conformado por 2^n posibles combinaciones, donde n es el número de ramas del circuito.

En este punto es valioso señalar que los POCMOs no han sido ampliamente estudiados en comparación con los problemas de optimización multi-objetivo en espacios continuos, para los que la mayoría de las metaheurísticas han sido diseñadas [31]. Es así que es difícil encontrar problemas de prueba que representen estrictamente un POCMO (con múltiples objetivos y variables de decisión discretas). Por lo tanto, se han seleccionado problemas de prueba con variables de decisión continuas, pero los algoritmos probados han sido utilizados con codificación binaria para así probar la eficiencia de los operadores discretos de cada algoritmo. Lo anterior se realiza como una manera de eludir la carencia de reportes de amplia difusión de problemas de prueba y de algoritmos para tratar con POCMOs.

De esta manera, se han seleccionado tres algoritmos de optimización multi-objetivo con el fin de comparar su funcionamiento: NSGA-II [11], NSDE [32] y MOPSO [33].

2.2.1. NON-DOMINATED SORTING GENETIC ALGORITHM (NSGA-II)

NSGA-II es un algoritmo propuesto por K. Deb *et al.* [11], [34], que en muchos aspectos, no tiene similitud con el algoritmo original NSGA [35]. El procedimiento realizado por el algoritmo NSGA-II se resume de la siguiente manera. Inicialmente, se crea una población P de N soluciones aleatorias. Esta población es clasificada en diferentes niveles de no dominancia usando el concepto de dominancia de Pareto. A cada solución se asigna un valor fitness o rango r igual a su nivel de no dominancia (1 es el mejor nivel). Después se utiliza un operador de selección llamado "Crowded Tournament", con el cual una solución i gana el torneo a otra solución j si cualquiera de las siguientes condiciones se cumple:

1. Si la solución i tiene mejor rango, esto es, $r_i < r_j$.

2. Si las dos soluciones tienen el mismo rango pero la solución i tiene mayor "Crowding Distance" que la solución j .

En la condición 2, "Crowding Distance" se refiere a una medida del espacio de búsqueda alrededor de i que no es ocupado por otra solución de la población. Luego, aquellas soluciones con muchos individuos alrededor de su espacio de búsqueda tendrán un valor de "Crowding Distance" menor que aquellas que se encuentran rodeadas por pocos individuos, lo cual es un mecanismo útil para preservar la diversidad entre las soluciones encontradas.

Después de realizar la selección, se procede a aplicar operadores de recombinación y mutación para crear la población de descendientes Q de tamaño N . A continuación, se forma una población R compuesta de la combinación de las poblaciones P y Q y se realiza nuevamente una clasificación en diferentes niveles de no dominancia con los individuos de R . Como paso final, se seleccionan los mejores N individuos de R con base en el nivel de dominancia y el valor de "Crowding Distance" de cada individuo para así formar la población P_{G+1} de la siguiente generación y realizar todo el procedimiento nuevamente hasta lograr un criterio de parada.

2.2.2. NON-DOMINATED SORTING DIFFERENTIAL EVOLUTION (NSDE)

Los algoritmos basados en Evolución Diferencial son algoritmos de búsqueda directa basados en una población de soluciones y son utilizados para optimización global [36]. En cuanto al algoritmo NSDE, es una modificación del algoritmo NSGA-II y difiere en la fase de recombinación y mutación. A diferencia de las técnicas estocásticas utilizadas por NSGA-II, donde las perturbaciones o cambios en un individuo ocurren de acuerdo a una cantidad aleatoria, NSDE utiliza diferencias ponderadas entre vectores de solución para perturbar la población. Existen diferentes variantes para llevar a cabo la perturbación de la población, de las cuales, en esta investigación se utiliza la variante conocida como *DE/current-to-rand/1* [37] dada por

Seleccionar aleatoriamente $In_1, In_2, In_3 \in \{1, 2, \dots, N\}; In_1 \neq In_2 \neq In_3 \neq i$

$$u_{i,G+1} = x_{i,G} + K \cdot (x_{In_3,G} - x_{i,G}) + F \cdot (x_{In_1,G} - x_{In_2,G}) \quad (11)$$

La variante mostrada en (11), y en general el algoritmo NSDE, están diseñados para trabajar sobre espacios de búsqueda continuos por lo que se debe buscar una forma de adaptar este algoritmo con el fin de usarlo con variables de decisión codificadas de forma binaria. De esta manera, se escoge el enfoque utilizado en [38], donde los operadores de suma y resta utilizados en evolución diferencial son

reemplazados por los operadores lógicos de unión (\cup) y or-exclusivo (\oplus). De esta manera la variante de evolución diferencial utilizada en este trabajo es

Seleccionar aleatoriamente $In_1, In_2, In_3 \in \{1, 2, \dots, N\}; In_1 \neq In_2 \neq In_3 \neq i$

$$u_{i,G+1} = x_{i,G} \cup (x_{In_3,G} \oplus x_{i,G}) \cup (x_{In_1,G} \oplus x_{In_2,G}) \quad (12)$$

2.2.3. MULTI-OBJECTIVE PARTICLE SWARM OPTIMIZATION (MOPSO)

“Particle Swarm Optimization” (PSO) es otra metaheurística basada en una población de soluciones y está inspirada en la inteligencia de enjambres [39]. Esta imita el comportamiento social de organismos naturales como bandadas o cardúmenes para encontrar lugares con suficiente alimento. En efecto, en esos enjambres surge un comportamiento coordinado utilizando movimientos locales sin ningún control central.

En el modelo básico, un enjambre está compuesto por N partículas ‘volando’ dentro de un espacio de búsqueda de dimensión D . Cada partícula i es una posible solución al problema y está representada por el vector X_i en el espacio de decisiones. Una partícula tiene su propia posición y velocidad, que en otras palabras son su dirección de vuelo y el tamaño de paso de la partícula. Cada partícula ajusta sucesivamente su posición X_i hacia el óptimo global de acuerdo a los siguientes factores: la mejor posición visitada por sí misma ($pbest_i$) denotada como p_i y la mejor posición visitada por algún miembro de todo el enjambre ($gbest$) denotado como g_i . De esta manera, (13) y (14) muestran las ecuaciones de movimiento utilizadas para ajustar la posición X_i en cada iteración, donde el subíndice d indica la d –ésima componente del vector de posición para cada partícula.

$$v_{i,d} = c_1 v_{i,d} + c_2 \cdot (p_{i,d} - x_{i,d}) + c_3 \cdot (g_{i,d} - x_{i,d}) \quad (13)$$

$$x_{i,d} = x_{i,d} + v_{i,d} \quad (14)$$

$$d \in \{1, 2, \dots, D\}.$$

En (13), c_1 es constante mientras que c_2 y c_3 son números aleatorios seleccionados en cada iteración de acuerdo a una distribución uniforme dentro del intervalo $[0, c_{max}]$. c_1 , c_2 y c_3 representan el peso que la partícula le da a su propio movimiento, a su mejor posición visitada y a la mejor posición visitada por algún miembro del enjambre, respectivamente.

Con respecto al uso de PSO en problemas de optimización multi-objetivo, se han hecho algunas propuestas con resultados prometedores [33], [40], [41], [42], [43], [44]. La principal dificultad para extender PSO a problemas multi-objetivo es encontrar una buena forma de seleccionar los individuos guías para cada partícula en el enjambre, es decir $pbest_i$ y $global_i$. En esta investigación se ha utilizado el enfoque propuesto en [45], en el que se describe un algoritmo PSO multi-objetivo basado exclusivamente en conceptos de dominancia de Pareto (llamado PB-MOPSO), evitando así introducir parámetros de ajuste como en otros algoritmos propuestos, por ejemplo el descrito en [33].

La mayor parte del procedimiento de optimización del PB-MOPSO es muy similar a la del modelo básico de PSO. Las partes cruciales del algoritmo PB-MOPSO son la selección de los guías $pbest_i$ y $global_i$. La selección de $pbest_i$ se realiza simplemente teniendo en cuenta que si la posición actual X_i domina a $pbest_i$, entonces $pbest_i$ es remplazado por X_i . Por otro lado, la selección de $global_i$ se realiza a partir de un conjunto A que es actualizado a cada iteración del algoritmo y está conformado por las posiciones (soluciones) no dominadas de las partículas que conforman el enjambre. Así para cada partícula i , se selecciona un $global_i$ del conjunto A a través del uso de alguna de las siguientes alternativas de selección: ROUNDS, RANDOM o PROB [45].

Al igual que el algoritmo NSDE, el BP-MOPSO y en general los algoritmos PSO multi-objetivo han sido desarrollados para trabajar con variables de decisión continuas. Por esto, en este trabajo se adapta el algoritmo PB-MOPSO a una forma que permita su utilización con variables de decisión codificadas de forma binaria. Así, con base en [46], donde los autores proponen una versión discreta con codificación binaria del algoritmo PSO para problemas de optimización mono-objetivo, se han realizado algunos cambios en (13) y (14). La forma de la ecuación de velocidad ($v_{i,d}$) permanece igual, excepto que ahora $p_{i,d}$ y $g_{i,d}$ son enteros en $[0,1]$. Además, ahora $v_{i,d}$ representa la probabilidad de que el bit $x_{i,d}$ tome el valor de uno. Por ejemplo, si $v_{i,d} = 0.25$, entonces hay una probabilidad del 25% de que $x_{i,d}$ sea un uno y un 75% de que sea un cero. Puesto que $v_{i,d}$ es una probabilidad, debe estar limitado por el intervalo $[0.0, 1.0]$, por lo que una transformación logística $S(v_{i,d})$ puede ser usada para lograr esta modificación. De esta manera, el cambio resultante en la posición de la partícula i es definido de la siguiente manera [46]:

$$\text{Si } (rand() < S(v_{i,d})), \text{ entonces } x_{i,d} = 1, \text{ sino, } x_{i,d} = 0$$

Donde, $rand()$ es un número aleatorio seleccionado de una distribución uniforme en el intervalo $[0.0, 1.0]$.

2.2.4. COMPARACIÓN DE RESULTADOS

Con el fin de realizar una evaluación cuantitativa del desempeño de un algoritmo multi-objetivo, se debe tener en cuenta que dos de las principales metas en optimización multi-objetivo son:

- 1) Encontrar soluciones tan cerca a las soluciones óptimas de Pareto como sea posible.
- 2) Encontrar soluciones tan diversas como sea posible dentro del frente de soluciones no dominadas obtenido.

Con el propósito de evaluar estas características, se han adoptado dos medidas denominadas Distancia generacional (DG) y espaciamento (SP). Adicionalmente, el tiempo de ejecución de cada algoritmo es evaluado utilizando el mismo hardware y la misma plataforma de programación, esto con el fin de comparar la velocidad de ejecución de cada uno de ellos.

2.2.4.1. Distancia generacional (DG)

Este concepto fue introducido por Van Veldhuizen Lamont [47] y es una medida de la distancia promedio entre los elementos del conjunto de soluciones no dominadas y las soluciones del conjunto óptimo de Pareto. La DG se define de la siguiente manera

$$DG = \frac{(\sum_{i=1}^{|Q|} d_i^p)^{1/p}}{|Q|} \quad (15)$$

donde Q es el conjunto de soluciones no dominadas encontradas. Para $p = 2$, el parametro d_i es la distancia Euclideana (en el espacio de objetivos) entre la solución i y el miembro más cercano del frente óptimo de Pareto. Así, la DG utilizada en este trabajo está dada por

$$DG = \frac{\sqrt{\sum_{i=1}^{|Q|} d_i^2}}{|Q|} \quad (16)$$

Cabe resaltar que un $DG = 0$ indica que todas las soluciones encontradas forman parte del frente óptimo de Pareto y cualquier otro valor indicará “que tan lejos” están las soluciones encontradas.

2.2.4.2. Espaciamiento (SP)

Schott en [48], sugirió una medida que es calculada con la distancia relativa entre soluciones consecutivas del conjunto de soluciones no dominadas de la siguiente manera

$$SP = \sqrt{\frac{1}{|Q|} \sum_{i=1}^{|Q|} (d_i - \bar{d})^2} \quad (17)$$

$$d_i = \min_{k \in Q \wedge k \neq i} \sum_{m=1}^M |f_m^i - f_m^k| \quad (18)$$

$$\bar{d} = \sum_{i=1}^{|Q|} \frac{d_i}{|Q|} \quad (19)$$

donde, f_m es la m-ésima función objetivo del problema con $m = \{1, 2, \dots, M\}$. SP da una medida de las desviaciones estándar de diferentes valores d_i , de modo que cuando las soluciones encontradas son uniformemente espaciadas, el valor de SP es pequeño. Así, un algoritmo que encuentre un conjunto de soluciones no dominadas con un valor pequeño de SP es mejor.

2.2.4.3. Problema de prueba 1

El primer problema de prueba utilizado en este trabajo es propuesto en [49] y es un caso de optimización bimodal conformado por dos funciones objetivo y con dos frentes óptimos de Pareto, uno global y otro local. Entonces, se pone a prueba la capacidad de los algoritmos para no quedar atrapados en óptimos locales. El problema está dado por

$$\text{Minimizar } f_1(x_1, x_2) = x_1 \quad (20)$$

$$\text{Minimizar } f_2(x_1, x_2) = \frac{g(x_2)}{x_1} \quad (21)$$

$$g(x_2) = 2.0 - \exp\left\{-\left(\frac{x_2 - 0.2}{0.004}\right)^2\right\} - 0.8 \exp\left\{-\left(\frac{x_2 - 0.6}{0.4}\right)^2\right\} \quad (22)$$

$$0.1 \leq x_1 \leq 1.0 \quad (23)$$

$$0.1 \leq x_2 \leq 1.0 \quad (24)$$

Para este problema de prueba, el número total de evaluaciones de cada función objetivo fue de 160000.

Las Figuras 2, 3 y 4 muestran los resultados gráficos de las soluciones producidas por los algoritmos NSGA-II, PB-MOPSO y NSDE para el problema de prueba 1. La línea continua muestra el frente óptimo de Pareto global.

Analizando las gráficas, de la Figura 2 se observa que el algoritmo NSGA-II presenta el mejor desempeño ya que todas las soluciones alcanzan el frente óptimo de Pareto y además existe una buena distribución de las soluciones por todo el frente. Con respecto a los resultados del algoritmo NSDE (Figura 3), a pesar de la buena distribución de las soluciones obtenidas, se ve claramente que no es capaz de alcanzar el frente óptimo de Pareto y al parecer las soluciones encontradas están en un frente de Pareto local. En cuanto al algoritmo PB-MOPSO, los resultados (Figura 4) muestran que algunas de las soluciones obtenidas por este algoritmo logran alcanzar el frente óptimo de Pareto, aunque no con una buena distribución de las soluciones dentro del frente y además con algunas soluciones que han quedado totalmente por fuera del frente óptimo de Pareto.

Las tablas 1, 2 y 3 presentan la comparación de resultados entre los tres algoritmos considerando las medidas descritas anteriormente. Se puede ver que el desempeño promedio de NSGA-II es el mejor con respecto a la medida de distancia generacional (DG). Aunque el valor promedio de DG para el PB-MOPSO es muy cercano, el hecho de que algunas soluciones no logren alcanzar el frente óptimo de Pareto (Figura 4) hace que la medida de DG se vea afectada, incrementando su valor con respecto al de NSGA-II. Debido a que las soluciones obtenidas con NSDE no están dentro del frente óptimo de Pareto (Figura 3), este algoritmo presenta un valor promedio de DG relativamente alto con respecto al logrado por los demás, mostrando así el más pobre desempeño de los tres.

Con respecto al espaciamiento (SP), NSGA-II también presenta el mejor desempeño promedio debido a la buena distribución de las soluciones obtenidas dentro del frente óptimo de Pareto. Para PB-MOPSO, y sobre todo para NSDE, la medida SP pierde un poco su significado debido a que no es de utilidad tener un conjunto de soluciones bien distribuidas (valor de SP bajo) mientras las soluciones obtenidas no logren alcanzar el frente óptimo de Pareto.

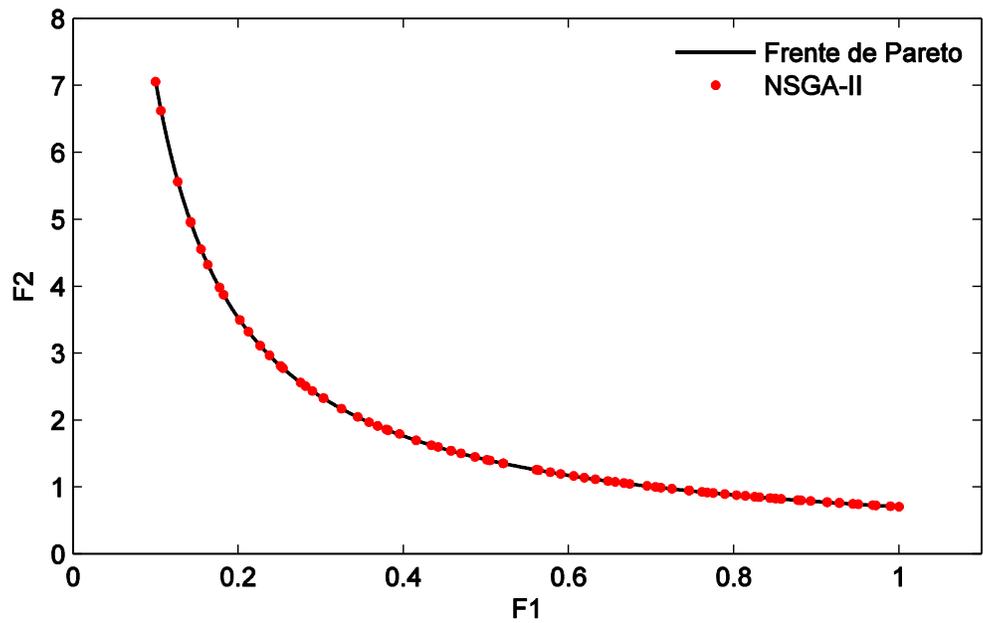


Figura 2. Frente de Pareto producido por el NSGA-II para el problema de prueba 1

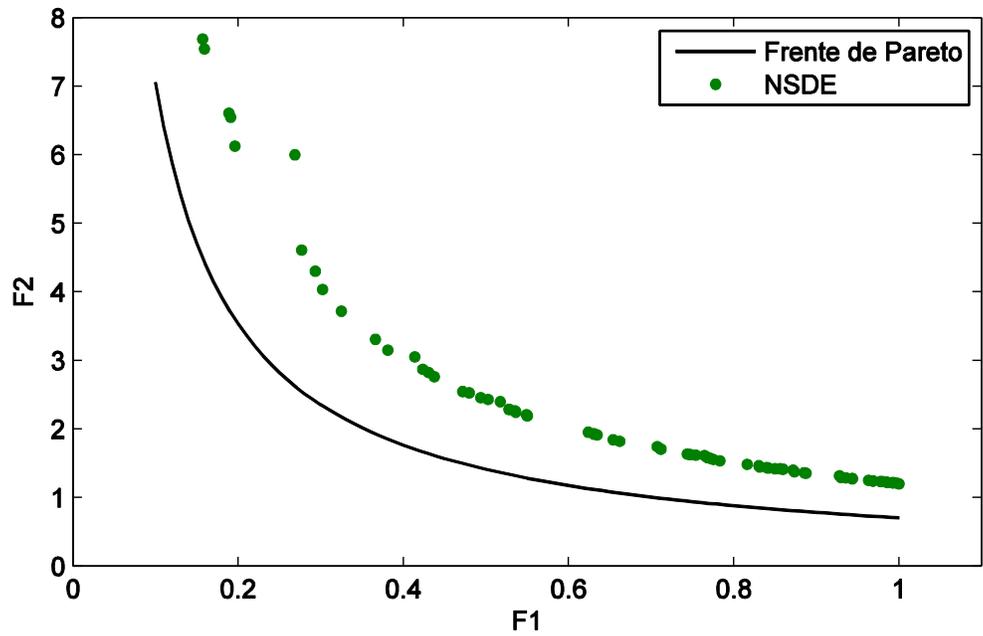


Figura 3. Frente de Pareto producido por el NSDE para el problema de prueba 1

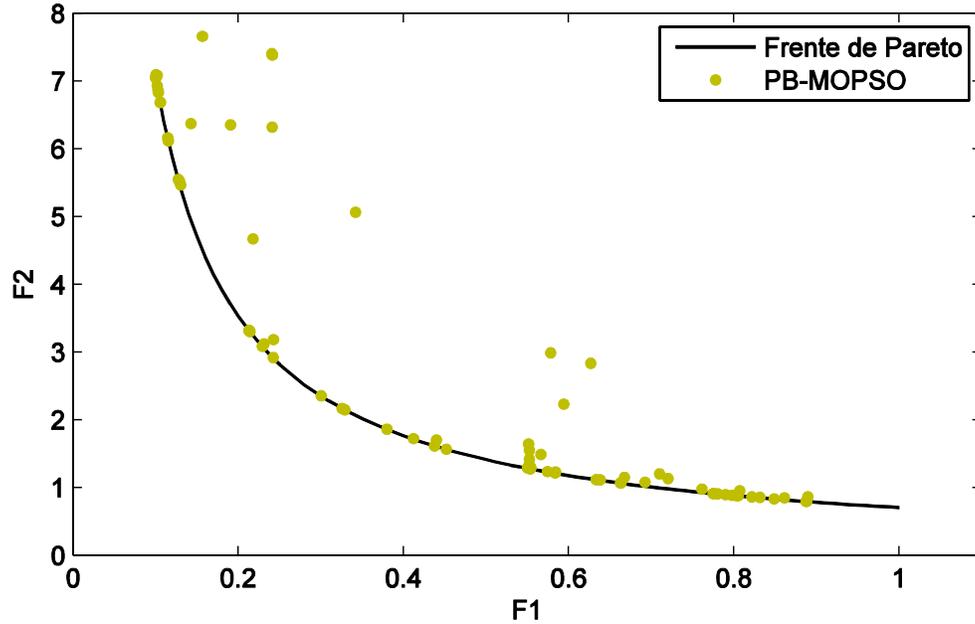


Figura 4. Frente de Pareto producido por el PB-MOPSO para el problema de prueba 1

DG	NSGA-II	PB-MOPSO	NSDE
Mejor	0,00218	0,01480	0,04894
Peor	0,04337	0,03767	0,06367
Media	0,02246	0,02895	0,05455
Mediana	0,02174	0,03146	0,05428
Desv.Estandar	0,02066	0,00601	0,00350

Tabla 1. Resultados de distancia generacional para el problema de prueba 1

A pesar de sus malos resultados, NSDE es el algoritmo de más rápida ejecución promedio. Comparando el tiempo tomado por NSGA-II y PB-MOPSO, que son los que lograron alcanzar el frente óptimo de Pareto, PB-MOPSO es más rápido en cuanto a ejecución por aproximadamente 8 segundos, siendo así el tiempo de ejecución el parámetro que desfavorece el desempeño del NSGA-II, aunque no en gran medida.

