



UNIVERSIDAD POLITÉCNICA SALESIANA

SEDE QUITO

CARRERA DE ELECTRICIDAD

**OPTIMIZACIÓN DE LOS TIEMPOS DE DISPARO EN LA COORDINACIÓN
ADAPTATIVA DE PROTECCIONES DE SOBRECORRIENTE EN REDES DE
DISTRIBUCIÓN CON GENERACIÓN DISTRIBUIDA MEDIANTE APRENDIZAJE
POR REFUERZO PROFUNDO.**

Trabajo de titulación previo a la obtención del
Título de Ingeniero Eléctrico

AUTOR: ALEX DARIO TASINCHANA YUGCHA

TUTOR: CARLOS ANDRÉS BARRERA SINGAÑA

Quito -Ecuador

2026

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE
TITULACIÓN**

Yo, Alex Dario Tasinchana Yugcha con documento de identificación N° 1750307264 manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Quito, 12 de enero de 2026

Atentamente,

A handwritten signature in blue ink, consisting of several overlapping loops and strokes, positioned above a horizontal dashed line.

Alex Dario Tasinchana Yugcha
1750307264

CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA

Yo, Alex Dario Tasinchana Yugcha con documento de identificación No. 1750307264, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del Artículo Académico “Optimización de los tiempos de disparo en la coordinación adaptativa de protecciones de sobrecorriente en redes de distribución con generación distribuida mediante aprendizaje por refuerzo profundo”, el cual ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito, 12 de enero de 2026

Atentamente,



Alex Dario Tasinchana Yugcha
1750307264

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Carlos Andrés Barrera Singaña con documento de identificación N° 0503503336, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: OPTIMIZACIÓN DE LOS TIEMPOS DE DISPARO EN LA COORDINACIÓN ADAPTATIVA DE PROTECCIONES DE SOBRECORRIENTE EN REDES DE DISTRIBUCIÓN CON GENERACIÓN DISTRIBUIDA MEDIANTE APRENDIZAJE POR REFUERZO PROFUNDO, realizado por Alex Dario Tasinchana Yugcha con documento de identificación N° 1750307264, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 12 de enero de 2026

Atentamente,



Ing. Carlos Andrés Barrera Singaña, MSc
0503503336

ÍNDICE GENERAL

1	Introducción	2
2	Redes de distribución con GD.....	3
2.1	Propiedades de las protecciones eléctricas	3
2.2	Curvas normalizadas IEC 60255-151	4
2.2.1	Curva normalmente inversa (NI).....	4
2.2.2	Curva muy inversa (MI).....	4
2.2.3	Curva extremadamente inversa (EI).....	4
2.3	Criterios para el ajuste para las protecciones de sobrecorriente	4
2.3.1	Ajuste del relé tiempo inverso.....	4
2.3.2	Ajuste del relé a tierra	5
2.3.3	Coordinación del tiempo intervalo (CTI).....	5
3	Planteamiento y solución del problema.....	5
3.1	Sistema de Prueba.....	6
3.2	Metodología - Algoritmo de aprendizaje por refuerzo profundo	7
3.3	Algoritmo Deep Deterministic Policy Gradient	8
3.3.1	Incorporación del algoritmo Deep Deterministic Policy Gradient (DDPG)	8
3.3.2	Función Objetivo.....	8
3.4	Restricciones para el ajuste de la protección	9
3.5	Restricción de selectividad	9
3.6	Formulación matemática del algoritmo Deep Deterministic Policy Gradient.....	10
3.7	Configuración del sistema de prueba IEEE 33 barras con GD.....	11
4	Casos de estudio	13
4.1	Escenario 1	14
4.2	Escenario 2	16
4.3	Escenario 3	20
5	Análisis de resultados.....	24
5.1	Caso 1 sin GD.....	24
5.2	Caso 2 con GD en (10,30 y 24)	24
5.3	Caso 3 con GD en (10,30 y 19)	24
6	Conclusiones	24
7	Trabajos Futuros.....	25
8	Referencias	25
8.1	Matriz de Estado del Arte.....	28