SP	NSGA-II	PB-MOPSO	NSDE
Mejor	0,00468	0,00489	0,00510
Peor	0,00654	0,01503	0,02999
Media	0,00558	0,00803	0,00916
Mediana	0,00562	0,00765	0,00768
Desv.Estandar	0,00045	0,00220	0,00474

Tabla 2. Resultados de espaciamento para el problema de prueba 1

Tiempo (s)	NSGA-II	PB-MOPSO	NSDE
Mejor	22,68794	14,86400	8,97939
Peor	24,75821	16,65144	9,61294
Media	23,38467	15,68892	9,13193
Mediana	23,35022	15,67920	9,11957
Desv.Estandar	0,56133	0,48223	0,11932

Tabla 3. Resultados de tiempo computacional en segundos para el problema de prueba 1

2.2.4.4. Problema de prueba 2

El segundo problema de prueba utilizado es el caso de optimización de un soporte plano de cuatro barras [50], descrito por

$$\text{Minimizar } f_1(X) = L(2x_1 + \sqrt{2}x_2 + \sqrt{x_3} + x_4) \quad (25)$$

$$\text{Minimizar } f_2(X) = \frac{FL}{E} \left(\frac{2}{x_1} + \frac{2\sqrt{2}}{x_2} + \frac{2\sqrt{2}}{x_3} + \frac{2}{x_4} \right) \quad (26)$$

$$\text{sujeto a} \quad (F/\sigma) \leq x_1 \leq 3(F/\sigma) \quad (27)$$

$$\sqrt{2}(F/\sigma) \leq x_2 \leq 3(F/\sigma) \quad (28)$$

$$\sqrt{2}(F/\sigma) \leq x_3 \leq 3(F/\sigma) \quad (29)$$

$$(F/\sigma) \leq x_4 \leq 3(F/\sigma) \quad (30)$$

donde $F = 10 \text{ kN}$, $E = 2 \cdot 10^5 \text{ kN/cm}^2$, $L = 200 \text{ cm}$ y $\sigma = 10 \text{ kN/cm}^2$.

Para este problema de prueba, el número total de evaluaciones de cada función objetivo fue de 160000.

Las Figuras 5, 6 y 7 muestran los resultados gráficos de las soluciones producidas por los algoritmos NSGA-II, PB-MOPSO y NSDE, respectivamente. La línea continua muestra el frente óptimo de Pareto global.

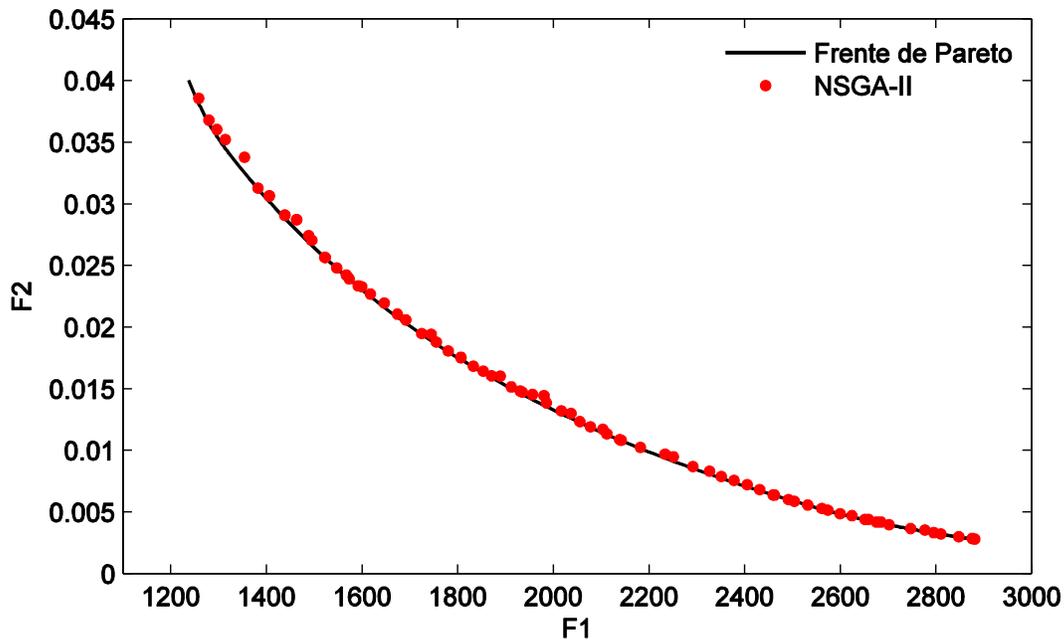


Figura 5. Frente de Pareto producido por el NSGA-II para el problema de prueba 2

Como se puede ver en la Figura 5, el algoritmo NSGA-II presenta el mejor desempeño debido a que las soluciones obtenidas alcanzan el frente óptimo de Pareto y además tiene una muy buena distribución a través de todo el frente. Por otro lado, el algoritmo NSDE (Figura 6) parece tratar de acercarse al frente de Pareto con una buena distribución de las soluciones en la parte derecha pero aun así no logra tener ninguna solución dentro del frente óptimo. Con respecto a PB-MOPSO (Figura 7), este algoritmo alcanza algunas soluciones dentro del frente óptimo (sobre todo en la parte central) pero aun deja muchas soluciones a una distancia considerable, además de dejar muchas áreas sin soluciones cercanas.

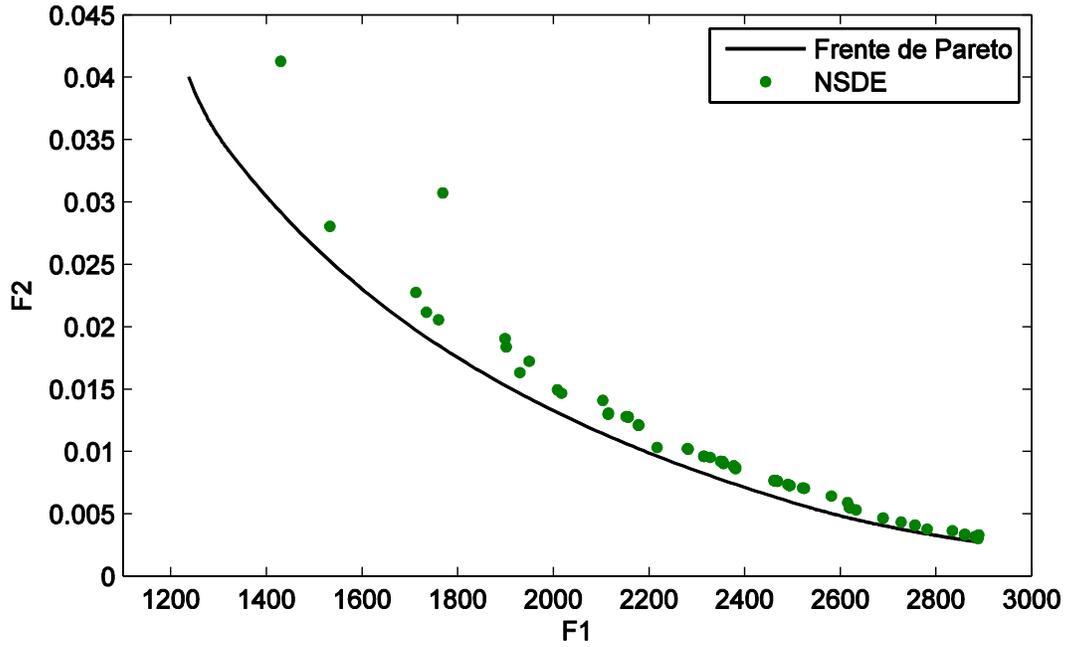


Figura 6. Frente de Pareto producido por el NSDE para el problema de prueba 2

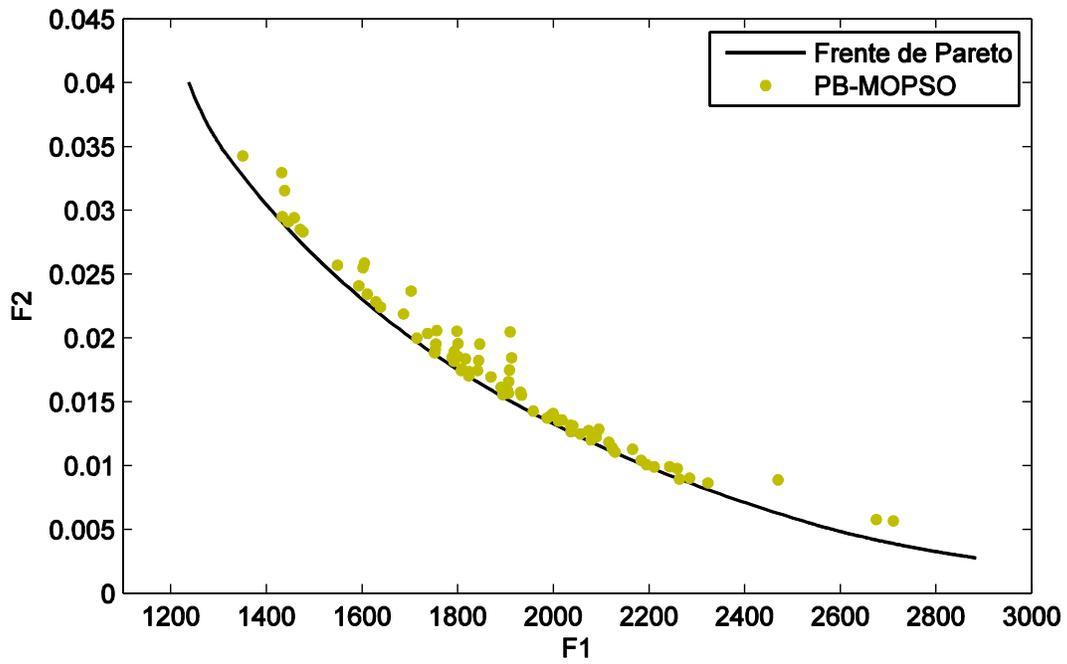


Figura 7. Frente de Pareto producido por el PB-MOPSO para el problema de prueba 2

Las Tablas 4, 5 y 6 presentan la comparación de resultados entre los tres algoritmos utilizados considerando las medidas propuestas. Para este caso, NSGA-II supera el funcionamiento de NSDE y PB-MOPSO con respecto a DG y SP lo cual corrobora el superior desempeño de NSGA-II tanto para obtener soluciones dentro del frente óptimo de Pareto como para distribuir de manera adecuada dichas soluciones dentro del frente. Además de la capacidad de obtener soluciones dentro del frente óptimo de Pareto, NSGA-II muestra un desempeño sobresaliente y muy superior en cuanto a la distribución de las soluciones, brindando soluciones distribuidas de manera muy eficiente por todo el frente de Pareto. Esto hace que la medida de SP sea muy inferior para NSGA-II comparado con los valores de NSDE y PB-MOPSO.

DG	NSGA-II	MOPSO	NSDE
Mejor	0,00897	0,01467	0,02530
Peor	0,01279	0,02179	0,04878
Media	0,01060	0,01793	0,03420
Mediana	0,01055	0,01797	0,03342
Desv.Estandar	0,00092	0,00181	0,00477

Tabla 4. Resultados de distancia generacional para el problema de prueba 2

SP	NSGA-II	MOPSO	NSDE
Mejor	0,00719	0,00844	0,00630
Peor	0,01088	0,03464	0,02937
Media	0,00908	0,01903	0,01471
Mediana	0,00913	0,01815	0,01383
Desv.Estandar	0,00087	0,00674	0,00534

Tabla 5. Resultados de espaciamiento para el problema de prueba 2

Tiempo (s)	NSGA-II	MOPSO	NSDE
Mejor	31,32548	13,98023	6,37968
Peor	32,44710	14,63067	6,81524
Media	31,48085	14,37627	6,44509
Mediana	31,41976	14,41598	6,43384
Desv.Estandar	0,20517	0,18787	0,07779

Tabla 6. Resultados de tiempo computacional en segundos para el problema de prueba 2

El único factor que está en contra del buen desempeño del NSGA-II es nuevamente el tiempo de ejecución del algoritmo que para este problema requiere

aproximadamente el doble del tiempo requerido por PB-MOPSO y es casi cinco veces el tiempo que toma NSDE, que tiene el menor tiempo promedio de los tres algoritmos.

2.2.4.5. Conclusiones de la comparación de resultados

De los resultados obtenidos con la comparación cuantitativa del desempeño de los algoritmos NSGA-II, NSDE y PB-MOPSO en los dos problemas de prueba utilizados en esta investigación, se encuentra que NSGA-II supera a NSDE y PB-MOPSO con valores promedio menores con respecto a las medidas de distancia generacional y espaciamento. De esta manera se muestra la capacidad de este algoritmo para cumplir con los dos principales objetivos de un algoritmo multi-objetivo: alcanzar el frente óptimo de Pareto y brindar diversas soluciones dentro del mismo. La única desventaja de NSGA-II es la mayor cantidad de tiempo que gasta durante el proceso de optimización con respecto a NSDE y PB-MOPSO. A pesar de lo anterior, lo más relevante es que el algoritmo sea capaz de encontrar soluciones óptimas, ya que para la aplicación resuelta en esta investigación, el proceso que más tiempo emplea es el de la evaluación de las funciones objetivo, siendo este mucho mayor en comparación con el tiempo de ejecución de la metaheurística.

Así, después de comparar el desempeño de estos tres algoritmos de optimización multi-objetivo, se selecciona a NSGA-II como el algoritmo que se utiliza en el proceso de optimización de la ubicación de reconectadores. Cabe recordar que la comparación de los algoritmos se ha realizado utilizando una codificación binaria de las variables de decisión con el fin de poner a prueba los operadores discretos y analizar su funcionamiento ante problemas de optimización combinatoria multi-objetivo, como el tratado en esta investigación.

A continuación se presenta una explicación más detallada del funcionamiento del algoritmo C-NSGA-II, aplicado al proceso de optimización del problema definido en (7). El funcionamiento es básicamente el mismo de NSGA-II únicamente que C-NSGA-II tiene la capacidad de trabajar con problemas que involucren restricciones, como el definido en este trabajo.

2.3. CONSTRAINED NON-DOMINATED SORTING GENETIC ALGORITHM (C-NSGA-II)

Los problemas relacionados con la ubicación óptima de dispositivos de protección tiene características de no linealidad, discontinuidad y no diferenciabilidad por lo que el uso de métodos tradicionales de optimización puede ser no factible. Además, el resultado de los métodos de optimización clásicos suele ser una única solución y no un conjunto de soluciones, como es requerido en problemas de

optimización multi-objetivo. Así, una alternativa factible para superar esta cuestión es usar un algoritmo evolutivo multi-objetivo (AEMO). Un AEMO utiliza un enfoque basado en una población de soluciones junto con el concepto de dominancia de Pareto con el fin de buscar múltiples soluciones no dominadas. En este trabajo, se utiliza el algoritmo “Constrained Non-Dominated Sorting Genetic Algorithm” (C-NSGA-II) [11] con el propósito de buscar soluciones del problema definido en (7). El C-NSGA-II utiliza las mismas dos propiedades clave del NSGA-II:

- i) Un enfoque de ordenamiento no dominado rápido para ordenar cada solución dentro de un frente no dominado \mathcal{F}_d ($d = 1, 2, \dots$) basado en un rango asignado d .
- ii) Una medida de distancia de hacinamiento entre soluciones (“Crowding distance”) utilizada para preservar la diversidad entre la población de soluciones.

La principal diferencia entre el C-NSGA-II y el NSGA-II convencional es que en el primero la definición usual de dominancia es remplazada por una condición de dominancia restringida. En este sentido, para decir que una solución $X^{(1)}$ domina con restricción una solución $X^{(2)}$, alguna de las siguientes condiciones debe ser cumplida:

1. La solución $X^{(1)}$ es factible mientras que la solución $X^{(2)}$ no lo es.
2. Tanto la solución $X^{(1)}$ como la solución $X^{(2)}$ son no factibles, pero la solución $X^{(1)}$ tiene una violación de la restricción menor.
3. Tanto la solución $X^{(1)}$ como la solución $X^{(2)}$ son factibles, y $X^{(1)}$ domina la solución $X^{(2)}$ en el sentido usual de dominancia definido en la sección 1.3.

Para ilustrar los anteriores conceptos, un pseudocódigo del C-NSGA-II es mostrado en Algoritmo 1 [11]. Primero, se crea una población inicial aleatoria P_0 compuesta de N individuos (cromosomas) X_N , cada uno de los cuales es un vector de decisión. Cada cadena binaria X_N es utilizada para localizar reconectores dentro de la red de distribución con base en el valor binario de cada variable de decisión (x_n). A continuación, una evaluación de la confiabilidad de la red es realizada en PowerFactory para cada configuración con el fin de obtener los valores de cada función objetivo. Después, las soluciones en la población son ordenadas en d conjuntos no dominados-no restringidos (NDR) \mathcal{F}_d usando la condición de dominancia restringida, de tal manera que, el frente \mathcal{F}_i es mejor que \mathcal{F}_j si $i < j$. Además, la “Crowding distance” es calculada para las soluciones en cada frente \mathcal{F}_d . Una vez realizado esto, se aplica un proceso de selección a la población por medio de un torneo restringido (“Constrained Tournament”). Con este operador de selección, dadas dos soluciones $X^{(1)}$ y $X^{(2)}$, la solución $X^{(1)}$ es escogida si cualquiera de las siguientes condiciones se cumple:

1. La solución $X^{(1)}$ pertenecer a un mejor conjunto NDR.
2. Las soluciones $X^{(1)}$ y $X^{(2)}$ pertenecen al mismo conjunto NDR, pero la solución $X^{(1)}$ tiene un valor mayor de “Crowding distance”.

La población descendiente Q_0 es producida por medio de los operadores genéticos usuales como cruce y mutación. Cuando se obtiene la población descendiente, se crea una nueva población $R_t = P_t \cup Q_t$. La evaluación de las funciones objetivo a partir de las soluciones en R_t es llevada a cabo nuevamente en PowerFactory. Entonces, R_t es ordenado en frentes NDR para así poder obtener la población de la siguiente generación. Cuando R_t es ordenada, se llena la población P_{t+1} con los elementos dentro del frente \mathcal{F}_1 (el mejor frente) solo si la suma de los elementos en P_{t+1} más la de los elementos en \mathcal{F}_1 es menor que N . El procedimiento mencionado anteriormente es repetido con los subsecuentes frentes hasta que el número de elementos en P_{t+1} sumado el número de elementos en \mathcal{F}_j sea mayor que N . Cuando esto ocurra, P_{t+1} no podrá incluir a todas las soluciones contenidas en \mathcal{F}_j . Por lo tanto, solo las $N - |P_{t+1}|$ soluciones de \mathcal{F}_j con el valor más grande de “Crowding distance” son seleccionadas para completar la población P_{t+1} . Finalmente, la población descendiente Q_{t+1} es creada por medio de la aplicación de los operadores de selección (“Constrained Tournament”), cruce y mutación a la población P_{t+1} .

La utilización de las herramientas ofrecidas por PowerFactory en el proceso de evaluación de las funciones objetivo es un aspecto destacable de esta investigación. Aunque el proceso de optimización puede ser realizado en el mismo software, la plataforma de programación de PowerFactory presenta algunas dificultades que podrían hacer que la codificación del algoritmo de optimización se convierta en una tarea difícil y tediosa de realizar. En este sentido, el enfoque de co-simulación usado en este trabajo saca provecho de un ambiente de programación simple y fácil como MATLAB con el fin de desarrollar el algoritmo de optimización, mientras que PowerFactory calcula los flujos de carga y los índices de confiabilidad de la red eléctrica seleccionada. No obstante, cabe resaltar que la co-simulación requiere mayor tiempo en la evaluación de las funciones objetivo con respecto al requerido solo por PowerFactory. Como un ejemplo, La tabla XXX muestra los tiempos requeridos en la evaluación de 10 individuos, en donde se aprecia que dicha evaluación consume menor tiempo cuando se utiliza únicamente PowerFactory.

Método\Tiempo [s]	Mejor	Peor	Media	Mediana	Des. Estándar
Power Factory	284,525	295,128	289,731	289,818	3,100
Co-simulación	312,235	322,653	317,574	316,927	2,934

Tabla 7. Tiempos de procesamiento: PowerFactory y Co-simulación

Algoritmo 1. C- NSGA-II

Inicializar población: $P_0 = (X_1^0, X_2^0, \dots, X_N^0)^T$

Evaluación de las funciones objetivos: Evaluación de confiabilidad para cada solución en P_0 .

Para $j = 1$ hasta N

$$f_1(X_j^0) = SAIDI(X_j^0); \quad f_2(X_j^0) = ENS(X_j^0); \quad f_3(X_j^0) = EUAC(X_j^0)$$

Fin

Fast non-constrain-dominated sorting: Clasificar P_0 en d conjuntos diferentes no restringidos no dominados \mathcal{F}_d .

Asignación local de “crowding distance”: Para cada solución j perteneciente a \mathcal{F}_d , asignar una medida de la densidad de soluciones en \mathcal{F}_d que rodean a la solución j .

Operador de selección “Constrained Tournament”: Escojer los padres de la población de descendientes Q_0 .

Cruce: Q_0 es creado con base en los padres escojidos.

Mutación: Alterar aleatoriamente las soluciones de Q_0

Para $t = 0$ hasta $(t - 1)$

Combinar poblaciones: $R_t = P_t \cup Q_t$

Evaluación de las funciones objetivo: Evaluación de confiabilidad para las soluciones en R_t

Fast non-constrain dominated sorting: Clasificar R_t en d conjuntos diferentes no restringidos no dominados \mathcal{F}_d .

Crear la nueva población: $P_{t+1} = \emptyset$, $j = 1$;

Mientras $|P_{t+1}| + |\mathcal{F}_j| < N$

$$P_{t+1} = P_{t+1} \cup \mathcal{F}_j;$$

$$j = j + 1;$$

Fin

Ordenar \mathcal{F}_j basado en “Crowding-distance”: Ordenar \mathcal{F}_j en orden descendente de acuerdo a la medida de “Crowding distance” de las soluciones

Completar P_{t+1} : Incluir las $(N - |P_{t+1}|)$ soluciones con los mayores valores de “Crowding distance” desde \mathcal{F}_j en P_{t+1} .

$$P_{t+1} = P_{t+1} \cup \mathcal{F}_j[1: (N - |P_{t+1}|)];$$

Crear la nueva población de descendientes Q_{t+1} : Aplicar los operadores de selección “Constrained tournament”, cruce y mutación a P_{t+1} para formar Q_{t+1} .

Fin

3. CASOS DE ESTUDIO Y RESULTADOS

3.1. CASO DE ESTUDIO 1

3.1.1. CIRCUITO DE PRUEBA “Roy Billinton Test System”

Con el objetivo de evaluar el funcionamiento de la metodología de optimización propuesta y mostrar su aplicación, se ha utilizado la red de distribución del bus 6 del circuito de prueba “Roy Billinton Test System (RBTS)”, desarrollada principalmente como red de prueba para estudios de confiabilidad. Esta red de distribución fue adecuada e implementada en PowerFactory (Figura 10) con base en los parámetros del sistema presentados en [51], en donde se puede encontrar una descripción detallada. Con el fin de corroborar la correcta implementación de este circuito en PowerFactory, se realiza una evaluación de confiabilidad para comparar los resultados entregados por el software con los valores de confiabilidad descritos en [51]. De esta manera, las Figuras 8 y 9 muestran los valores de algunos índices de confiabilidad entregados por Powerfactory y los presentados en [51], respectivamente, en donde se observa que los valores generados por el software son muy cercanos a los presentados en la literatura con lo que se comprueba la correcta implementación del circuito.

La red del bus 6 del RBTS tiene 41 cargas con una potencia pico de 20 MW y dos niveles de voltaje, uno de 33 kV y otro de 11 kV. La red radial original ha sido equipada con generadores distribuidos con el propósito de realizar simulaciones comparativas entre la red original y la red con dos niveles de penetración: 20% y 60% de generación distribuida.

----- System Summary -----			
System Average Interruption Frequency Index	:	SAIFI =	0,998689 1/Ca
Customer Average Interruption Frequency Index	:	CAIFI =	0,998689 1/Ca
System Average Interruption Duration Index	:	SAIDI =	6,630 h/Ca
Customer Average Interruption Duration Index	:	CAIDI =	6,639 h
Average Service Availability Index	:	ASAI =	0,9992431077
Average Service Unavailability Index	:	ASUI =	0,0007568923
Energy Not Supplied	:	ENS =	71,122 MWh/a

Figura 8. Resultados de la evaluación de confiabilidad en PowerFactory

<i>Index</i>	<i>Bus 3</i>	<i>Bus 5</i>	<i>Bus 6</i>
SAIFI (fr/ syst. cust)	0.3027	0.2325	1.0067
SAIDI (hr/ syst. cust)	3.4726	3.5512	6.6688
CAIDI (hr/ cust)	11.4691	15.2751	6.6247
ASAI	0.999604	0.999595	0.999239
EENS (MWh/yr)	66.68024	40.11936	72.81531

Figura 9. Indices de confiabilidad para el Bus 6 del RBTS

Un modelo de fallas es requerido para llevar a cabo el análisis de confiabilidad, por lo que se define un modelo estocástico de fallas para cada componente de la red utilizando los datos detallados en [52], en donde se listan las tasas de fallo y tiempos de reparación para transformadores, breakers, barras y líneas para cada nivel de voltaje.

Considerando la función de costo *EUAC* (Ecuación (10)), los valores utilizados para las constantes son los siguientes:

- $AOC = 400 \text{ USD}$
- $R_p = 18000 \text{ USD}$
- $d_r = 0.1 \text{ (10\%)}$
- $lt = 20 \text{ años}$

De esta manera el valor de *EUAC* para un solo reconfigurador instalado es de 2514 *USD*. Además, el valor de $EUAC_{max}$ es tomado como 26000 *USD*.

3.1.2. RESULTADOS CASO DE ESTUDIO 1

El C-NSGA-II ha sido implementado en MATLAB con el objetivo de encontrar la ubicación eficiente de reconfiguradores dentro de la red de distribución descrita anteriormente (Figura 10). La red es simulada en PowerFactory para calcular los valores de las funciones objetivo (SAIDI y ENS) de acuerdo con el modelo estocástico de fallas y flujos de potencia. El proceso de optimización resulta en el conjunto de soluciones mostradas en la Figura 11, en la que están representados tres casos de simulación, uno sin generación distribuida y dos con generación distribuida con penetraciones de 20% y 60%.

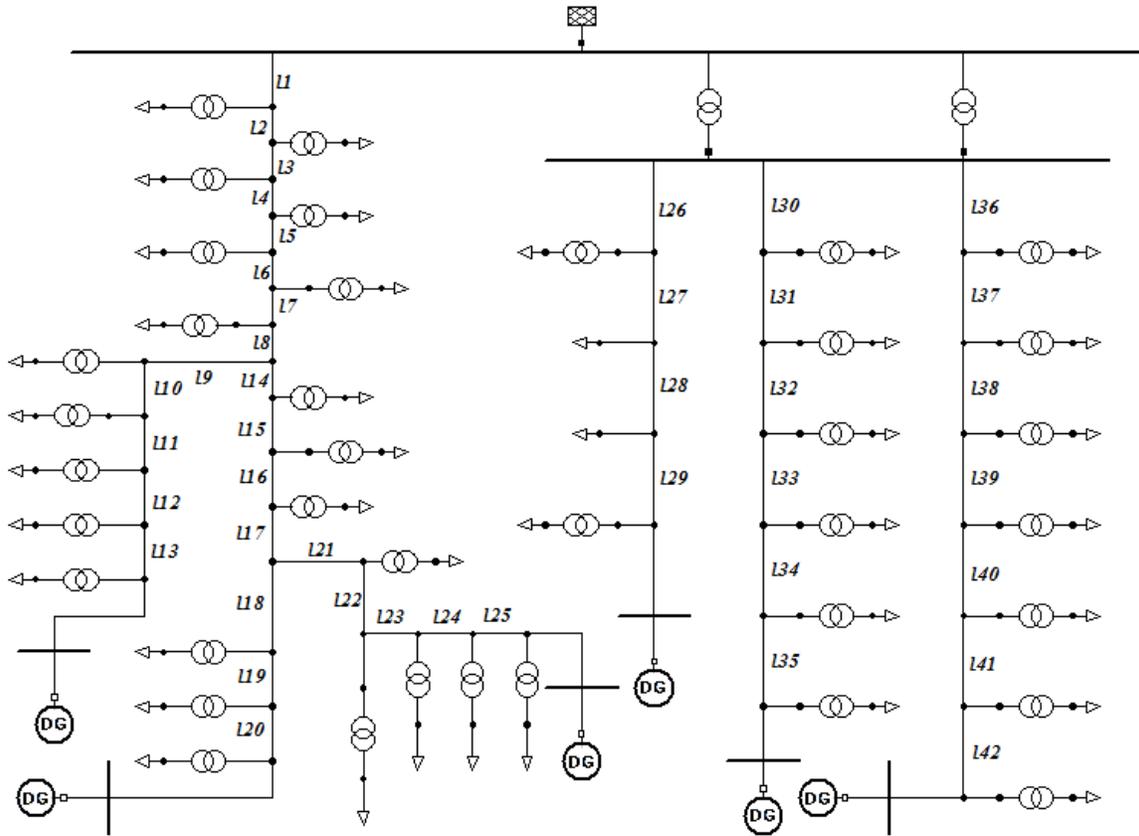


Figura 10. Red de distribución del bus 6 del circuito RBTS equipada con generación distribuida.

Para cada caso de simulación, se escoge tres soluciones representativas no restringidas-no dominadas que son presentadas en la Tabla 8. De estas soluciones, "A" representa la solución más económica ($EUAC = \$ 7542$), pero es la que produce menores mejoras en los índices SAIDI y ENS. Por otro lado, la solución "C" tiene los menores valores de SAIDI y ENS, pero esta solución requiere la inversión más alta ($EUAC = \$ 25140$), aunque aún satisface la restricción del problema. Por último, "B" representa una solución más asequible ($EUAC = \$ 15084$) con valores intermedios de SAIDI y ENS con respecto a las soluciones "A" y "C".

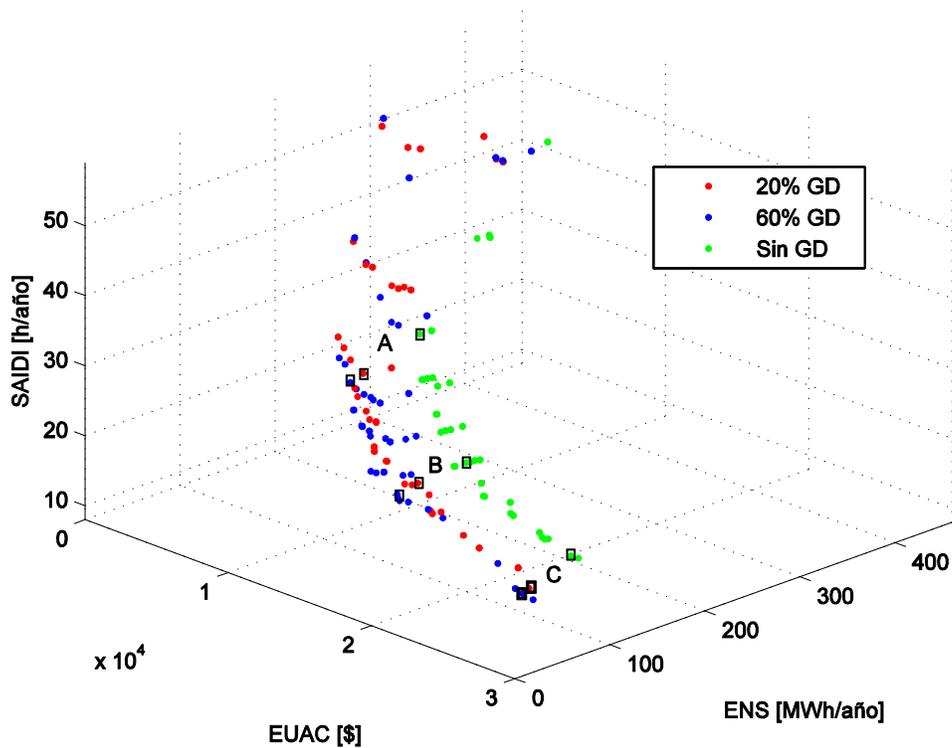


Figura 11. Conjunto de soluciones no dominadas para el caso de estudio 1

Observando la Figura 11 es evidente que SAIDI y ENS son funciones no lineales del número de re-conectores ubicados en la red de distribución. Más aun, el grado de mejora en dichos índices logrado por la adición de re-conectores, decrece a medida que la cantidad de re-conectores aumenta. Desde este punto de vista, tener múltiples soluciones es muy útil con el fin de analizar en qué momento un incremento en la inversión realizada no produce reducciones significativas en los valores de SAIDI y ENS. De esta manera, es posible encontrar puntos en donde los beneficios obtenidos por la adición de un re-conector no justifican la inversión a realizar.

Otro resultado importante obtenido con la adición de generadores distribuidos y la capacidad de funcionamiento en modo isla es que las soluciones son desplazadas hacia valores menores de SAIDI y ENS a medida que la penetración de generación distribuida aumenta.

Analizando las posiciones en la que los re-conectores son ubicados (Tabla 8), se puede notar que los alimentadores son segmentados eficientemente dependiendo del número de re-conectores que se vayan a instalar en la red de distribución.

CASO		SAIDI (horas/año)	ENS (MWh/año)	EUAC (\$)	Posición Reconectores
<i>i. 0%GD</i>	A	28.65	238.35	7542	12,130,136.
	B	19.15	173.23	15084	12,19,114,126,130,137.
	C	15.41	132.13	25140	12,19,114,117,126, 129,130,132,136,140.
<i>ii. 20%GD</i>	A	25.94	178.78	7542	17,130,137.
	B	18.70	122.57	15084	13,115,126,131,139,142.
	C	12.97	88.16	25140	13,19,115,122,126, 130,132,136,139,142.
<i>iii. 60%GD</i>	A	25.25	165.38	7542	18,130,136.
	B	17.70	101.44	15084	17,116,127,131,136,140.
	C	12.57	81.04	25140	17,19,121,127,131, 132,135,136,139,141.

Tabla 8. Ejemplos de soluciones no dominadas del proceso de optimización en el caso de estudio 1

Considerando la penetración de la generación distribuida, el proceso de optimización busca soluciones que ubiquen los reconectores cerca de las unidades de generación distribuida con el propósito de crear microrredes. Como ejemplo, se considera la solución “C” en la que el reconector ubicado en el segmento de línea 117 para el caso *i* es reubicado en los segmentos de línea 122 y 123 para los casos *ii* y *iii*, respectivamente. Esto permite la formación de una zona aislada (microrred), con pocas cargas aguas abajo del reconector. Así, cuando fallas permanentes surgen aguas arriba, una unidad de generación distribuida puede suministrar energía dentro de esta zona aislada y así la confiabilidad del sistema es mejorada.

Finalmente, comparando las soluciones que tienen la misma inversión (es decir, el mismo valor de *EUAC*) de los casos *ii* y *iii*, evidentemente el caso *iii* tiene soluciones con mejores valores de SAIDI y ENS que aquellos del caso *ii*. Como un ejemplo, comparando las soluciones “B” del caso *ii* (SAIDI=18.70, ENS=122.57) con “B” del caso *iii* (SAIDI=17.70, ENS=101.44), claramente los valores para el caso *iii* son menores que los del caso *ii*. En consecuencia, los resultados mostrados anteriormente indican que mejores soluciones pueden ser encontradas a medida que el nivel de penetración de la generación distribuida aumenta.

3.2. CASO DE ESTUDIO 2

3.2.1. RED ELECTRICA DEL CAMPUS UNIVERSIDAD DE NARIÑO

Una vez realizado el proceso de optimización sobre la red de prueba RBTS se procede a aplicar la metodología de optimización sobre la red eléctrica del campus de la Universidad de Nariño en una estructura de microrred. De esta manera la red actual del campus que cuenta con 9 transformadores con una capacidad instalada total de 930 kVA, ha sido equipada con cuatro generadores distribuidos como se muestra en la Figura 12. Toda la información técnica de la red eléctrica del campus ha sido obtenida de [53].

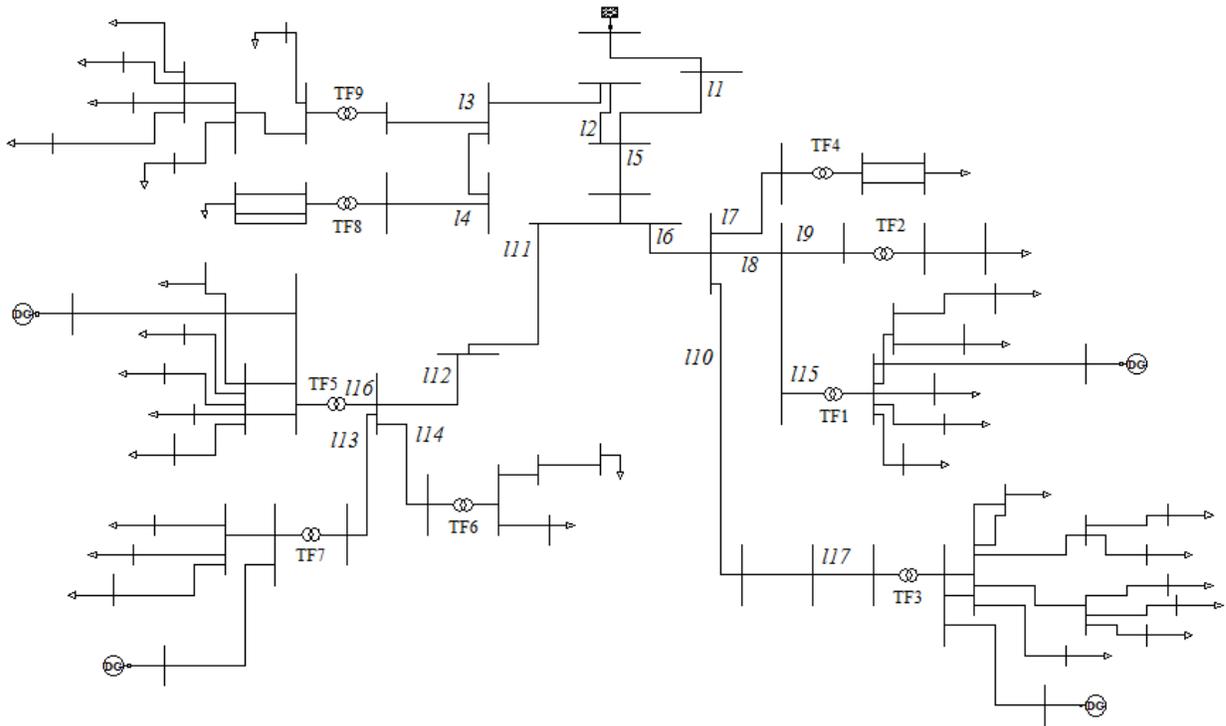


Figura 12. Red eléctrica del campus de la Universidad de Nariño equipada con generación distribuida.