8.2	Resumen de indicadores	32
9	Anexos.....	33

ÍNDICE DE FIGURAS

Figura 1. Sistema de prueba IEEE 33 barras con GD	7
Figura 2. Configuración genérica para la GD fotovoltaica	12
Figura 3. Caso 1 sin GD	14
Figura 4. Falla trifásica nodo 13 sin DDPG	15
Figura 5. Falla trifásica nodo 13 con DDPG	15
Figura 6. Escenario 2 con GD	16
Figura 7. Falla trifásica barra 11 relé A-B sin DDPG	17
Figura 8. Falla trifásica barra 11 relé A-B con DDPG	17
Figura 9. Falla trifásica barra 33 relé A-C sin DDPG	18
Figura 10. Falla trifásica barra 33 relé A-C con DDPG	18
Figura 11. Falla trifásica barra 25 relé A-D sin DDPG	19
Figura 12. Falla trifásica barra 25 relé A-D con DDPG	19
Figura 13. Caso 3 con GD	20
Figura 15. Falla trifásica barra 14 relé A-B con DDPG	21
Figura 14. Falla trifásica barra 14 relé A-B sin DDPG	21
Figura 17. Falla trifásica barra 33 relé A-C con DDPG	22
Figura 16. Falla trifásica barra 33 relé A-C sin DDPG	22
Figura 18. Falla trifásica barra 22 relé A-D sin DDPG	23
Figura 19. Falla trifásica barra 22 relé A-D con DDPG	23
Figura 21. Indicador de la solución propuesta estado del arte	32
Figura 22. Indicador de formulación del problema-Estado del arte	32
Figura 20. Indicador de la temática estado del arte	32

ÍNDICE DE TABLAS

Tabla 1: Parámetros característicos de las curvas IEC	4
Tabla 2: Parámetros de la generación distribuida caso 2	13
Tabla 3: Parámetros de la generación distribuida caso 3	13
Tabla 4: Ajustes para el escenario 1	14
Tabla 5: Ajustes para el escenario 2	16
Tabla 6: Ajustes para el escenario 3	20
Tabla 7: Matriz de estado del arte	28
Tabla 8: Parámetros de la red IEEE 33 barras	33

OPTIMIZACIÓN DE LOS TIEMPOS DE DISPARO EN LA COORDINACIÓN ADAPTATIVA DE PROTECCIONES DE SOBRECORRIENTE EN REDES DE DISTRIBUCIÓN CON GENERACIÓN DISTRIBUIDA MEDIANTE APRENDIZAJE POR REFUERZO PROFUNDO

Resumen

La presente investigación tiene como objetivo el diseño de un modelo de coordinación adaptativa de protecciones que se basa en la optimización de la corriente de arranque (I_s) y del dial de tiempo (TMS) de los relés de sobrecorriente (OCR), para lo cual se hizo uso del algoritmo de aprendizaje por refuerzo profundo, específicamente el Deep Deterministic Policy Gradient (DDPG) quien se encarga de tomar valores calculados bajo la norma IEC 60909 y escoger dos ajustes ideales para cada relé, esto se cumple a través del aprendizaje del algoritmo con el propósito de cumplir con la función objetivo, respetando las restricciones dadas al algoritmo y penalizando los tiempos de operación elevados, teniendo de esta manera un tiempo de actuación más rápido, sensible y selectivo al método tradicional. La metodología propuesta se implementó en un sistema IEEE de 33 barras con generación distribuida (GD) en el entorno de Python e integrando Pandapower y considerando cambios topológicos del sistema para verificar la eficiencia del modelo.