La Tabla 9, muestra los valores promedio de potencia activa, reactiva y aparente para la red del campus de la Universidad de Nariño. En la quinta columna de la Tabla 9, se muestra el porcentaje de potencia aparente de cada transformador con respecto a la potencia aparente total (169836.97 VA). Este porcentaje se utiliza para analizar cuáles son las cargas que más demanda de potencia requieren por

parte de la red. Por ejemplo, las cargas aguas abajo del transformador TF5 son las que más potencia demandan de todo el campus, en cambio, las cargas aguas abajo del transformador TF6 son las que menor potencia demandan. Esta información se utilizó con el propósito de decidir el número de generadores distribuidos a ser ubicados dentro del campus, dando prioridad a las cargas de mayor consumo. De esta manera se decidió ubicar cuatro generadores distribuidos de la siguiente manera:

- El primer generador distribuido por el transformador TF5 (consume el 26.67% de la potencia aparente total)
- El segundo generador distribuido por los transformadores TF3 y TF4 (sumados consumen el 25.25% de la potencia aparente total)
- El tercer generador distribuido por los transformadores TF1 y TF2 (sumados consumen el 24.26% de la potencia aparente total)
- El cuarto generador distribuido por los transformadores TF6, TF7, TF8 y TF9 (sumados consumen el 23.8% de la potencia aparente total)

Transformador	P. Activa (W)	P. Reactiva (VAR)	P. Aparente (VA)	% P. Aparente
TF1	18882.8	5818.8	19759.01	11.63 %
TF2	18455	10930	21448.82	12.63 %
TF3	31801	18374.2	36727.57	21.62%
TF4	6170	0	6170	3.64%
TF5	43490	16279	46436.9	26.67%
TF6	4227	1690.8	4552.61	2.68%
TF7	16056	7043	17532.8	10.32%
TF8	9389	3325	9960.36	5.87%
TF9	7564.87	3602.36	8378.8	4.94%
TOTAL	156035.67	67063.16	169836.97	100%

Tabla 9. Valores promedio de potencia activa, reactiva y aparente para la red del campus de la Universidad de Nariño

Teniendo en cuenta que el consumo para cada conjunto de transformadores no difiere significativamente (el menor valor es de 23.8% del consumo total y el máximo de 26.67%), se decide seleccionar el mismo valor de potencia nominal para cada uno de los generadores. De este modo, para una penetración de GD del 20% se tiene una potencia de 33.96 kVA (20% de 169.8367 kVA) y por lo tanto a cada generador distribuido le corresponde una potencia nominal de 8.49 kVA. De igual manera, para una penetración del 60% de GD se tiene una potencia de

101.632 kVA con lo cual cada generador tendrá una potencia nominal de 25.4 kVA.

Debido a que no se cuenta con datos relacionados con la tasa de falla y los tiempos de reparación de los elementos de la red del campus, fue necesario seleccionar valores típicos encontrados en la literatura [5], que según el autor pueden servir como una guía apropiada para la comparación de diferentes diseños del sistema.

Considerando la función de costo $EUAC$, los valores utilizados para las constantes son iguales a los del caso 1, es decir:

- $AOC = 400 \text{ USD}$
- $R_p = 18000 \text{ USD}$
- $d_r = 0.1 \text{ (10\%)}$
- $lt = 20 \text{ años}$

Así, el valor de $EUAC$ para un solo reconectador instalado es de 2514 USD . Además, el valor de $EUAC_{max}$ es tomado como 26000 USD .

3.2.2. RESULTADOS CASO DE ESTUDIO 2

El algoritmo C-NSGA-II ha sido utilizado ahora para encontrar la ubicación óptima de reconectores en la red del campus de la Universidad de Nariño equipada con generadores distribuidos (Figura 12). Al igual que en el caso de estudio 1, los valores de las funciones objetivo (SAIDI y ENS) son obtenidos a partir de la evaluación de confiabilidad realizada en PowerFactory a través de una co-simulación con el algoritmo C-NSGA-II implementado en MATLAB. De esta manera, el proceso de optimización da como resultado el conjunto de soluciones mostradas en la Figura 13, en la que están representados tres casos de simulación, uno sin generación distribuida y dos con generación distribuida con penetraciones de 20% y 60%.

Para cada caso de simulación, se escoge tres soluciones representativas no restringidas-no dominadas que son presentadas en la Tabla 10. De estas soluciones, "A" representa la solución más económica ($EUAC = \$ 10056$), pero es la que produce menores mejoras en los índices SAIDI y ENS. Por otro lado, la solución "C" tiene los menores valores de SAIDI y ENS, pero esta solución requiere la inversión más alta ($EUAC = \$ 25140$), aunque aún satisface la restricción de la inversión máxima estipulada. Por último, "B" representa una solución más asequible ($EUAC = \$ 17598$) con valores intermedios de SAIDI y ENS con respecto a las soluciones "A" y "C".

La Figura 13 es similar a la obtenida en el caso de estudio 1 (Figura 11) y se muestra nuevamente que SAIDI y ENS son funciones no lineales del número de reconectores ubicados en la red de distribución, que el grado de mejora en dichos índices decrece a medida que la cantidad de reconectores aumenta y que la adición de generadores distribuidos junto con la capacidad de funcionamiento en modo isla hace que las soluciones se desplacen hacia valores menores de SAIDI y ENS a medida que la penetración de generación distribuida aumenta.

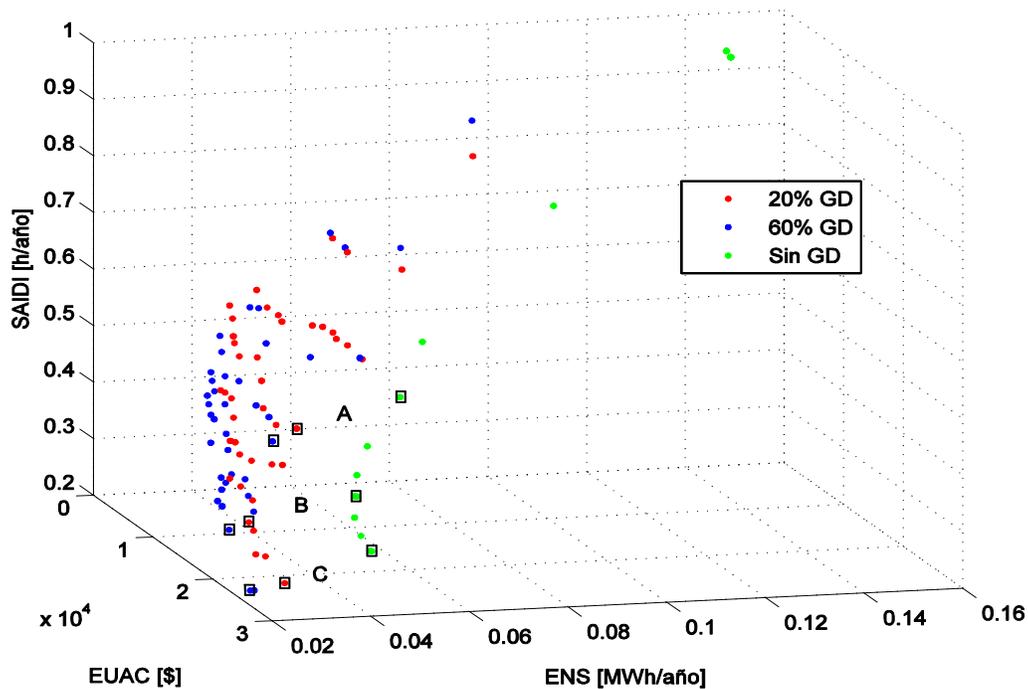


Figura 13. Conjunto de soluciones no dominadas para el caso de estudio 2

Considerando la penetración de la generación distribuida, se analiza la solución “B” (Tabla 10) de cada caso para mostrar como el proceso de optimización busca soluciones que ubiquen los reconectores cerca de las unidades de generación distribuida con el propósito de crear microrredes. Inicialmente se nota que el reconector ubicado en el segmento de línea *l14* para el caso *i* (0% GD) es reubicado en el segmento de línea *l16* para los casos *ii* y *iii*, esto debido a la posibilidad de formar una zona aislada gracias al generador distribuido ubicado aguas abajo de este segmento de línea. Por otro lado, se observa que el reconector ubicado en el segmento de línea *l7* para el caso *i* es reubicado en el segmento de línea *l6* para los casos *ii* y *iii*. Lo anterior se debe a que no se cuenta con un generador distribuido aguas abajo del segmento de línea *l7* y además a la

posibilidad formar una zona aislada de gran tamaño, aguas abajo del segmento de línea 16, de ser necesario gracias a la presencia de dos generadores distribuidos ubicados aguas abajo de los transformadores TF1 y TF3.

CASO		SAIDI (horas/año)	ENS (kWh/año)	EUAC (\$)	Posición Reconectores
<i>i. 0% GD</i>	A	0.4276	69.95	10056	12, 16, 18, 111.
	B	0.3146	52.40	17598	12, 17, 18, 110, 111, 113, 114.
	C	0.2762	46.08	25140	12, 13, 16, 17, 18, 19, 110, 111 113, 114.
<i>ii. 20% GD</i>	A	0.3804	49.05	10056	12, 16, 110, 111.
	B	0.2781	30.25	17598	12, 16, 110, 111, 113, 115, 116.
	C	0.2273	28.42	25140	12, 16, 17, 18, 110, 111, 113, 114, 115, 116.
<i>iii. 60% GD</i>	A	0.3596	44.15	10056	12, 18, 110, 111.
	B	0.2665	26.23	17598	12, 16, 18, 111, 113, 116, 117.
	C	0.217	21.42	25140	12, 13, 16, 18, 110, 111, 113, 115, 116, 117.

Tabla 10. Ejemplos de soluciones no dominadas del proceso de optimización en el caso de estudio 2

Igual que en el caso de estudio 1, la Tabla 10 muestra que se pueden encontrar mejores soluciones a medida que el nivel de penetración de generación distribuida aumenta, es decir, para una misma inversión en reconectores (el mismo valor de *EUAC*) las soluciones del caso *ii* presentan valores más bajos en los índices de confiabilidad SAIDI y ENS con respecto a las soluciones del caso *i*, y de la misma manera las soluciones del caso *iii* superan a las del caso *ii* reduciendo aún más los valores de SAIDI y ENS.

De esta manera se ha aplicado de forma correcta la metodología de optimización propuesta en este trabajo de investigación sobre la red eléctrica del campus de la Universidad de Nariño, mostrando que el proceso de optimización encuentra un conjunto de múltiples soluciones no-dominadas para cada nivel de penetración de generación distribuida. La toma de decisión sobre cual solución es la más adecuada dependerá de los límites en el capital disponible y los requerimientos técnicos definidos. Sin embargo, se ha mostrado que encontrar múltiples soluciones puede facilitar la toma de decisiones debido a que es posible encontrar puntos (soluciones) en donde los beneficios obtenidos, en cuanto a mejora de la confiabilidad por la adición de una cierta cantidad de reconectores, no justifican la inversión a realizar.

3.2.3. COMPARACIÓN DE RESULTADOS CON LOS ALGORITMOS NSDE Y PB-MOPSO.

En esta sección se hace una comparación de los resultados obtenidos con el algoritmo C-NSGA-II (Figura 13) y los resultados obtenidos con los algoritmos NSDE y PB-MOPSO para cada nivel de penetración de generación distribuida.

La Figura 14 muestra los resultados obtenidos por los tres algoritmos utilizados en esta investigación para una penetración del 0% de GD, en donde se evidencia que el algoritmo C-NSGA-II presenta mejores soluciones ya que cuenta con resultados que dominan muchas de las soluciones de NSDE y PB-MOPSO, además de tener una mejor distribución de las mismas. También, se puede ver que NSDE y PB-MOPSO logran alcanzar algunas de las soluciones obtenidas por C-NSGA-II aunque dejan muchas de las soluciones por fuera del frente alcanzado por C-NSGA-II. Por ejemplo, para el caso de NSDE se puede notar una mayor concentración de soluciones en la parte inferior del frente y en cambio para PB-MOPSO se aprecia una mayor concentración de soluciones en la parte central del frente.

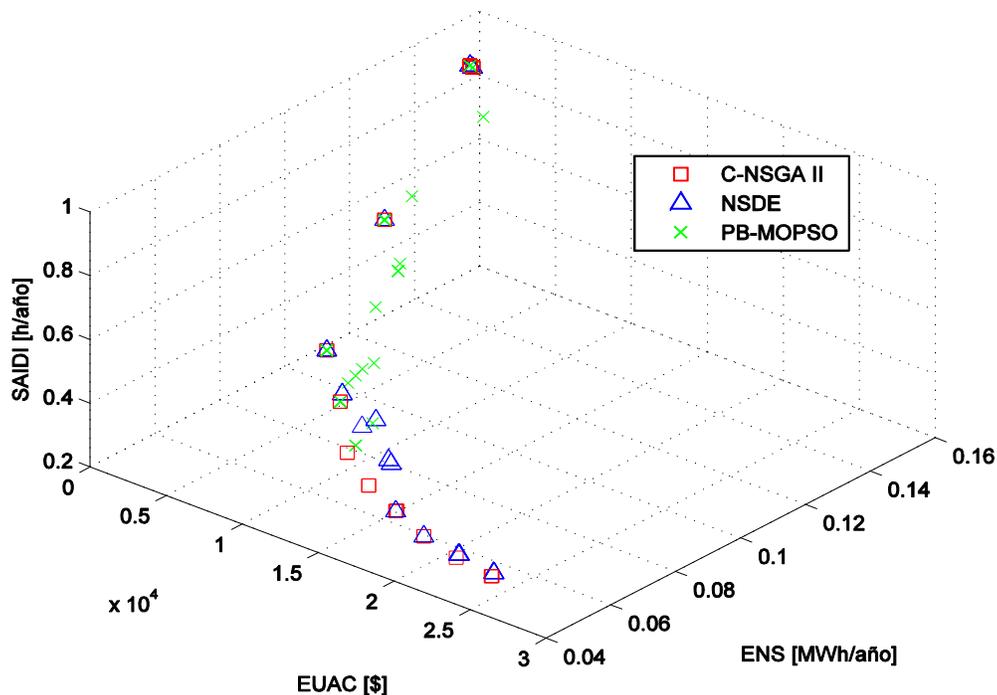


Figura 14. Resultados obtenidos para 0% de penetración de GD

La Figura 15 muestra nuevamente los resultados obtenidos por los algoritmos C-NSGA-II, NSDE y PB-MOPSO pero esta vez para un nivel de penetración de GD del 20%. Para este caso no se puede determinar a simple vista cuál algoritmo es el que encuentra mejores soluciones al problema de optimización, sin embargo, realizando un ordenamiento no dominado de todas las soluciones se logra establecer que todas las soluciones obtenidas por el C-NSGA-II son no dominadas por las soluciones alcanzadas por NSDE y PB-MOPSO. No obstante, el algoritmo NSDE, a pesar de encontrar muchas soluciones dominadas por las del C-NSGA-II, logra hallar un grupo de soluciones no dominadas que se encuentran en la parte inferior del frente, mostrando así un desempeño aceptable. Con respecto a PB-MOPSO, este muestra el desempeño más pobre de los tres algoritmos ya que una gran cantidad de soluciones obtenidas por este algoritmo son dominadas por las soluciones del C-NSGA-II y una reducida cantidad de soluciones alcanzaron el frente al que pertenecen las soluciones del C-NSGA-II.

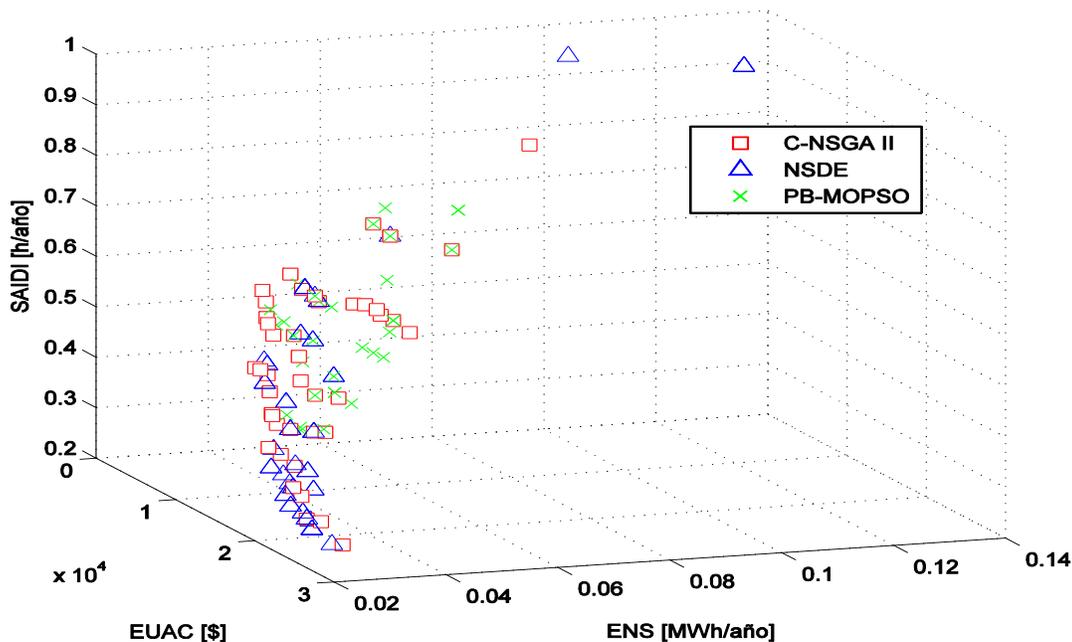


Figura 15. Resultados obtenidos para 20% de penetración de GD

Por último, la Figura 16 muestra la comparación de los resultados de los tres algoritmos utilizados para un nivel de penetración de 60% de GD. En la Figura 16 se puede apreciar un patrón similar al de la Figura 15, donde nuevamente las soluciones obtenidas por el C-NSGA-II son no dominadas por todas las demás soluciones. Con respecto a NSDE, muestra un desempeño muy similar al del caso anterior (20% de penetración de GD) alcanzando algunas soluciones no dominadas en la parte inferior del frente pero también con soluciones dominadas por las del C-NSGA-II. PB-MOPSO también muestra un desempeño similar al del

caso anterior, con muchas soluciones dominadas por las del C-NSGA-II y logrando muy pocas soluciones dentro del frente alcanzado por C-NSGA-II, además de que las soluciones se concentran principalmente en la parte central del frente.

Los anteriores resultados corroboran el mejor desempeño obtenido por el NSGA-II en la comparación de algoritmos realizada en el Capítulo 2.2, mostrando nuevamente su capacidad para encontrar soluciones no dominadas con una buena distribución dentro del frente alcanzado.

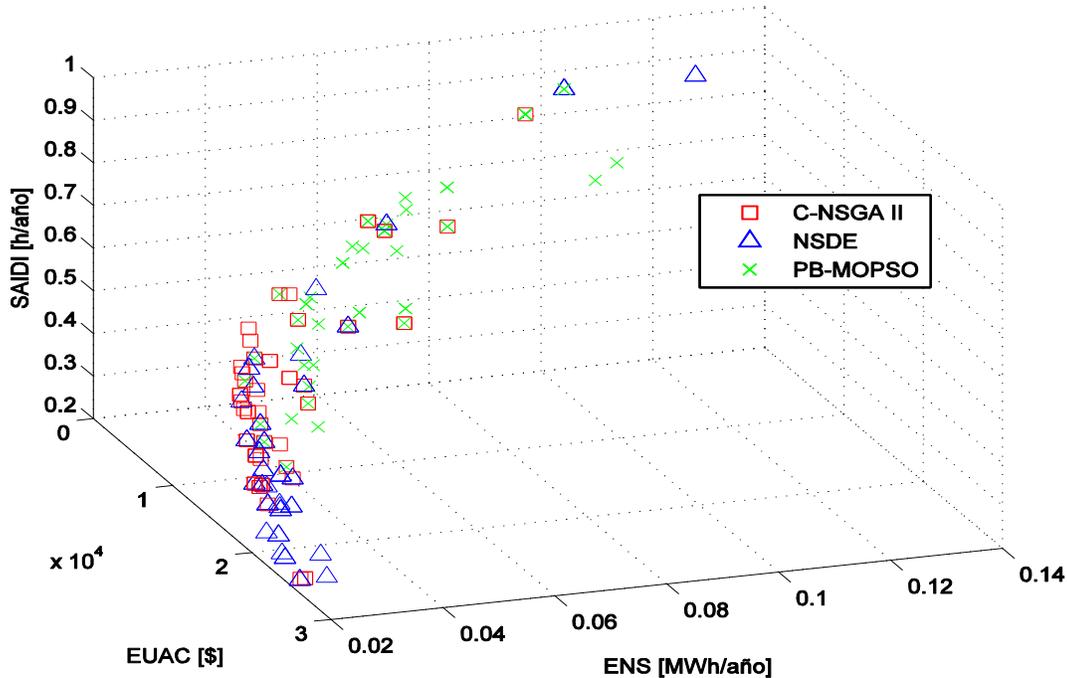


Figura 16. Resultados obtenidos para 60% de penetración de GD

3.2.4. RESULTADOS CASO DE ESTUDIO 2 CON GENERACIÓN VARIABLE.

En las anteriores secciones se ha tratado a los generadores distribuidos como generadores despachables asumiendo recursos energéticos continuos e ilimitados. En esta sección se utiliza la metodología de optimización para encontrar la ubicación óptima de reconectores en la red eléctrica de la Universidad de Nariño pero en esta ocasión se equipa la red con generadores distribuidos cuya generación depende de recursos limitados y estocásticos. Específicamente, la generación que se utiliza en este trabajo es de tipo fotovoltaica debido a que se cuentan con datos de radiación solar y temperatura medidos en el campus de la Universidad de Nariño.

Inicialmente se utiliza un modelo de Simulink [54], [55] (Figura 17) con el fin de simular el funcionamiento de los paneles fotovoltaicos y calcular la salida de potencia de dos arreglos cuyas potencias nominales son 33.96 kW (penetración del 20% de GD) y 101.632 kW (penetración del 60% de GD), respectivamente. Las entradas al modelo son la irradiancia y la temperatura medidas durante un periodo de tiempo de un año (entre 2015 y 2016) en el campus de la Universidad de Nariño cuyas graficas se muestran en la Figura 18 y Figura 19, respectivamente.

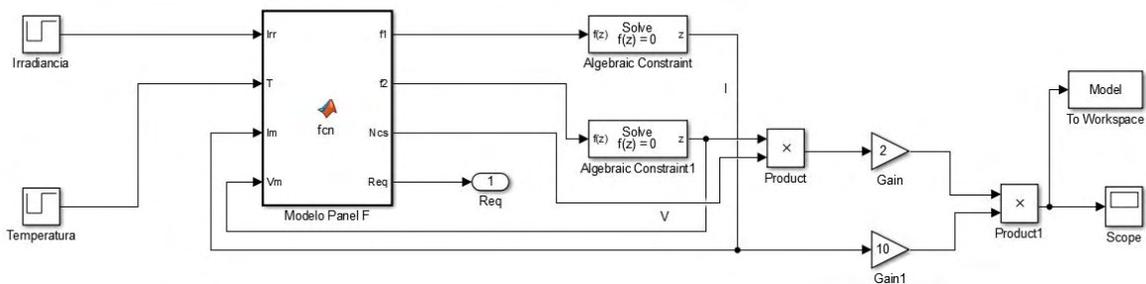


Figura 17. Modelo de arreglo de paneles fotovoltaicos en Simulink

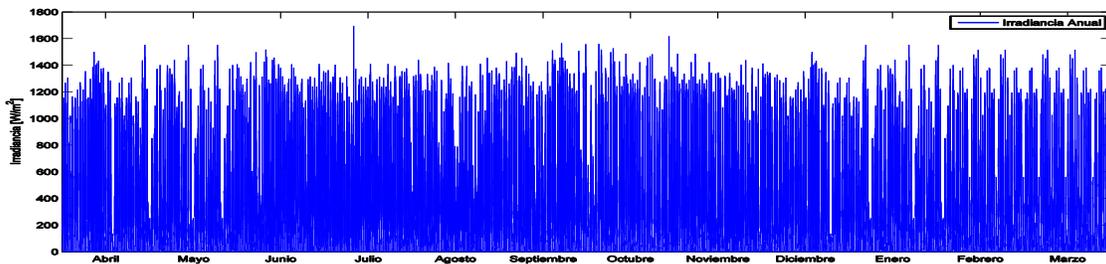


Figura 18. Irradiancia medida dentro de la Universidad de Nariño durante un año

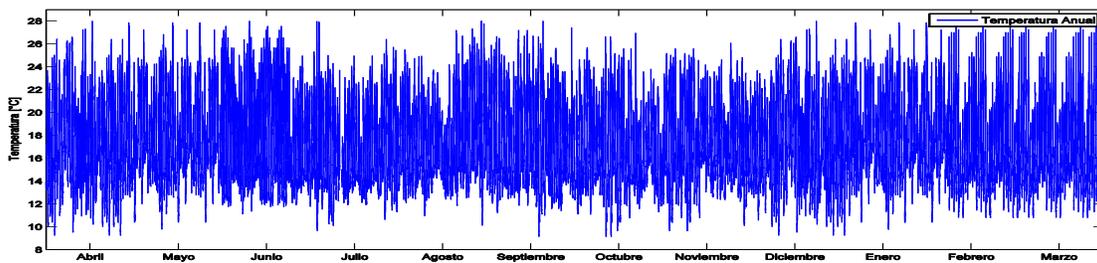


Figura 19. Temperatura medida dentro de la Universidad de Nariño durante un año

De esta manera, la salida de potencia durante un periodo de tiempo de un año para el arreglo de paneles de 101.632 kW se muestra en la Figura 20. Además, en la Figura 21 se puede observar un acercamiento que indica los 7 primeros días del mes de Agosto del año 2015 con el fin de dar una idea más clara de la forma típica de la potencia de salida durante una semana. Las Figuras 22 y 23 muestran también la potencia de salida durante un año y un acercamiento de los 7 primeros días de Agosto (año 2015) pero en esta ocasión para el arreglo de 33.96 kW.

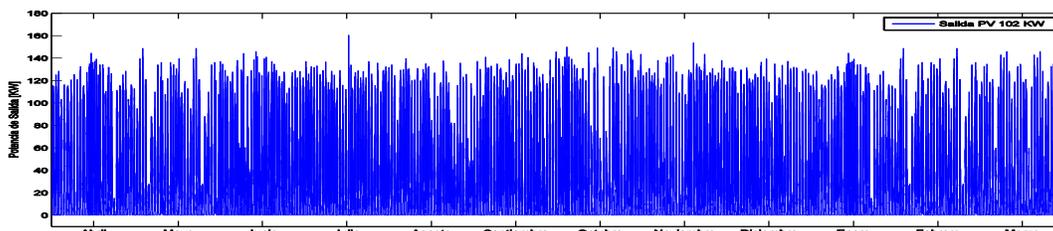


Figura 20. Potencia arreglo de 101.632 kW durante un año

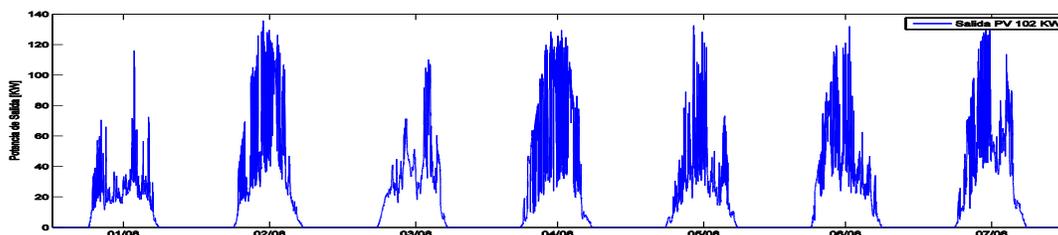


Figura 21. Potencia arreglo de 101.632 kW durante 7 días

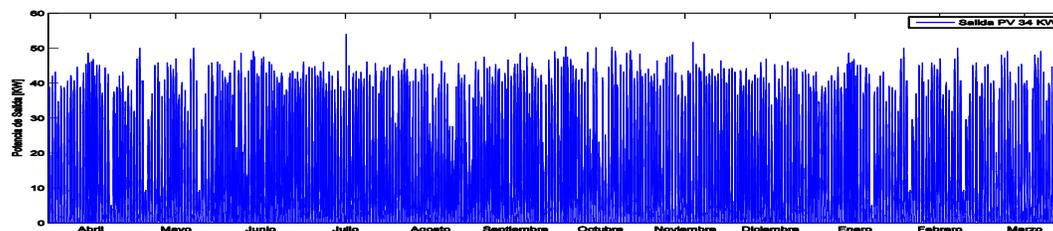


Figura 22. Potencia arreglo de 33.96 kW durante un año

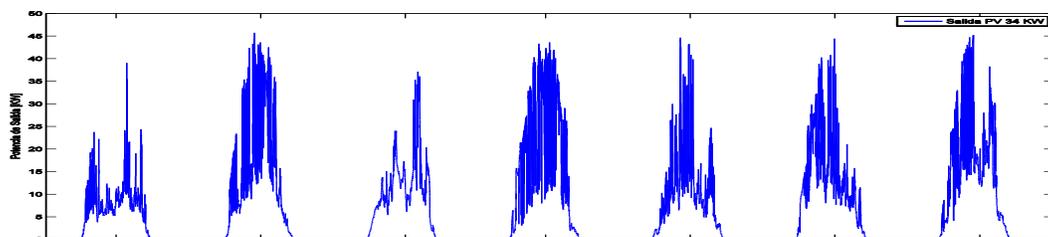


Figura 23. Potencia arreglo 33.96 kW durante 7 días

La tabla 11 muestra los valores máximo, mínimo y promedio para cada curva en las Figuras 18, 19, 20, 21, 22 y 23 con el fin de dar mayor claridad a las mismas.

	Fig. 18	Fig. 19	Fig. 20	Fig. 21	Fig. 22	Fig. 23
Máximo	1,70E+03	28,1	1,60E+05	1,35E+05	5,41E+04	4,56E+04
Mínimo	0	9,12	0	0	0	0
Promedio	169,46	16,48	1,82E+04	1,86E+04	6127	6291

Tabla 11. Valores maximo, minimo y promedio Figuras 18,19,20,21,22,23

Los datos de potencia anual generada (Figura 20 y Figura 21) se utilizan para formar curvas de generación ordenadas, las cuales se obtienen sumando para cada nivel de potencia el número de horas en que dicha potencia se ha igualado o ha sido superada a lo largo del año. La Figura 24 ilustra la construcción de una curva anual ordenada (en rojo) a partir de curva anual horaria (en azul) en donde, por ejemplo, el valor mínimo de potencia en la curva anual horaria (PDmin) tiene un valor de 8760 horas (un año) en el eje de las abscisas para la curva anual ordenada debido a que dicho valor de potencia ha sido superado o igualado durante esa cantidad de horas durante todo el año. Por el contrario, el valor de potencia máxima en la curva anual horaria (PDmax) tiene un valor de 0 horas para la curva anual ordenada ya que ningún valor de potencia supera o iguala a PDmax durante todo el año.

Realizando el procedimiento descrito anteriormente para ciertos valores de potencia se obtienen los datos mostrados en las Tabla 12 y 13. El cálculo de las curvas de generación ordenadas se realiza debido a que este tipo de curvas son las requeridas para llevar a cabo el análisis de confiabilidad con generadores distribuidos de generación variable en PowerFactory. Esencialmente, los datos requeridos dentro de la simulación son los valores de potencia en por unidad (segunda columna de las Tablas 12 y 13) y el número total de horas que cada valor de potencia fue igualado o superado durante un año (columna 15 de las Tablas 12 y 13).

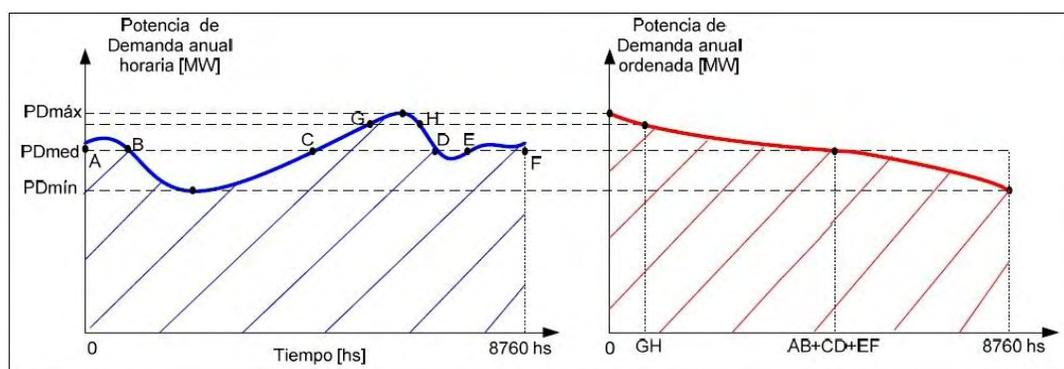


Figura 24. Ilustración curva de demanda anual ordenada.

P(kW)	p.u	Horas al año												
		Abril	Mayo	Junio	Julio	Agos	Sept	Oct	Nov	Dic	Ene	Feb	Mar	Total
10,2	0,1	296	294	289	302	319	318	310	285	289	296	294	271	3563
20,4	0,2	243	217	230	256	257	268	254	231	221	243	217	211	2848
30,6	0,3	199	159	158	200	177	199	189	165	150	199	159	166	2120
40,8	0,4	163	106	104	141	113	137	137	114	100	163	106	120	1504
51	0,5	139	70	73	98	77	99	103	83	74	139	70	88	1113
61,2	0,6	117	51	54	73	59	79	81	63	58	117	51	67	870
71,4	0,7	101	39	42	56	45	64	65	50	47	101	39	53	702
81,6	0,8	86	29	33	41	35	51	53	41	37	86	29	40	561
91,8	0,9	67	20	23	28	26	37	40	33	28	67	20	29	418
102	1	38	12	15	17	19	24	27	22	18	38	12	15	257

Tabla 12. Número de horas en que ciertos valores de potencia fueron igualados o superados para el arreglo fotovoltaico de 101.632 kW

P (kW)	p.u	Horas al año												
		Abril	Mayo	Junio	Julio	Agos	Sept	Oct	Nov	Dic	Ene	Feb	Mar	Total
3,4	0,1	296	295	290	302	320	318	310	285	290	296	295	272	3569
6,8	0,2	244	219	231	258	258	269	255	232	223	244	219	212	2864
10,2	0,3	200	160	159	202	179	201	191	167	151	200	160	167	2137
13,6	0,4	165	108	106	143	115	139	139	116	101	165	108	122	1527
17	0,5	140	72	74	100	78	100	104	84	75	140	72	89	1128
20,4	0,6	118	52	55	75	60	80	82	64	59	118	52	67	882
23,8	0,7	101	40	43	57	46	65	66	51	48	101	40	54	712
27,2	0,8	87	30	34	42	36	52	54	42	38	87	30	41	573
30,6	0,9	69	21	24	30	27	38	41	34	29	69	21	30	433
34	1	42	13	16	19	19	25	28	23	19	42	13	16	275

Tabla 13. Número de horas en que ciertos valores de potencia fueron igualados o superados para el arreglo fotovoltaico de 33.96 kW

De esta manera, los datos de las Tablas 12 y 13 son utilizados en PowerFactory para crear las curvas de generación ordenada de cada uno de los generadores distribuidos tanto para el arreglo fotovoltaico de 101.632 kW como para el arreglo de 33.96 kW como se muestra en las Figuras 23 y 24.

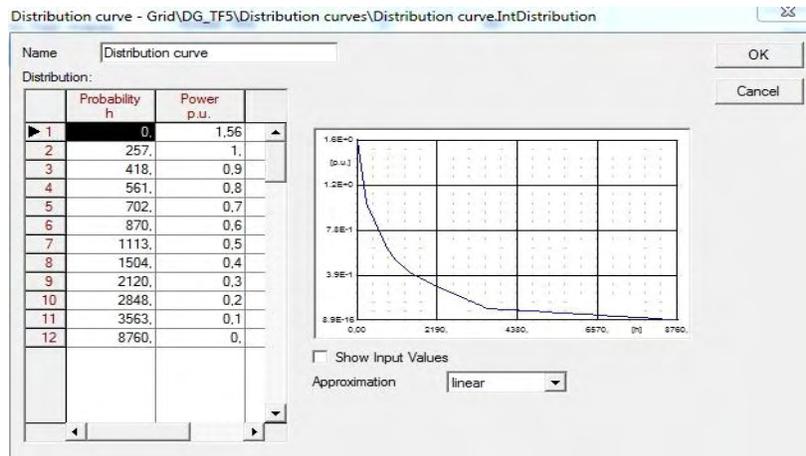


Figura 25. Curva de generación ordenada para el arreglo fotovoltaico de 101.632 kW

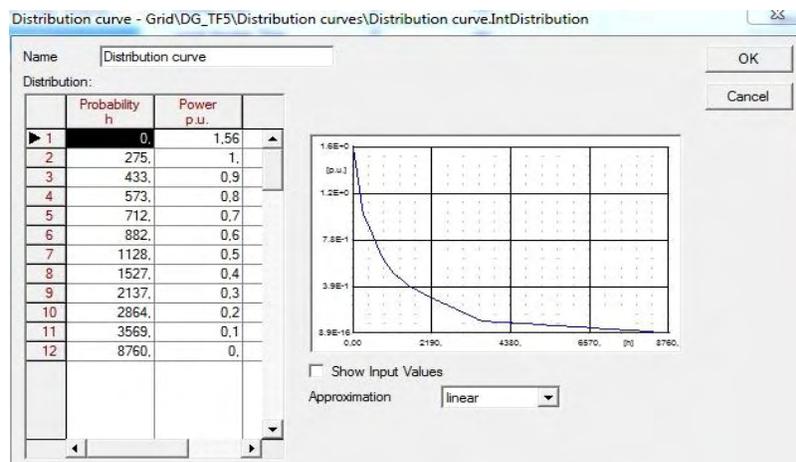


Figura 26. Curva de generación ordenada para el arreglo fotovoltaico de 33.96 kW

Una vez realizado el procedimiento anteriormente descrito se procede a aplicar la metodología de optimización para buscar la ubicación óptima de reconectores en la red eléctrica de la Universidad de Nariño equipada con generadores distribuidos con generación variable, obteniendo el conjunto de soluciones mostradas en las Figuras 27 y 28. La Figura 27 muestra los resultados para el caso de penetración del 20% de generación distribuida variable junto con los resultados obtenidos anteriormente para 20% de generación distribuida constante (Figura 13).

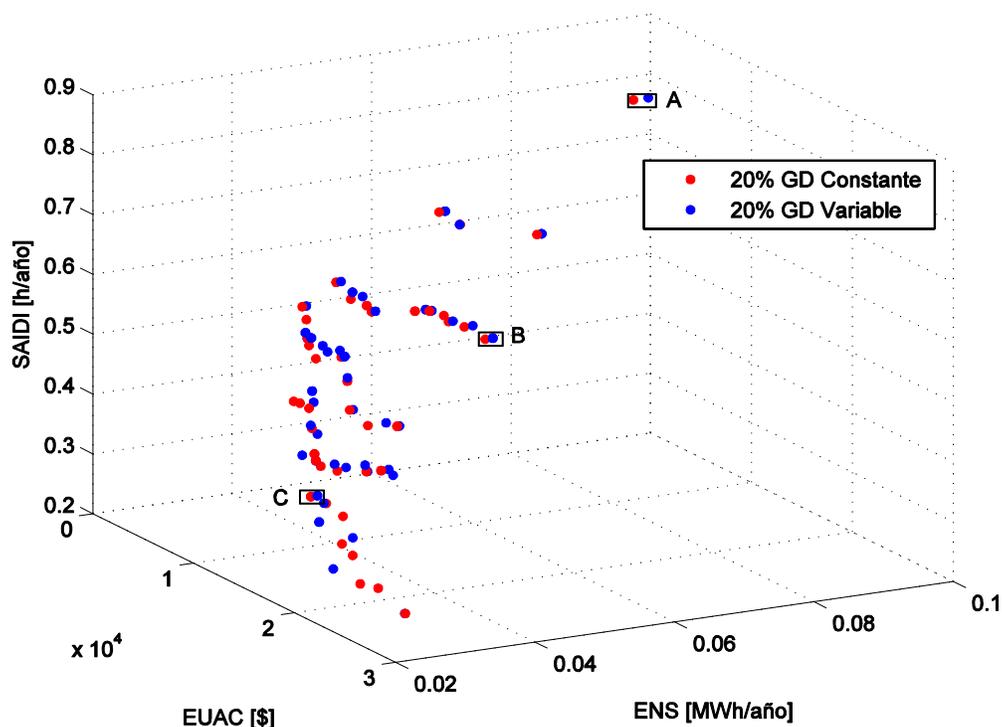


Figura 27. Resultados obtenidos para 20% de GD variable

CASO		SAIDI (horas/año)	ENS (kWh/año)	EUAC (\$)	Posición Reconectores
i. 20% GD Continua	A	0.7878	93.88	2514	16
	B	0.4776	65.36	7542	12,16,111
	C	0.3376	29.43	15084	12,16,18,113,116,117
ii. 20% GD Variable	A	0.7878	96.05	2514	16
	B	0.4776	66.44	7542	12,16, 111
	C	0.3376	30.35	15084	12, 16, 18 ,113,116,117

Tabla 14. Ejemplos de soluciones obtenidas para los casos con 20% de GD (Constante y Variable)

Como se puede observar en la Figura 27 se ve nuevamente que SAIDI y ENS son funciones no lineales del número de reconectores ubicados en la red de distribución y que el grado de mejora en dichos índices decrece a medida que la cantidad de reconectores aumenta.