Palabras clave: Relé sobrecorriente (OCR), coordinación adaptativa, sistema de transmisión, algoritmo de aprendizaje por refuerzo profundo (DRL), corriente de arranque (I_s), dial de tiempo (TMS).

Abstract

This research aims to design an adaptive protection coordination model based on optimizing the starting current (I_s) and time-switching time (TMS) of overcurrent relays (OCRs). This was achieved using a deep reinforcement learning algorithm, specifically the Deep Deterministic Policy Gradient (DDPG). This algorithm takes values calculated according to the IEC 60909 standard and selects two ideal settings for each relay. This is accomplished through algorithm learning, ensuring the model fulfills its objective function while respecting the algorithm's constraints and penalizing excessive operating times. The result is a faster, more sensitive, and more selective response time compared to the traditional method. The proposed methodology was implemented in a 33-bus IEEE system with distributed generation (DG) using Python and integrating PandaPower, Topological changes to the system were also considered to verify the model's efficiency.

Keywords: Overcurrent relay (OCR), adaptive coordination, transmission system, deep reinforcement learning (DRL) algorithm, starting current (I_s), time dial (TMS).

1 Introducción

En los últimos años la energía eléctrica se ha vuelto un recurso indispensable para la sociedad, el crecimiento sostenido de la demanda ha provocado la expansión de las redes eléctricas de distribución y con ello la necesidad de requerir más generación para cubrir este aumento en la demanda, en la actualidad es importante contar con sistema de protecciones bien parametrizadas, esto se lo hace a través de dispositivos de protección como los relés sobrecorriente mismos que ayudan a mitigar daños severos ante fallas eléctricas y proteger al sistema para que pueda garantizar una operación segura y eficiente del sistema eléctrico de potencia.

La generación distribuida (GD) se ha consolidado como una de las alternativas más rápidas y seguras debido a los múltiples beneficios que esta posee como reducción de pérdidas, mejoras en los perfiles de voltaje, menor impacto ambiental o mejorar la calidad de energía, etc., es por ello que este tema es uno de los más estudiados debido al gran impacto que pueden aportar hacia la red eléctrica [1], en vista de eso varias investigaciones han podido demostrar que la implementación de GD contribuye también al aumento o decremento de la corriente de falla en distintos puntos del sistema haciéndolo susceptible a cambios en la dirección de la corriente o pérdida de selectividad en los relés [2],

Históricamente los sistemas de protecciones han sido diseñados para redes de distribución tradicionalmente radiales, cuyo flujo de carga se dirige de un extremo hacia el usuario final, pero con la implementación de la GD los parámetros usados para los ajustes de los relés de sobrecorriente se ven afectados por la inclusión de esta nueva tecnología [2], los OCR están definidos bajo ciertos criterios de parametrización los mismos que brindan un esquema de

coordinación de protecciones óptima, sus parámetros de ajuste son la corriente de arranque o pickup y el dial de tiempo [5].

En consecuencia, los ajustes tradicionales para los relés dejan de ser validos o requieren ser recalculados para garantizar una operación rápida, selectiva y confiable para la red eléctrica, debido a esto algunos investigadores optan por sugerir nuevas metodologías en la coordinación de relés de protecciones de sobrecorriente basado en redes neuronales [1], algoritmos híbridos [3], técnicas heurísticas [4], etc., todo eso con el fin de poder mantener una protección adecuada para el sistema eléctrico de potencia, no obstante muchas de estas soluciones presentan una convergencia lenta, alta complejidad computacional o los casos están reducidos a un único escenario operativo lo que dificulta en su implementación en redes reales de alta variabilidad.