En la Figura 27 se ve que muchas de las soluciones obtenidas con GD constante (puntos rojos) se encuentran muy cerca de soluciones obtenidas con GD variable

(puntos azules) formando una especie de duplas, de las cuales tres de ellas (duplas “A”, “B” y “C”) son analizadas. De este modo, la Tabla 14 muestra los valores de SAIDI, ENS y EUAC para las duplas “A”, “B” y “C” mostradas en la Figura 27, así como la ubicación de los reconectores para cada solución. Analizando los datos de la Tabla 14 se encuentra que las dos soluciones que conforman cada una de las tres duplas seleccionadas representa básicamente la misma solución en cuanto a la cantidad y ubicación de reconectores. Por ejemplo, la solución “A” para el caso “i” tiene el mismo número de reconectores e igual disposición dentro de la red eléctrica que la solución “A” del caso “ii”, además de tener igual valor de SAIDI y EUAC. Lo mismo sucede con las soluciones pertenecientes a “B” y “C”, como se puede verificar en la Tabla 14.

No obstante, un aspecto importante es que el valor de ENS sí difiere entre las soluciones pertenecientes a una misma dupla. Por ejemplo, el valor de ENS para la solución “A” del caso “i” (93.88) es menor que aquel del caso “ii” (96.05) y de la misma manera ocurre para las soluciones pertenecientes a “B” y “C”.

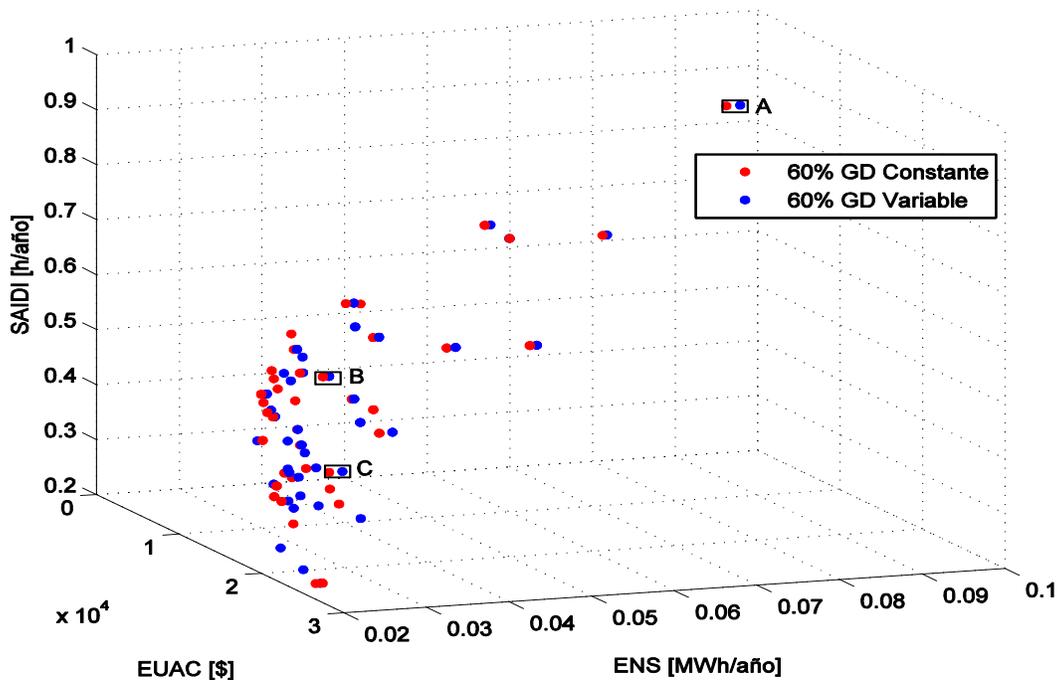


Figura 28. Resultados obtenidos para 60% de GD variable

Así, del anterior análisis se puede concluir que la utilización de GD variable hace que la energía no suministrada al sistema sea mayor con respecto a la que se obtiene con la utilización de GD constante. Esto es coherente debido a que, aunque el sistema cuente con GD y capacidad de funcionar en modo isla, el hecho de que tenga una salida de potencia variable puede dar lugar a que dicho nivel de

potencia no sea suficiente para suplir las cargas dentro de la isla en determinados momentos durante una interrupción.

CASO		SAIDI (horas/año)	ENS (kWh/año)	EUAC (\$)	Posición Reconectores
<i>i. 60% GD Continua</i>	A	0.8507	93.65	2514	16
	B	0.4690	37.33	10056	18,110,111,113
	C	0.3150	35.57	12570	12,18,110,111,113
<i>ii. 60% GD Variable</i>	A	0.8507	95.34	2514	16
	B	0.4690	38.06	10056	18,110,111,113
	C	0.3150	37.18	12570	12,18,110,111,113

Tabla 15. Ejemplos de soluciones obtenidas para los casos con 60% de GD (Constante y Variable)

Con respecto al caso de 60% de GD variable, la Figura 28 muestra los resultados obtenidos en donde se puede observar nuevamente varias duplas de soluciones al igual que en el caso de 20% de GD variable (Figura 27). Al igual que en el caso anterior, se tomaron tres duplas de soluciones (“A”, “B” y “C”) cuyos valores de SAIDI, ENS, EUAC y las correspondientes posiciones de los reconectores se muestran en la Tabla 15. Los resultados tienen el mismo patrón que los obtenidos en la Tabla 14, es decir, las soluciones pertenecientes a una misma dupla presentan iguales valores de SAIDI, EUAC, número y posición de reconectores. Nuevamente, el único valor que se ve afectado con la utilización de GD variable es la energía no suministrada al sistema (ENS) la cual es mayor cuando la GD es variable, corroborando así los resultados obtenidos en el caso anterior.

De este modo, al parecer en redes eléctricas con un número no muy considerable de elementos y de tamaño pequeño, el análisis de confiabilidad con generación distribuida variable brinda resultados muy semejantes a los que se obtienen con generación distribuida fija. Así, de no contar con información sobre el comportamiento estocástico de las unidades de GD se podría realizar el análisis de confiabilidad sin que esto afecte drásticamente en los resultados finales.

4. CONCLUSIONES

- Una metodología que utiliza un enfoque multi-objetivo ha sido utilizada con el fin de tratar con el problema de planeación de protecciones en sistemas de distribución. El propósito de este método es encontrar un conjunto de múltiples soluciones que determinen el número y localización eficientes de reconectores en una red de distribución. Dichas soluciones son buscadas de tal forma que SAIDI, ENS y EUAC son minimizados con base en el concepto de dominancia de Pareto.
- El C-NSGA-II es implementado y aplicado en el proceso de optimización con el objetivo de encontrar un conjunto de soluciones no dominadas-no restringidas satisfaciendo la restricción establecida en el problema de optimización. Además, la comparación de resultados mostraron un desempeño superior por parte del C-NSGA-II, sobre los algoritmos NSDE y PB-MOPSO, en el problema tratado en esta investigación.
- La importancia de la ubicación de dispositivos de protección y la generación distribuida ha sido demostrada por medio de los resultados de simulación de cada caso de estudio, mejorando la confiabilidad de la red y reduciendo la energía no suministrada. Además, la optimización de la ubicación de reconectores procura la creación de microrredes cuando se permite el funcionamiento en modo aislado de la generación distribuida. Por otro lado, los alimentadores son eficientemente segmentados con base en el número de reconectores a ser colocados, y se alcanzan valores más bajos de SAIDI y ENS a medida que la penetración de la generación distribuida aumenta.
- La utilización de generadores distribuidos cuya generación es variable hace que la energía no suministrada al sistema sea mayor con respecto al valor obtenido cuando se utiliza generadores distribuidos con generación constante. Esto debido a que la potencia necesaria para suplir las cargas dentro de una isla puede no ser la suficiente en determinados momentos durante una interrupción ya que la salida de potencia de los generadores distribuidos es intermitente.
- El acople de dos herramientas, como MATLAB y PowerFactory, muestra un buen enfoque para resolver problemas complejos de optimización relacionados con sistemas de potencia, como el propuesto en este trabajo de investigación.
- La optimización combinatoria multi-objetivo es un área que tiene mucho campo de investigación debido a que la mayor parte de los trabajos de

investigación se centra en problemas de combinatoria multi-objetivo en el dominio real.

4.1. RECOMENDACIONES

- Se recomienda utilizar circuitos de prueba cuyos alimentadores tengan una longitud considerable ya que de esta manera se pueden evidenciar mejor los resultados del proceso de optimización de la ubicación de reconectores, como se mostró en el caso de estudio 1. De otra forma, la utilización de circuitos de prueba con alimentadores muy cortos puede no proporcionar información sobre mejoras significativas en los índices de confiabilidad. Este caso sucedió durante la realización de este trabajo en donde antes de utilizar el circuito del bus 6 del RBTS se utilizó el circuito del bus 4 de la misma red de prueba (con alimentadores muy cortos) el cual no permitía evidenciar muy bien los resultados del proceso de optimización.
- Dependiendo del tamaño y la complejidad de la red de distribución utilizada, se recomienda el uso de computadores con una alta velocidad de procesamiento debido a que a medida que la red eléctrica presenta un mayor número de componentes, la evaluación de la confiabilidad y por ende la evaluación de las funciones objetivo requiere cada vez más una cantidad considerable de tiempo, haciendo que todo el proceso de optimización tome bastante tiempo en completarse.

4.2. TRABAJO FUTURO

- Se propone aplicar algoritmos de búsqueda local al frente de soluciones obtenido por el C-NSGA-II con el fin de asegurar que no existen mejores soluciones en las regiones cercanas a este frente.
- Con el fin de realizar una aproximación más real del problema tratado, se buscara incluir modelos estocásticos de falla para los dispositivos de protección y los generadores distribuidos para analizar su efecto en el proceso de optimización. Esta sugerencia fue realizada por el profesor Math Bollen en la conferencia internacional ICREPQ'17 durante la presentación del artículo científico producto de esta investigación (ANEXO 1).
- Un enfoque interesante constituye la utilización de procesamiento en paralelo con el objetivo de reducir el tiempo empleado en la evaluación de las funciones objetivo y así mejorar el desempeño del proceso de optimización.

BIBLIOGRAFÍA

- [1] M. Brenna, F. Foiadelli, P. Petroni, G. Sapienza, and D. Zaninelli, «Distributed generation regulation for intentional islanding in smart grids,» In 2012 IEEE PES Innovative Smart Grid Technologies (ISGT), pp 1–6, 2012.
- [2] L. G. W. da Silva, R. A. F. Pereira, J. R. Abbad, and J. R. S. Mantovani, «Optimised placement of control and protective devices in electric distribution systems through reactive tabu search algorithm,» Electric Power Systems Research, Vol. 78, No.3, pp.372–381, 2008.
- [3] M. Hajivand, R. Karimi, M. Karimi, et al, «Optimal recloser placement by binary differential evolutionary algorithm to improve reliability of distribution system,» International Journal of Information, Security and SystemsManagement, Vol. 3, No. 2, pp.345–349, 2014.
- [4] A. Pregelj, M. Begovic, and A. Rohatgi, «Recloser allocation for improved reliability of dg-enhanced distribution networks,» IEEE Transactions on Power Systems, Vol. 21, No. 3, pp.1442–1449, 2006.
- [5] R. E. Brown. Electric power distribution reliability. CRC press, 2008.
- [6] K. Deb. Multi-objective optimization using evolutionary algorithms, volume 16. John Wiley & Sons, 2001.
- [7] G. D. Ferreira, A. S. Bretas, and G. Cardoso, «Optimal distribution protection design considering momentary and sustained reliability indices,» In Modern Electric Power Systems (MEPS), 2010 Proceedings of the International Symposium, pages 1–8. IEEE, 2010.
- [8] M. R. Mazidi, M. Aghazadeh, Y. A. Teshnizi, and E. Mohagheghi, «Optimal placement of switching devices in distribution networks using multi-objective genetic algorithm nsgaii,» In 2013 21st Iranian Conference on Electrical Engineering (ICEE), pages 1–6. IEEE, 2013.
- [9] W. Tippachon and D. Rerkpreedapong, «Multiobjective optimal placement of switches and protective devices in electric power distribution systems using ant colony optimization,» Electric Power Systems Research, Vol. 79, No. 7, pp.1171–1178, 2009.

- [10] J.-H. Teng and Y.-H. Liu, «A novel acs-based optimum switch relocation method,» IEEE transactions on power systems, Vol. 18, No. 1, pp.113–120, 2003.
- [11] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan. A fast and elitist multiobjective genetic algorithm: Nsga-ii,» IEEE transactions on evolutionary computation, Vol. 6, No. 2, pp.182–197, 2002.
- [12] A. Stavičá, M. Gavrilas, and V. Stahie, «Optimal tuning and placement of power system stabilizer using particle swarm optimization algorithm,» In Electrical and Power Engineering (EPE), 2012 International Conference and Exposition on, pages 242–247. IEEE, 2012.
- [13] Viktoria Neimane, «On Development Planning of Electricity Distribution Networks,» Royal Institute of Technology, 2001.
- [14] Oscar Danilo Montoya, Planeación óptima de sistemas de distribución considerando reconectores automáticos para aislamiento de fallas y transferencia de carga, Tesis de Maestría. Universidad Tecnológica de Pereira, Colombia, 2014.
- [15] IEEE Standard 1366, Guide for Electric Power Distribution Reliability Indices, 2003.
- [16] IEEE Std. 1547-2003, IEEE Standard for interconnecting Distributed resources with electric power systems, 2003.
- [17] C. A. C. Coello, «Recent trends in evolutionary multiobjective optimization,» In Evolutionary Multiobjective Optimization, pages 7–32. Springer, 2005.
- [18] Talbi, El-Ghazali. Metaheuristics: from design to implementation. Vol. 74. John Wiley & Sons, 2009
- [19] E. H. L. Aarts and J. K. Lenstra. Local Search in Combinatorial Optimization. Wiley, 1997.
- [20] S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi, «Optimization by simulated annealing,» Science, 220(4598):671–680, 1983
- [21] V. Cerny, «A thermodynamical approach to the traveling salesman problem: An efficient simulation algorithm,» Journal of Optimization Theory and Applications, 45:41–51, 1985.
- [22] F. Glover, «Tabu search: Part I,» ORSA Journal on Computing, 1(3):190–206, 1989.

- [23] J. H. Holland, «Outline for a logical theory of adaptive systems,» *Journal of the ACM*, 3:297–314, 1962.
- [24] J. H. Holland. *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor, MI, 1975.
- [25] I. Rechenberg, «Cybernetic solution path of an experimental problem,» Technical Report, Royal Aircraft Establishment Library Translation No. 1112, Farnborough, UK, 1965.
- [26] I. Rechenberg. *Evolutionstrategie: Optimierung technischer systeme nach prinzipien der biologischen evolution*. Frommann-Holzboog, 1973.
- [27] L. J. Fogel, A. J. Owens, and M. J. Walsh. *Artificial Intelligence Through Simulated Evolution*. Wiley, 1966.
- [28] F. Glover, «Heuristics for integer programming using surrogate constraints. *Decision Sciences*,» 8:156–166, 1977.
- [29] J. Kennedy and R. C. Eberhart, «Particle swarm optimization,» In *IEEE International Conference on Neural Networks*, Perth, Australia, 1995, pp. 1942–1948.
- [30] Guo, Jianmei, et al, «Scaling exact multi-objective combinatorial optimization by parallelization,» *Proceedings of the 29th ACM/IEEE international conference on Automated software engineering*. ACM, 2014
- [31] Ehrgott, Matthias, and Xavier Gandibleux, «Multiobjective combinatorial optimization—theory, methodology, and applications,» *Multiple criteria optimization: State of the art annotated bibliographic surveys*. Springer US, 2003. 369-444.
- [32] Iorio, Antony W., and Xiaodong Li, «Solving rotated multi-objective optimization problems using differential evolution,» *Australasian Joint Conference on Artificial Intelligence*. Springer Berlin Heidelberg, 2004.
- [33] Coello, Carlos A. Coello, Gregorio Toscano Pulido, and M. Salazar Lechuga, «Handling multiple objectives with particle swarm optimization,» *IEEE Transactions on evolutionary computation* 8.3 (2004): 256-279
- [34] K. Deb, S. Agrawal, A. Pratab, and T. Meyarivan, «A fast elitist nondominated sorting genetic algorithm for multi-objective optimization: NSGA-II,» in *Proc. Parallel Problem Solving From Nature VI Conf.*, 2000, pp. 849–858

- [35] N. Srinivas and K. Deb, «Multiobjective optimization using nondominated sorting in genetic algorithms,» *Evol. Comput.*, vol. 2, no. 3, pp. 221–248, Fall 1994.
- [36] Price, K. V, «Differential evolution: a fast and simple numerical optimizer,» In: Smith, M., Lee, M., Keller, J., Yen., J. (eds.): *Biennial Conference of the North American Fuzzy Information Processing Society, NAFIPS*. IEEE Press, New York (1996) 524–527
- [37] Price, K V, «An Introduction to Differential Evolution,» In: Corne, D., Dorigo, M., and Glover, F. (eds.): *New Ideas in Optimization*. McGraw-Hill, London (UK) (1999) 79–108.
- [38] Maravilha, André L., Jaime A. Ramírez, and Felipe Campelo, «A new algorithm based on differential evolution for combinatorial optimization,» *Computational Intelligence and 11th Brazilian Congress on Computational Intelligence (BRICS-CCI & CBIC)*, 2013 BRICS Congress on. IEEE, 2013.
- [39] J. Kennedy and R. C. Eberhart. *Swarm Intelligence*. Morgan Kaufmann, San Francisco, CA, 2001.
- [40] Hu, X., Eberhart, R, «Multiobjective Optimization Using Dynamic Neighborhood Particle Swarm Optimization,» In: *Proceedings of the 2002 Congress on Evolutionary Computation*, IEEE Press (2002).
- [41] Parsopoulos, K., Vrahatis, M, «Particle Swarm Optimization Method in Multiobjective Problems,» In: *Proceedings of the 2002 ACM Symposium on Applied Computing (SAC 2002)*. (2002) 603–607.
- [42] Coello, C., Lechunga, M, «MOPSO: A Proposal for Multiple Objective Particle Swarm Optimization,» In: *Proceedings of the 2002 Congress on Evolutionary Computation*, IEEE Press (2002) 1051–1056.
- [43] Fieldsend, J., Singh, S, «A Multi-Objective Algorithm based upon Particle Swarm Optimisation, an Efficient Data Structure and Turbulence,» In: *Proceedings of UK Workshop on Computational Intelligence (UKCI 02)*. (2002) 37–44.
- [44] Mostaghim, S., Teich, J, «Strategies for Finding Good Local Guides in Multi-Objective Particle Swarm Optimization (MOPSO),» In: *IEEE 2003 Swarm Intelligence Symposium*. (2003) 26–33
- [45] Alvarez-Benitez, Julio E., Richard M. Everson, and Jonathan E. Fieldsend, «A MOPSO algorithm based exclusively on pareto dominance concepts,» *International Conference on Evolutionary Multi-Criterion Optimization*. Springer Berlin Heidelberg, 2005.

- [46] Kennedy, James, and Russell C. Eberhart, «A discrete binary version of the particle swarm algorithm,» *Systems, Man, and Cybernetics*, 1997. *Computational Cybernetics and Simulation.*, 1997 IEEE International Conference on. Vol. 5. IEEE, 1997.
- [47] D. A. Van Veldhuizen and G. B. Lamont, «Multiobjective evolutionary algorithm research: A history and analysis,» Dept. Elec. Comput. Eng., Graduate School of Eng., Air Force Inst. Technol., Wright-Patterson AFB, OH, Tech. Rep. TR-98-03, 1998.
- [48] J. R. Schott, «Fault tolerant design using single and multicriteria genetic algorithm optimization,» M.S. thesis, Dept. Aeronautics and Astronautics, Massachusetts Inst. Technol., Cambridge, MA, May 1995.
- [49] K. Deb, «Multi-objective genetic algorithms: problem difficulties and construction of test problems,» *Evol. Comput.*, vol. 7, pp. 205–230, Fall 1999.
- [50] F. Y. CHENG & X. S. LI, «Generalized center method for multiobjective engineering optimization,» *Engineering Optimization*, 31:5, 641-661, 1999.
- [51] R. Billinton and S. Jonnavithula, «A test system for teaching overall power system reliability assessment,» *IEEE Transactions on Power Systems*, Vol. 11, No. 4, pp.1670–1676, 1996.
- [52] R. N. Allan, R. Billinton, I. Sjarief, L. Goel, and K. So, «A reliability test system for educational purposes-basic distribution system data and results,» *IEEE Transactions on Power Systems*, Vol. 6, No. 2, pp.813–820, 1991.
- [53] Daniel Andrade, Levantamiento análisis y diagnóstico de la red eléctrica actual de la Universidad de Nariño como base de una microrred, Tesis de Pregrado, Universidad de Nariño, Pasto 2015.
- [54] J. A. Hernández, «Metodología para el análisis técnico de la masificación de sistemas fotovoltaicos como opción de generación distribuida en redes de baja tensión,» Tesis de grado Doctoral. Universidad Nacional de Colombia, Colombia, 2012.
- [55] Fredy Dulce, Modelamiento y control de una microrred en modo isla, Tesis de Maestría. Universidad de los Andes, Colombia 2015.

ANEXOS

ANEXO 1. ARTICULO DE CONFERENCIA INTERNACIONAL (<http://www.icrepq.com/icrepq17/306-17-lopez.pdf>)



International Conference on Renewable Energies and Power Quality (ICREPQ'17)
Malaga (Spain), 4th to 6th April, 2017
Renewable Energy and Power Quality Journal (RE&PQJ)
ISSN 2172-038 X, No.15 April 2017



Optimization of Recloser Placement in DG-Enhanced Distribution Networks Using a Multi-objective Optimization Approach

Fabian Lopez¹ and Andrés Pantoja¹

¹ Department of Electronics
Universidad de Nariño

Ciudadela Universitaria Torobajo, Pasto, Colombia

e-mail: fabianlopezch@outlook.com, ad_pantoja@udenar.edu.co

Abstract. Efficient placement of protective devices in electric power distribution networks is necessary in order to achieve a reliable system and provide continuous power supply to customers as long as possible. The islanded operation with distributed generation (DG) provides a way to reduce the energy not supplied (ENS) but the placement of protections, such as reclosers, is necessary in order to allow the system to achieve this mode of operation. This paper presents a multi-objective optimization method to place efficiently normally closed reclosers by using a constrained non-dominated sorting genetic algorithm (C-NSGA-II) to reduce SAIDI, ENS and investment costs. A co-simulation approach is used in such a way that the power system is modelled in PowerFactory, while MATLAB is used to implement the C-NSGA-II. Then, a distribution test network is probed in simulation cases with different DG penetration levels, showing the efficiency of the proposed optimization method. Results show the importance of protective devices and DG in enhancing system reliability and reducing the energy not supplied to customers.

Key words

Co-simulation, distributed generation, distribution systems reliability, multi-objective optimization, protective systems.

1. Nomenclature

DG: Distributed Generation.
ENS: Energy Not Supplied.
SAIDI: System Average Interruption Duration Index
NCR: Normally Closed Recloser
SOOP: Single Objective Optimization Problem
MOOP: Multi-Objective Optimization Problem
NCD: Non-Constraint Dominated
 $ACIT_i$: average customer interruption time of the load point i .
 Pd_i : amount of power not supplied when load point i is disconnected.
 k : total number of loads in the network.
EUAC: Equivalent Uniform Annual Cost.
AOC: Annual Operation Cost.
 R_p : Cost of a single recloser.
 N_r : Amount of placed reclosers.
 d_r : Discount rate.
 l_r : Lifetime of reclosers

2. Introduction

A priority of any distribution utility is to meet the requirements for safety, reliability and quality of supply. This can be achieved with the assist of some subsystems associated with the distribution network, where the protection system is the most important due to its capability for clearing and isolating faults. Concerning reliability, satisfying the load demand of customers with a continuous supply of energy is required to improve the reliability indices and reduce the energy not supplied (ENS). To make it possible, distribution automation is necessary to isolate faults on the network as quickly as possible, offering the possibility that distributed generation (DG) units can operate in islanded mode, an important function required for future smart grids [1].

In order to achieve a proper balance between financial resources and the technical requirements of the network, a cost/benefit analysis of the protection system must be considered. With these conditions, distribution utility has the task to meet two conflictive objectives: minimizing economical cost and maximizing reliability. Fulfilling the above objectives, the number and location of protective devices are critical variables. Thus, the contribution of this work is to deal with the planning of protection systems based on normally closed reclosers (NCRs). These devices are capable to isolate faulted sections and can be used to allow the islanded operation of networks with DG by establishing autonomous shares and achieving service restoration to certain loads of the distribution network.

The optimal placement of protective devices has been studied as single objective (SOOP) and multi-objective (MOOP) optimization problems taking into account the DG capability of islanded operation. Considering the SOOP approach, the reactive tabu search algorithm (RTS) is implemented in [2] to solve a cost minimization problem modeled through a mixed integer non-linear programming with real and binary variables. Moreover, [3] presents a novel structure for the simple differential evolution algorithm (DE) to solve optimal recloser placement by minimizing an objective function composed by four

reliability indices. Taking into account both optimal positions for DG and protection devices, in [4] the feeder is equipped with capacity-constrained DG, while a custom-tailored genetic algorithm is used to minimize a composite reliability index.

The aforementioned studies address the reliability optimization problems with one of two approaches: *i*) minimize cost while satisfying reliability constraints, and *ii*) minimize customer interruptions subject to cost constraints [5]. Nevertheless, decision-making in planning of protection systems should be treated as a multi-objective optimization problem because of the conflictive maximization of reliability and minimization of costs. To work with the MOOP approach, two ways can be considered. On the one hand, the MOOP is turned into a SOOP by means of methods such as the weighted-sum approach and the ϵ -constraint method [6]. However, such a transformation is often subjective to the decision-maker and it needs precise information about the trade-off relationship among objectives. On the other hand, a more reliable approach is to first find a Pareto-optimal set with multiple trade-off solutions, and then, choose one solution from the set using convenient information or assumptions about the system.

Considering this approach, there are some works using the Pareto-optimal concept in planning of protection systems. A methodology for multi-objective optimization of protective devices allocation in order to minimize, SAIDI, SAIFI and MAIFI_E indices simultaneously is proposed in [7]. The authors use the non-dominated sorting genetic algorithm (NSGA-II) in the search of the best solutions, in the same way as in [8], where the problem address with the minimization of the installation cost of sectionalizers while improving SAIDI and ECOST indices. With a different metaheuristic, the multi-objective ant colony system (MACS) is used in [9] for optimal placement of switching and protective devices in distribution systems by means of minimizing SAIFI, SAIDI, and total cost.

In this paper, we propose a multi-objective optimization that uses the Pareto-dominance concept to minimize SAIDI, ENS, and cost investment simultaneously on a DG-enhanced distribution network with islanded operation capabilities. The optimization procedure provides multiple trade-off solutions of efficient configurations with different amounts and placements of NCRs in the distribution network. Since the optimal placement of protective devices is a complex combinatorial problem with nonlinearity, discontinuity, and non-differentiability characteristics [4], [9], [10], solving the problem with traditional methods (e.g., linear and nonlinear programming) is difficult. Then, the use of metaheuristic methods such as the Non-dominated Sorting Genetic Algorithm (NSGA-II) [11] is an appropriate alternative to attain efficient solutions. To obtain a solution set belonging to a Pareto surface, we use a linked simulation with MATLAB and PowerFactory with the automatic data exchange procedure presented in [12].

3. General Optimization Problem

A. Multi-objective Optimization and Pareto Optimality

Even though many of the decision-making problems are handled as single objective problems, including all the aspects in a single function is difficult. Thus, a multi-objective optimization problem can be defined with a vector of functions that includes a number of conflicting objectives to be maximized or minimized. Without loss of generality it is assumed that these objectives are to be minimized, as such the problem can be expressed by its general form as follow [6]:

$$\begin{aligned} & \text{Minimize} && f_m(X), && m = 1, 2, \dots, M; \\ & \text{subject to} && g_j(X) \geq 0, && j = 1, 2, \dots, J; \\ & && h_k(X) = 0, && k = 1, 2, \dots, K; \\ & && x_i^{(L)} \leq x_i \leq x_i^{(U)}, && i = 1, 2, \dots, n. \end{aligned} \quad (1)$$

where M , J and K are the number of objective functions, inequality, and equality constraints, respectively, and $X = (x_1, x_2, \dots, x_n)^T$ is a vector of the n decision variables. The values $x_i^{(L)}$ and $x_i^{(U)}$ define the lower and upper bounds of the decision space that restricts the decision variables.

In MOOPs where the objectives are in conflict to each other, there does not exist a single solution that simultaneously optimizes all objective functions. Instead, the most commonly adopted concept for optimality in MOOPs is the Pareto optimality [13], where a feasible vector of decision variables X^* is Pareto optimal if there does not exist another X such that $f_i(X) \leq f_i(X^*)$ for all $i = 1, 2, \dots, M$ and $f_j(X) < f_j(X^*)$ for at least one j . Almost always, this approach gives a set of multiple trade-off solutions instead of a single solution. That set of solution is so-called the Pareto-optimal set and the vectors X^* belonging to this set are so-called non-dominated solutions. The image of the Pareto-optimal set under the objective functions is the Pareto front.

Since multiple solutions arise in MOOPs, a mechanism to assess their relative fitness must be established. Thus, the Pareto-dominance concept has widely been used to accomplish this task and guide the search towards the Pareto front. The conditions that must be true for a solution $X^{(1)}$ to dominate other solution $X^{(2)}$ are defined as follow [6]:

1. The solution $X^{(1)}$ is no worse than $X^{(2)}$ in all objectives.
2. The solution $X^{(1)}$ is strictly better than $X^{(2)}$ in at least one objective.

Since the Pareto-dominance is a method to compare solutions in MOOPs, this concept is used in most multi-objective optimization algorithms to search for non-dominated solutions and achieve the Pareto front.

B. Islanded Mode of DG

The islanded operation capability is one of the most outstanding features of a DG-enhanced distribution network because it may offer a reliable and uninterrupted energy supply to certain loads. This feature allows the system to produce microgrids with the ability to operate in off-grid mode when faults arise in the utility grid. It can be

enabled by using switches and protective devices (e.g. NCRs). Although islanded mode is not widely accepted, implementation of intentional islanding of DG is a current research area covered by standards such as the IEEE 1547-2003, continuously under consideration for future revisions [14].

Considering disturbances, when a fault arises in a DG-enhanced distribution network, it may be energized from both the substation transformer and the DG whereby mis-coordination between protective devices may emerge. This condition increases the difficulty in the reliability assessment. In this case, in normal conditions we assume that the distribution network works as a typical radial network, and that the DG only supplies power when a fault occurs in the feeder. This assumption is established given that the focus of this work is to analyze the improvement that DG can provide in system reliability. In consequence, for a fault anywhere on the network, only the closest recloser upstream to the fault can operate.

With the aforementioned assumptions, the DG-enhanced radial feeder shown in Figure 1 is used as an example to illustrate the islanded operation mode. In normal conditions, the utility grid is the only source that supplies energy to loads L_1 , L_2 and L_3 , while the DG does not provide power. Now, assume that a fault arise between busbars B_1 and B_2 which causes the opening of the recloser (R). After this, loads L_2 and L_3 are isolated from the utility grid forming an island along with the DG unit. DG should be able to provide energy to total load $L_T = L_2 + L_3$, while the network returns to normal conditions. When the island is established, one of the following cases may occur: *i*) the DG power supply (P_{DG}) equals L_T power consumption (P_T), which need no actions and is the most efficient case, *ii*) P_{DG} is not sufficient for meet P_T ($P_{DG} < P_T$), so load shedding is required in order to keep the supply-demand balance and causing an increase in ENS, and *iii*) P_{DG} exceeds P_T ($P_{DG} > P_T$), so actions such as storing/dumping the excess of energy, or reducing generation should be considered.

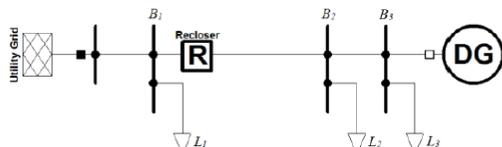


Figure 1. Illustrative DG-enhanced feeder.

Taking into account the above, an inadequate placement of reclosers may result in the formation of inefficient islands either with excessive or insufficient generation, so the reliability provided by DG is not obtained. Hence, efficient placement of reclosers is required in order to ensure efficient islands, and in consequence, maximizing the benefits of using DG.

4. Problem Formulation

One of the purposes of the protective devices is to enhance certain reliability indices, procuring a continuous energy supply to loads. To accomplish this goal, investments must

be done depending on the desired performance of the distribution utility. This work addresses SAIDI and ENS reduction in the optimization problem, along with a cost function that includes investment and operational costs of the protective system. SAIDI is selected since in addition to being the most common reliability index used by utilities, reliability investments based on this index alone have shown good improvements in SAIFI and MAIFI_E too [5]. Also, since indices such as SAIFI depend on the interruptions that customers perceive, poor improvements could be achieved with the approach used in this research because interruptions can be experienced by customers while the islands are established.

This problem has conflictive functions because a high improvement in reliability usually requires high investment, and inexpensive protection systems may lead to poor reliability indices. Therefore, there does not exist a single solution that simultaneously minimizes the three objective functions so a Pareto optimization is used to find a set of trade-off solutions. The MOOP is defined based on the general form described in (1):

$$\begin{aligned} \min \quad & SAIDI(X), ENS(X), EUAC(X) \\ \text{subject to} \quad & 1 - \frac{EUAC(X)}{EUAC_{max}} \geq 0, \\ & x_i \in \{0,1\} \end{aligned} \quad (2)$$

where,

$$SAIDI = \frac{\sum_{i=1}^k ACIT_i C_i}{\sum_{i=1}^k C_i} \quad (3)$$

$$ENS = \sum_{i=1}^k ACIT_i Pd_i \quad (4)$$

$$EUAC = AOC + \left[\frac{d_r(1 + d_r)^{l_t}}{(1 + d_r)^{l_t} - 1} \right] R_p N_r \quad (5)$$

Here, $ACIT_i$ is the average customer interruption time of the load point i , C_i is the number of customers in load point i , Pd_i is the amount of power not supplied when load point i is disconnected, and k is the total number of loads in the network. Considering costs, $EUAC$ is the equivalent uniform annual cost, where AOC is the annual operation cost, R_p is the cost of a single recloser, N_r is the amount of placed reclosers on the network and the expression in the brackets represents an annualization factor composed by a discount rate d_r and the lifetime of reclosers l_t . Also, $EUAC_{max}$ is the maximum $EUAC$ that the utility is willing to invest in reliability improvement. By last, the n decision variables composing the vector $X = (x_1, x_2, \dots, x_n)^T$ are binary variables which represent the existence ($x_i = 1$) or absence ($x_i = 0$) of a recloser in the i^{th} branch of the network.

5. Constrained Non-Dominated Sorting Genetic Algorithm-II (C-NSGA-II)

Problems related to optimal placement of protection devices have nonlinear, discontinuous, and non-differentiable characteristics so the use of traditional methods may be infeasible. Furthermore, the outcome of

classical optimization methods is a single solution and not a set of solutions, as required in multi-objective problems. Thus, a feasible alternative to overcome this issue is to use a multi-objective evolutionary algorithm (MOEA). A MOEA use a population based approach along with the Pareto-dominance concept to look for multiple non-dominated solutions. In this paper, we use the constrained non-dominated sorting genetic algorithm (C-NSGA-II) [11] in order to search for solutions of the MOOP defined in (2). The C-NSGA-II use the same two key features of NSGA-II: *i*) a fast non-dominated sorting approach to sort each solution within a non-dominated front \mathcal{F}_d ($d = 1, 2, \dots$) based on an assigned rank d , and *ii*) a crowding distance metric used to preserve diversity among solutions. The main difference is that in C-NSGA-II the usual definition of domination is replaced by a constrain-domination condition. In this sense, to say that a solution $X^{(1)}$ constrain-dominate a solution $X^{(2)}$, any of the following conditions must be true:

1. Solution $X^{(1)}$ is feasible and solution $X^{(2)}$ is not.
2. Solution $X^{(1)}$ and $X^{(2)}$ are both infeasible, but solution $X^{(1)}$ has smaller constraint violation.
3. Solution $X^{(1)}$ and $X^{(2)}$ are feasible, and $X^{(1)}$ dominates the solution $X^{(2)}$ in the usual domination sense defined in Section 3.A.

To illustrate these concepts, a pseudo-code of the proposed C-NSGA-II is shown in Algorithm 1. First, a random initial population P_0 is created composed by individuals of N chromosomes as in X_N (i.e., the decision vectors). Each binary string X_N is used to place reclosers in the distribution network based on the binary value of each decision variable (x_n). Next, a reliability assessment is done in PowerFactory for each configuration to obtain the objective function values. Then, the solutions in the population are sorted into d non-constrain-dominated (NCD) sets (\mathcal{F}_d) using the constrain-domination condition, such that, the front \mathcal{F}_i is better than \mathcal{F}_j if $i < j$. Also, crowding distance is calculated for solutions in each front \mathcal{F}_d . After this, a selection process is applied to the population by means of a constrained tournament. With this selection operator, given two solutions $X^{(1)}$ and $X^{(2)}$, solution $X^{(1)}$ is chosen if any of the following conditions are true:

1. Solution $X^{(1)}$ belongs to a better NCD set.
2. Solutions $X^{(1)}$ and $X^{(2)}$ belong to the same NCD set, but solution $X^{(1)}$ has greater crowding distance value.

The offspring population Q_0 is produced by regular genetic operators such as crossover and mutation. When the offspring population is obtained, a new population $R_t = P_t \cup Q_t$ is created. The objective functions evaluation with solutions in R_t is accomplished through reliability assessment again. Then, R_t is sorted in NCD fronts in order to obtain the population of the next generation. Thus, when R_t is sorted, the population P_{t+1} is filled by the elements inside of front \mathcal{F}_1 (the best front) only if the addition of the size of P_{t+1} and the size of \mathcal{F}_1 is less than N . The aforementioned process is repeated with subsequent fronts until the value of P_{t+1} size added to \mathcal{F}_j size is greater than N . When it

happens, P_{t+1} cannot include all solutions contained in \mathcal{F}_j . Hence, only the $N - |P_{t+1}|$ solutions with the greatest crowding distance values from \mathcal{F}_j are selected to complete the population of P_{t+1} . Finally, offspring population Q_{t+1} is created by applying constrained tournament selection, crossover and mutation operators to P_{t+1} population.

Algorithm 1. Constrained NSGA-II

Initialize population: $P_0 = (X_1^0, X_2^0, \dots, X_N^0)^T$
Objective functions evaluation: network reliability assessment for each solution in P_0 .
for $j = 1$ **to** N
 $f_1(X_j^0) = SAIDI(X_j^0)$; $f_2(X_j^0) = ENS(X_j^0)$;
 $f_3(X_j^0) = EUAC(X_j^0)$
End
Fast non-constrain-dominated sorting: classify P_0 into d different non-constrain-dominated sets \mathcal{F}_d .
Local crowding distance assignment: For each solution j belongs to \mathcal{F}_d , assign a measure of the density of solutions in \mathcal{F}_d that surround solution j .
Constrained Tournament Selection operator: chose the parents of the offspring population Q_0 .
Crossover: Q_0 is created based on the chosen parents.
Mutation: alters randomly solutions of Q_0
for $t = 0$ **to** $(t - 1)$
Combine populations: $R_t = P_t \cup Q_t$
Objective functions evaluation: reliability assessment for solutions in R_t
Fast non-constrain dominated sorting: classify R_t into d different non-constrain-dominated sets \mathcal{F}_d .
Create new population: $P_{t+1} = \emptyset$, $j = 1$;
while $|P_{t+1}| + |\mathcal{F}_j| < N$
 $P_{t+1} = P_{t+1} \cup \mathcal{F}_j$;
 $j = j + 1$;
End
Local crowding-sort of \mathcal{F}_j : sort \mathcal{F}_j in descending order according to the crowding distance of solutions.
Complete P_{t+1} : Include the $(N - |P_{t+1}|)$ solutions with the largest crowding distance values from \mathcal{F}_j in P_{t+1} .
 $P_{t+1} = P_{t+1} \cup \mathcal{F}_j[1 : (N - |P_{t+1}|)]$;
Create new offspring population Q_{t+1} : apply constrained tournament selection, crossover and mutation operators to P_{t+1} to form Q_{t+1} .
End

The use of powerful tools offered by PowerFactory in the evaluation of the objective functions is a remarkable aspect of this work. Although optimization can be done in the same software, the programming platform of PowerFactory presents some difficulties and coding the optimization algorithm could become a hard task. In this sense, the co-simulation approach used in this work takes advantage of an easy programming environment such as MATLAB and its toolboxes to develop the optimization algorithm.