En respuesta a esta problemática el presente estudio propone un modelo de coordinación adaptiva de protecciones de sobrecorriente basado en técnicas de aprendizaje por refuerzo profundo. Para este estudio se implementó el Deep Deterministic Policy Gradient (DDPG) dado que este algoritmo forma parte la familia de métodos de aprendizaje por refuerzo profundo (DRL) porque esta metodología combina el aprendizaje por refuerzo y el uso de redes neuronales profundas de modo que permita determinar ajustes óptimos para la parametrización de los relés de sobrecorriente temporizado [6]. Se consideró esta opción debido a que existen estudios realizados como es el caso de [7] en donde utiliza el mismo algoritmo pero enfocado a otro ámbito demostrando que la metodología puede ser una opción factible para el desarrollo de este trabajo.

El algoritmo DDPG permite encontrar los ajustes óptimos para cada relé de acuerdo a

cada GD en el sistema IEEE 33 barras [8], para ello la metodología emplea una arquitectura de aprendizaje por refuerzo profundo basada en dos redes neuronales Actor y Critico [9]. La red actor es la encargada de entregar una I_s y TMS optimizada dentro de los límites técnicos establecidos, mientras que la red critico evalúa su desempeño en cuanto a la sensibilidad, selectividad y rapidez que esta respuesta podría ofrecer. La evaluación de la respuesta se realiza tomando en cuenta las corrientes de cortocircuito calculadas bajo la norma IEC 60909 con la curva de tiempo normalmente inversa, de modo que el algoritmo asigna una recompensa premiando tiempos bajos y penalizando tiempos altos, por consiguiente los resultados obtenidos de la metodología son en función de la política aprendida por el agente misma que respeta la función de optimización y criterios de sensibilidad, verificando que cumpla con el tiempo de coordinación (CTI) el cual es un intervalo de coordinación que existe entre el relé principal y el respaldo [10].

El entorno de simulación utilizado en este proyecto es Python, utilizando la librería Pandapower para el modelado de la red, flujos de carga y el cálculo de cortocircuito trifásicos conforme a la norma IEC 60909 garantizando una corriente de cortocircuito precisa como lo haría PowerFactory y facilitando la integración del algoritmo DDPG.

Por todo lo expuesto el presente artículo tiene como objetivo proponer y validar una metodología de coordinación adaptativa basada en aprendizaje profundo, capaz de ajustar automáticamente los parámetros de operación de los relés de sobrecorriente a partir de los datos proporcionados por la red. De esta forma se presenta o una metodología alternativa novedosa y diferente frente a los enfoques tradicionales demostrando así que los parámetros para el

ajuste de dispositivos de protección pueden ser automatizados utilizando nuevos enfoques demostrando que es posible tener protecciones que se adapten a redes de distribución complejas pero que aún mantengan sensibilidad, selectividad y rapidez para poder actuar frente a cualquier tipo de anomalía que pueda presentarse en el sistema eléctrico de potencia.

2 Redes de distribución con GD

En la actualidad la presencia de generación distribuida en las redes de distribución modernas ha transformado la forma en la que se operan y protege. Debido a que la potencia fluye desde un punto de generación hacia las cargas. Las GD son implementadas cerca a los usuarios finales como áreas residenciales, centros comerciales o industrias basados en energías renovables como fotovoltaica o eólica [11]. Al usar esta nueva tecnología ayuda en la mejora en los perfiles de voltaje, mejor calidad de energía etc., pero a su vez puede ocasionar que las corrientes de cortocircuitos aumenten y provocar cambios en los flujos de carga lo que obliga a una reestructuración en los ajustes del sistema de protecciones.

2.1 Propiedades de las protecciones eléctricas

Frente a este contexto los sistemas de protecciones eléctricas son diseñados para detectar y despejar fallas eléctricas en distintos tramos de la red para los cuales fueros ajustados, estos equipos actúan sumamente rápido para garantizar la seguridad y preservar la estabilidad del sistema. Para lograrlo estos dispositivos deben satisfacer criterios como sensibilidad que es la capacidad para identificar corrientes de falla por más pequeñas que sean, selectividad que garantiza que un único dispositivo actúe en la zona para la que fue ajustada y rapidez, que debe tener sistema de protecciones para despejar la

falla en el menor tiempo posible después de haber detectado una anomalía, su principal objetivo es limitar el daño a los equipos aguas arriba de la falla y preservar la integridad de la red [5], [12].

La incorporación de GD altera las propiedades que tienen estos dispositivos, ya que modifica los niveles y la dirección de la corriente de falla afectando directamente los ajustes de la corriente de pick up (I_s) y del dial de tiempo (TMS) las cuales definen las curvas de operación de los relés de sobrecorriente [13]. Como consecuencia estos dispositivos dejan de garantizar suficientes intervalos de tiempo de coordinación (CTI) entre el relé principal y respaldo. Es por ello que el análisis y la reformulación del problema no se limita a una descripción normativa, sino que se forma como un problema de optimización sujeto a restricciones físicas y operativas

2.2 Curvas normalizadas IEC 60255-151

Las curvas de la IEC tiempo vs corriente son muy utilizadas en la protección de sistemas eléctricos de potencia, es por ello que las mismas son normalizadas por la IEC por su precisión y adaptabilidad ante diferentes condiciones que puede presentar un sistema eléctrico.

Tabla 1: Parámetros característicos de las curvas IEC

Curva IEC	α	β	L
NI	0.02	0.14	0
MI	1	13.5	0
EI	2	80	0

2.2.1 Curva normalmente inversa (NI)

Esta curva es una de las más usadas debido a que la corriente de falla aumenta por encima de la corriente de arranque I_s y el

tiempo de despeje de la falla disminuye de forma inversa, debido a esto es muy utilizada en redes de distribución generales o radiales donde se requiere una respuesta rápida ante anomalías [14].

2.2.2 Curva muy inversa (MI)

La curva muy inversa es caracterizada porque posee un comportamiento más pronunciado que la normalmente inversa, esta es utilizada para corrientes ligeramente superiores a la corriente de arranque y el tiempo de operación es realmente rápido. Este tipo de curvas permite tener una mejor coordinación con relés aguas abajo porque son ideales para fallas lejanas [14].

2.2.3 Curva extremadamente inversa (EI)

Este tipo de curva es una de las más agresivas porque posee una pendiente más pronunciada, por lo que para corrientes pequeñas cercanas a la corriente de arranque es bastante lento en su activación por otra parte para corrientes de cortocircuito sumamente altas es muy rápido [14].

2.3 Criterios para el ajuste para las protecciones de sobrecorriente

En la parametrización de los equipos de protección se pueden encontrar diversos criterios y ajustes dependiendo de la norma, es por ello que para el presente trabajo se optó por los criterios más usados para este tipo de redes.

2.3.1 Ajuste del relé tiempo inverso

$$I_s' = OLF * I \quad (1)$$

Para realizar el ajuste se propone la ecuación (1), en donde OLF es el factor de sobrecarga que está dentro del rango 120% a 150% en donde este valor puede cambiar dependiendo de la ubicación del relé en la red, se sugiere que la corriente I_s' sea menor

al 50% de la corriente de corto circuito I_{cc} en el punto más lejano.

El criterio también establece que para determinar el dial de tiempo (TMS) según se establece en la ecuación (2) y también se debe considerar un margen de discriminación según la tecnología del relé [15].

$$t = \frac{\beta * TMS}{\left(\frac{I}{I_s}\right)^\alpha - 1} + L \quad (2)$$

Donde:

I: corriente de cortocircuito

I_s : corriente de pickup o arranque

t: tiempo de operación

TMS: dial de tiempo

Nota: α , β y L son parámetros que están definidos de acuerdo a los tipos de curvas características de la IEC mostrados en la tabla 1.