6. Case Study and Results

A. Case Study

To assess the performance of the proposed optimization algorithm and show its application, we use the network at bus 6 of the Roy Billinton Test System (RBTS) implemented in PowerFactory (Figure 2) based on the

system parameters presented in [15]. This network has 41 load points with a peak load of 20 MW and two voltage levels (33 kV and 11 kV). The original radial network has been enhanced with DG penetration in order to make comparative simulations between the original network and the enhanced one with DG penetration of 20% and 60%.

A failure model is required to accomplish the reliability analysis, so we define a stochastic failure model for the network components, using the data detailed in [16]. Here, the failure rates and repair times for transformers, breakers, busbars, and lines are listed for each voltage level. Regarding *EUAC*, the values of *AOC*, *Rp*, *dr* and *lt* are set to 400 USD, 18000 USD, 0.1 (10%), and 20 years, respectively, so the *EUAC* for a single installed recloser is 2514 USD, and *EUACmax* is set to 26000 USD.

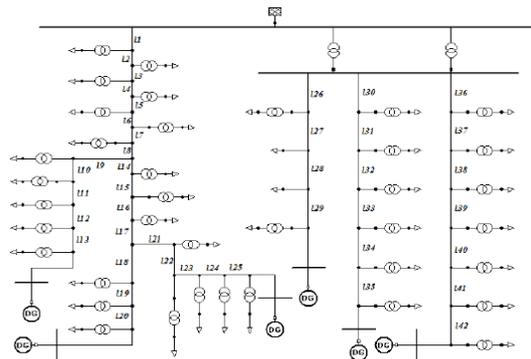


Figure 2. Distribution Network at Bus 6 of the RBTS with DG Penetration.

B. Results

The C-NSGA-II has been implemented in MATLAB for finding efficient placement of reclosers in the distribution network described above (Figure 2). The network is simulated in PowerFactory to calculate the objective functions (SAIDI and ENS) according to the stochastic model of failures and the power flows. The optimization procedure results in the set of solutions showed in Figure 3, which represent three simulation cases, one without DG penetration and two with different levels of DG penetration.

For each simulation case, we have selected three representative non-constrain-dominated solutions presented in Table I. Between these solutions, “A” represents the cheapest solution (*EUAC*=\$7542), but it produces less improvements in SAIDI and ENS. On the other hand, solution “C” has the best SAIDI and ENS values, but it requires the highest investment (*EUAC*=\$25140), satisfying the constraint of the problem. By last, “B” represents an affordable solution (*EUAC*=\$15084) with intermediate SAIDI and ENS values with respect to solutions “A” and “C”.

Observing Figure 3, it is evident that SAIDI and ENS are non-linear functions of the number of recloser placed in the network. Even more, the extent of improvement in those indices, achieved by the addition of reclosers, decrease as the amount of reclosers increases. From this point of view, having

multiple solutions is useful to analyze when increases in investment does not produce significant decrease in SAIDI and ENS values. Then, it is possible to find points where the benefits obtained by the addition of a recloser do not justify the investment.

Another important result with the addition of DG and isolated mode capability is that solutions are displaced towards lower values of SAIDI and ENS as the DG penetration increases.

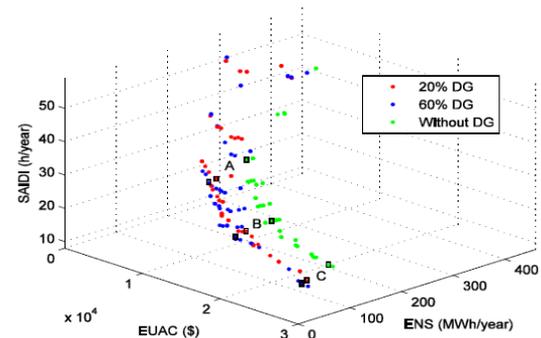


Figure 3. Sets of Non-Constrain-Dominated Solutions

Analyzing the positions in which reclosers are placed (Table I), it may be noted that feeders are segmented efficiently depending on the number of reclosers to be installed in the network.

Regarding DG penetration, the optimization process seeks for solutions locating reclosers close to DG units with the aim to create microgrids. As an example, consider the solution “C” in which the recloser placed in the line-segment *l17* for case *i*. is relocated in line-segments *l22* and *l21* for cases *ii*. and *iii*., respectively. This allows the formation of an isolated zone (microgrid), with few loads downstream the recloser. When permanent faults arise upstream, a DG unit can supply energy inside this isolated zone, and thus, the system reliability is improved.

Table I. – Samples of non-dominated solutions of C-NSGA-II

CASE	SAIDI (h/a)	ENS (MW/h)	EUAC (\$)	Reclosers Position	
<i>i</i> . 0% DG	A	28.65	238.35	7542	12,130,136
	B	19.15	173.23	15084	12,19,114,126,130,137
	C	15.41	132.13	25140	12,19,114,117,126,129,130,132,136,140
<i>ii</i> . 20% DG	A	25.94	178.78	7542	17,130,137
	B	18.70	122.57	15084	13,115,126,131,139,142
	C	12.97	88.16	25140	13,19,115,122,126,130,132,136,139,142
<i>iii</i> . 60% DG	A	25.25	165.38	7542	18,130,136
	B	17.70	101.44	15084	17,116,127,131,136,140
	C	12.57	81.04	25140	17,19,121,127,131,132,135,136,139,141

Finally, by comparing solutions of the cases *ii*. and *iii*. having the same investment (i.e. similar *EUAC*), evidently case *iii* has solutions with better SAIDI and ENS values than those of case *ii*. As an example, comparing solution

“B” of case *ii* (SAIDI=18.70, ENS=122.57) with “B” of case *iii* (SAIDI=17.70, ENS=101.44), clearly the values for case *iii* are lower than those in case *ii*. Therefore, the solution of case *iii* is better than the one of case *ii*. In consequence, the aforementioned results show that best solutions can be found as the level of DG increases.

7. Conclusion

A methodology that uses a multi-objective approach has been used to address the problem of protection planning of distribution systems. The aim of this method is to find a set of multiple trade-off solution that determine efficient number and placement of reclosers in a distribution network. Those solutions are searched in a way that SAIFI, ENS and EUAC are minimized based on the Pareto dominance concept.

The C-NSGA-II is implemented and applied in the optimization process to find a set of non-constrain-dominated solutions satisfying the constraint established in the optimization problem.

The importance of the protective devices and DG placement has been proved in enhancing reliability and reducing the energy not supplied by means of the results in the simulation cases. Moreover, the optimization of reclosers placement procure the creation of microgrids when islanded mode of DG is allowed. Besides, feeders are efficiently segmented based on the number of reclosers to be placed, and lower SAIDI and ENS values are achieved as the DG penetration level increases. Thus, better non-constrain-dominated solutions can be found.

Coupling of two powerful tools, such as MATLAB and PowerFactory, shows a good approach to solve complex optimization problems related with power systems, as the proposed in this work.

Future work includes developing a methodology to prove by simulation that the solutions found in the C-NSGA-II algorithm belong to the Pareto front and that there are no better solutions in the neighborhood of this front.

Acknowledgement

We would like to thank ALTERNAR Project, BPIN 20130001000089, Acuerdo 005 de 2013, OCAD - Fondo de CTeI – SGR, Colombia and ‘Programa de Jovenes Investigadores e Innovadores - 2016’ of Gobernación de Nariño and CEIBA foundation, for the partial support of this work.

References

- [1] M. Brenna, F. Foiadelli, P. Petroni, G. Sapienza, and D. Zaninelli. Distributed generation regulation for intentional islanding in smart grids. In *2012 IEEE PES Innovative Smart Grid Technologies (ISGT)*, pp 1–6, 2012.
- [2] L. G. W. da Silva, R. A. F. Pereira, J. R. Abbad, and J. R. S. Mantovani. Optimised placement of control and protective devices in electric distribution systems through reactive tabu search algorithm. *Electric Power Systems Research*, Vol. 78, No.3, pp.372–381, 2008.
- [3] M. Hajivand, R. Karimi, M. Karimi, et al. Optimal recloser placement by binary differential evolutionary algorithm to improve reliability of distribution system. *International Journal of Information, Security and SystemsManagement*, Vol. 3, No. 2, pp.345–349, 2014.
- [4] A. Pregelj, M. Begovic, and A. Rohatgi. Recloser allocation for improved reliability of dg-enhanced distribution networks. *IEEE Transactions on Power Systems*, Vol. 21, No. 3, pp.1442–1449, 2006.
- [5] R. E. Brown. *Electric power distribution reliability*. CRC press, 2008.
- [6] K. Deb. *Multi-objective optimization using evolutionary algorithms*, volume 16. John Wiley & Sons, 2001.
- [7] G. D. Ferreira, A. S. Bretas, and G. Cardoso. Optimal distribution protection design considering momentary and sustained reliability indices. In *Modern Electric Power Systems (MEPS), 2010 Proceedings of the International Symposium*, pages 1–8. IEEE, 2010.
- [8] M. R. Mazidi, M. Aghazadeh, Y. A. Teshnizi, and E. Mohagheghi. Optimal placement of switching devices in distribution networks using multi-objective genetic algorithm nsgaii. In *2013 21st Iranian Conference on Electrical Engineering (ICEE)*, pages 1–6. IEEE, 2013.
- [9] W. Tippachon and D. Rerkpreedapong. Multiobjective optimal placement of switches and protective devices in electric power distribution systems using ant colony optimization. *Electric Power Systems Research*, Vol. 79, No. 7, pp.1171–1178, 2009.
- [10] J.-H. Teng and Y.-H. Liu. A novel acs-based optimum switch relocation method. *IEEE transactions on power systems*, Vol. 18, No. 1, pp.113–120, 2003.
- [11] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE transactions on evolutionary computation*, Vol. 6, No. 2, pp.182–197, 2002.
- [12] A. Stativˆa, M. Gavrilas, and V. Stahie. Optimal tuning and placement of power system stabilizer using particle swarm optimization algorithm. In *Electrical and Power Engineering (EPE), 2012 International Conference and Exposition on*, pages 242–247. IEEE, 2012.
- [13] C. A. C. Coello. Recent trends in evolutionary multiobjective optimization. In *Evolutionary Multiobjective Optimization*, pages 7–32. Springer, 2005.
- [14] IEEE Std. 1547-2003. IEEE Standard for interconnecting Distributed resources with electric power systems, 2003.
- [15] R. Billinton and S. Jomavithula. A test system for teaching overall power system reliability assessment. *IEEE Transactions on Power Systems*, Vol. 11, No. 4, pp.1670–1676, 1996.
- [16] R. N. Allan, R. Billinton, I. Sjarief, L. Goel, and K. So. A reliability test system for educational purposes-basic distribution system data and results. *IEEE Transactions on Power Systems*, Vol. 6, No. 2, pp.813–820, 1991.

ANEXO 1.1 CARTA DE ACEPTACIÓN.



European Association for the
Development of Renewable Energies,
Environment and Power Quality

Vigo, 5th December, 2016

REFERENCE OF THE PAPER: 306-lopez

TITLE and AUTHORS: Optimization of Recloser Placement in DG-Enhanced Distribution Networks Using a Multi-Objective Optimization Approach
Fabián López, Andrés Pantoja

I would like to thank to the authors for proposing a paper for the "*International Conference on Renewable Energies and Power Quality (ICREPQ'17)*". The number of papers that can be presented in the Conference is limited. For this reason, the International Scientific Committee found it necessary to decline some of the papers. This was a difficult task in view of the quality of the submitted proposals. Each digest/provisional full paper was evaluated by two referees, peer review, and the papers submitted were selected on the following bases: *originality, interest, quality, elaboration, references and objectives/conclusions*.

Take into account these bases the members of the International Scientific Committee have expressed a global conclusion about each paper like: *excellent, good, average, poor, bad or very bad*, and sometimes they send us some remarks for the authors.

After the Reviewing Process, I am very delighted to inform you that the **ICREPQ International Scientific Committee** has reviewed your paper and it **HAS BEEN ACCEPTED** for the presentation at ICREPQ'17.

Congratulations on your fine contribution and it's my pleasure to invite you to attend at ICREPQ'17 that will be held in Malaga (Spain) from 4th to 6th of April, 2017, for to present your paper.

Best regards.

Manuel Pérez-Donsión
Chairman of the ICREPQ Steering Committee

Fiscal Address: C/ Ramón Aller, 83 ; Entrepantana C, 36500 Lalín, Pontevedra (Spain)
RNA N°. 169208 C.I.F.: G36415636

ANEXO 1.2 CERTIFICADO DE ASISTENCIA Y PRESENTACIÓN DEL ARTICULO DE INVESTIGACIÓN.



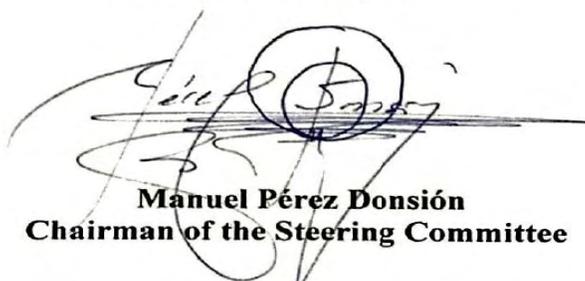
WE HEREBY CERTIFY THAT

Mr: Fabián Marcelo López

Has attended at the '*International Conference on Renewable Energies and Power Quality (ICREPQ'17)*', that has been held in the "Escuela Técnica Superior de Ingeniería Industrial". University of Málaga (Spain), from 4th to 6th of April, 2017 and presented the paper(s):

Optimization of Recloser Placement in DG-Enhanced Distribution Networks Using a Multi-Objective Optimization Approach

Málaga, 6th of April 2017



Manuel Pérez Donsión
Chairman of the Steering Committee



ANEXO 2. POSTER ENCUESTO DEPARTAMENTAL DE CIENCIA, TECNOLOGÍA E INNOVACIÓN.



RESUMEN
 La ubicación eficiente de dispositivos de protección en redes eléctricas de distribución es necesaria con el fin de lograr un sistema confiable y proporcionar un suministro de energía continuo a los clientes tanto como sea posible. La operación en isla con **generación distribuida (GD)** proporciona una forma de reducir la **energía no suministrada (ENS)**, sin embargo, es necesaria la ubicación de dispositivos de protección, con el fin de permitir que el sistema logre este modo de operación. Esta investigación presenta un método de optimización **multi-objetivo** para ubicar eficientemente reconectores normalmente cerrados en redes de distribución eléctrica con GD por medio del Algoritmo Genético de Ordenación No-Dominada con restricciones (C-NSGA-II) [1], con el fin de reducir SAIDI, ENS y los costos de inversión. Un enfoque de **co-simulación** es utilizado de tal modo que el sistema de potencia es modelado en PowerFactory, mientras que MATLAB es utilizado en la implementación del C-NSGA-II. Una red de distribución de prueba es utilizada para realizar simulaciones de diferentes casos de estudio, mostrando la eficiencia del método de optimización propuesto. Finalmente, los resultados muestran la importancia de los dispositivos de protección y la GD en el mejoramiento de la confiabilidad del sistema y la reducción de la energía no suministrada.

Palabras claves: Co-simulación, confiabilidad de sistemas de distribución, generación distribuida, optimización multi-objetivo, sistemas de protección.

CONTEXTO
 Una prioridad de cualquier empresa de distribución es satisfacer los requerimientos de seguridad, confiabilidad y calidad en el suministro de energía eléctrica. Esto se puede lograr a través de algunos subsistemas asociados a la red de distribución, entre los cuales, el sistema de protección es el más importante debido a su capacidad de eliminar y aislar fallas. En lo que respecta a la confiabilidad del sistema, un suministro continuo de energía hacia los clientes se hace necesario con el fin de mejorar los índices de confiabilidad y reducir la energía no suministrada (ENS). Para lograr este objetivo, se requiere de la automatización en el sistema de distribución con el propósito de aislar las fallas dentro del sistema tan rápido como sea posible, ofreciendo la posibilidad de que la generación distribuida pueda operar en modo aislado, la cual es una importante función requerida para las futuras **Smart Grids** [2].
 Con el fin de lograr un adecuado balance entre los recursos financieros y los requerimientos técnicos de la red de distribución, un análisis de costo/beneficio del sistema de protección debe ser considerado. Con estas condiciones, la empresa de distribución tiene la tarea de satisfacer dos objetivos en conflicto: **minimizar los costos económicos y maximizar la confiabilidad de la red**. El número y la ubicación de dispositivos de protección son variables críticas para cumplir con estos dos objetivos. Así, la contribución de esta investigación es tratar con la planeación de sistemas de protección basados en reconectores normalmente cerrados (RNCs). Estos dispositivos son capaces de aislar secciones afectadas por alguna falla y también pueden ser usados para permitir la operación aislada de redes con GD por medio de acciones automáticas logrando así el restablecimiento del servicio de energía eléctrica a ciertas zonas de la red de distribución.

OBJETIVOS
OBJETIVO GENERAL:
 - Desarrollar un algoritmo de optimización multiobjetivo, usando técnicas de optimización heurísticas, con el fin de encontrar la ubicación óptima de reconectores dentro de redes eléctricas con generadores distribuidos.
OBJETIVOS ESPECÍFICOS :
 - Realizar un estudio comparativo de las diferentes técnicas heurísticas que son usadas en la solución de problemas de optimización multi-objetivo.
 - Proponer un modelo matemático de optimización en función de índices de confiabilidad de la red eléctrica y el costo de los dispositivos de protección.
 - Desarrollar un algoritmo de optimización que resuelva el modelo matemático definido y comprobar su funcionamiento a través de simulaciones por computadora.
 - Utilizar el algoritmo propuesto para encontrar la ubicación óptima de protecciones dentro de la red eléctrica del campus de la Universidad de Nariño en una estructura de microrred.

METODOLOGÍA
Fase 1. Revisión bibliográfica.
Fase 2. Estudio técnico y observación.
Fase 3. Formulación del modelo matemático de optimización.

$$\begin{aligned} \min \quad & SAIDI(X), ENS(X), EUAC(X) \\ \text{subject to} \quad & 1 - \frac{EUAC(X)}{EUAC_{max}} \geq 0, \\ & x_i \in \{0,1\} \end{aligned}$$

donde,

$$SAIDI = \frac{\sum_{i=1}^k ACIT_i C_i}{\sum_{i=1}^k C_i}$$

$$ENS = \sum_{i=1}^k ACIT_i P d_i$$

$$EUAC = AOC + \left[\frac{d_r(1 + d_r)^{t_r}}{(1 + d_r)^{t_r} - 1} \right] R_p N_r$$

Figura 4. Desarrollo y prueba del algoritmo de optimización.

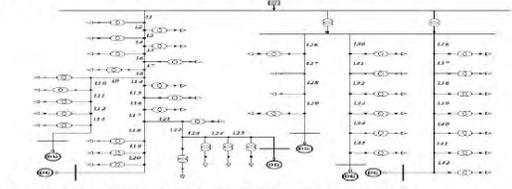


Figura 1. Red de distribución de prueba (RBT) con penetración de GD.

Figura 5. Ubicación óptima de protecciones en la red eléctrica del campus de la Universidad de Nariño.

Figura 6. Publicación y divulgación de resultados

RESULTADOS

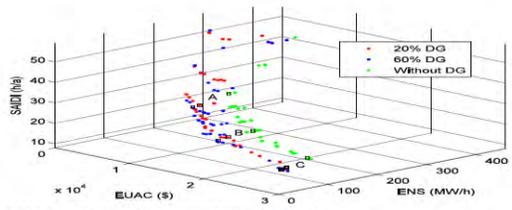


Figura 2. Conjunto de soluciones factibles no dominadas.

CONCLUSIONES

Una metodología que usa un enfoque multi-objetivo es usada para tratar con el problema de planeación de protecciones en sistemas de distribución. La metodología sirve para encontrar un conjunto de soluciones eficientes que determinan el número y la ubicación de reconectores dentro de una red de distribución ya sea equipada o no con GD.
 La importancia de los dispositivos de protección y la GD en el mejoramiento de la confiabilidad del sistema y la reducción de la energía no suministrada ha sido mostrada con los resultados de los casos de simulación.
 La optimización de la ubicación de reconectores procura la creación de microrredes mientras sea posible el funcionamiento aislado de la GD. Además, los alimentadores son eficientemente segmentados según el número de reconectores a ser ubicados.
 El acople de dos herramientas robustas como MATLAB y PowerFactory muestra un buen enfoque para resolver problemas de optimización complejos relacionados con sistemas de potencia, como el tratado en esta investigación.

REFERENCIAS

[1] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan. A fast and elitist multi-objective genetic algorithm: Nsga-ii. IEEE transactions on evolutionary computation, Vol. 6, No. 2, pp.182–197, 2002.
 [2] M. Brenna, F. Foiadelli, P. Petroni, G. Sapienza, and D. Zaninelli. Distributed generation regulation for intentional islanding in smart grids. In 2012 IEEE PES Innovative Smart Grid Technologies (ISGT), pp 1–6, 2012.