2.3.2 Ajuste del relé a tierra

$$I_s' = OLF * I_n \quad (3)$$

En la ecuación (3) el factor de sobrecarga va cambiar por tratarse de una falla monofásica a tierra, en la cual va variar entre 20% y 60% de la corriente nominal, es por ello que I_s' se sugiere que sea menor al 30% de la corriente de cortocircuito monofásica en el punto más lejano de la red. Para el cálculo del dial de tiempo se lo realiza mediante ecuación (2), pero es importante considerar el cortocircuito entre el 80% y 90% de la línea [16].

2.3.3 Coordinación del tiempo intervalo (CTI)

El intervalo de coordinación de tiempo se define como el tiempo mínimo de separación que debe tener entre el relé principal y el relé de respaldo para que

permita asegurar que solo un dispositivo opere ante una falla cerca, esto ayuda a evitar que existan disparos no deseados durante una operación normal del sistema [15],[17].

3 Planteamiento y solución del problema

El problema de estudio nace del creciente uso de la generación distribuida en los sistemas eléctricos tradicionales, provocando que exista cambios que afecten a la red convencional. Esta tecnología si bien aporta beneficios operativos también causa inconvenientes hacia los sistemas de protección eléctrica, especialmente en los relés de sobrecorriente (50/51).

Tradicionalmente estos equipos son parametrizados de forma estática por medio de la corriente de arranque (I_s) y dial de tiempo (TMS), los cálculos realizados para ello son en función de suposiciones con flujos unidireccionales sin embargo con la integración de la GD estos flujos pueden verse afectados convirtiéndolos en unidireccionales y provocando que los parámetros de los relés estén sujetos a cambios.

Debido a esto los ajustes tradicionales dejan de ser adecuados obligando a volverlos a calcular y parametrizar. Es por ello que se optó por utilizar el sistema IEEE de 33 barras el cual es un sistema de los más frecuentes para estudios de protección y añadiendo GD lo hace un caso de estudio interesante, para enfrentar esta problemática varias investigaciones hacen uso de técnicas de aprendizaje por refuerzo profundo como [24], a más de ello [25] presenta una coordinación operativa basada en DRL que decide si operar o no ante fallas en función de las condiciones locales de cada relé, también [26] realiza una coordinación adaptativa basado en

entrenamiento offline de la red y usando estructuras de comunicación como RTUs y canales híbridos de fibra/PLC y con ello hace que se abra una brecha de estudio para lograr una óptima parametrización usando DRL como una alternativa prometedora. Es por ello que el presente trabajo plantea el desarrollo de un modelo adaptativo de protecciones mediante el algoritmo Deep Deterministic Policy Gradient (DDPG) el cual forma parte de la familia de DRL permitiendo obtener parámetros óptimos de Is y TMS para los relés ubicados de acuerdo a cada GD en el sistema de 33 barras.

El agente se entrena en un entorno de simulación desarrollado en Python utilizando la librería Pandapower, con la cual se realiza todos los cálculos de flujo de carga, cortocircuitos, todo esto se lleva a cabo bajo la norma IEC 60909 y a partir de esas corrientes parametrizar los relés de forma manual y usando el agente poder encontrar nuevos ajustes y evaluarlos para validar los tiempos de disparo. La función objetivo empleada en la metodología combina la minimización del tiempo de despeje de falla de cada relé con penalización relacionadas con el CTI y castiga a valores altos de Is y TMS, haciendo que el algoritmo aprenda ajustes óptimos que respeten las restricciones físicas de la parametrización del relé, también mantienen la selectividad y se adaptan cuando existan cambios topológicos de la GD o su reubicación.

La metodología empleada en este estudio se valida mediante múltiples escenarios de cortocircuito evidenciando la capacidad que el modelo tiene para mantener buena parametrización y en función de las gráficas tiempo – corriente se observará los tiempos de actuación de cada relé para verificar la eficiencia de la metodología propuesta para la solución a este problema que esta

presente en las redes actuales de distribución.

3.1 Sistema de Prueba

En este trabajo se utiliza como red de prueba el sistema IEEE de 33 barras, debido a que es un modelo ampliamente usado para análisis de flujos de carga, estudios de cortocircuito y estudios de sistemas con generación distribuida. El sistema opera a un nivel de voltaje de 12.66 kV y los datos usados para la recreación de la red fueron tomados de [8], el mismo que considera una configuración radial ideal para los propósitos de este estudio debido a que permite analizar con claridad el desempeño de los ajustes de cada relé de sobrecorriente de acuerdo a su topología. La red presenta configuraciones operativas realistas lo que ayuda en el análisis del desempeño de los ajustes de cada relé de sobrecorriente en función de la topológica u las condiciones d carga del sistema.

Sobre este sistema de prueba se agregaron fuentes de generación distribuida en barras específicas para establecer distintos escenarios de estudio, para el primer caso de estudio es sistema se analizó sin presencia de GD a modo de escenario base de los siguientes escenarios, en el segundo caso ya se considera la presencia de GD ubicadas en las barras 10,30,24 y como tercer caso las GD son reubicadas en las barras 10,30 y 19.

Esta incorporación gradual de escenarios permite evaluar comparativamente los resultados obtenidos mediante la metodología tradicional y los resultados del DDPG para verificar sensibilidad, selectividad, rapidez y adaptación del nuevo enfoque hacia el sistema de distribución.




Figura 1. Sistema de prueba IEEE 33 barras con GD

Cada generación distribuida opera con distintos parámetros y con un factor de potencia cercano a la unidad, a partir de este caso se puede modificar la red para realizar nuevas pruebas y crear distintos escenarios a los propuestos. Dentro del entorno de Python la GD se puede habilitar o deshabilitar e inclusive cambiar los parámetros técnicos de las unidades generadoras. El modelo permite simular fallas monofásicas o trifásicas en barras cercanas o lejanas usando las corrientes calculadas según la IEC 60909 dentro del mismo script de Python.

A más de ello cada generación distribuida cuenta con una protección asociada a la barra donde está conectada y de ese modo el agente DDPG ajusta las corrientes de arranque (I_s) y dial de tiempo (TMS) para cada relé en función del tipo de falla y condiciones del sistema según el escenario propuesto.

3.2 Metodología - Algoritmo de aprendizaje por refuerzo profundo

El algoritmo de aprendizaje por refuerzo profundo (Deep Reinforced Learning) o conocido por sus siglas DRL es una de las técnicas que ocupa inteligencia artificial en el cual un agente aprende a tomar decisiones por su cuenta mediante prueba y error, esto lo hace al interactuar con el entorno que lo rodea y mejorando a partir de las acciones adquiriendo experiencia. La idea es muy similar a como una persona aprende y diferencia lo bueno de lo malo [7],[18].

El agente observa un estado del entorno puede ser una variable discreta o continua y toma una acción que esta recibirá una recompensa que indica si es una buena o mala decisión, esto lo hará repetidas veces durante varios escenarios de prueba [7],[18].

Esta metodología combina dos escenarios:

Reinforced que consiste en el aprendizaje basado en experiencia.

Deep Learning que procesa grandes cantidades de información por medio de redes neuronales que ayudan a resolver problemas complejos usando variables continuas.

3.3 Algoritmo Deep Deterministic Policy Gradient

El Deep Deterministic Policy Gradient (DDPG) es un algoritmo de aprendizaje por refuerzo profundo de tipo actor – crítico que está diseñado para resolver problemas de tipo continuo, en donde las variables no son fijas como corrientes, voltajes, ángulos o tiempos. Es por ello que el actor es una red neuronal que da una respuesta continua determinista mientras que el crítico es otra red neuronal que valora que tan buena o mala es la respuesta que da el actor, esto se evalúa mediante una función $Q(s, a)$. Mientras actor-crítico estén trabajando juntos se almacena la experiencia en un replay buffer y la metodología las reutiliza varias veces para alcanzar la función objetiva dada, a más de ello el DDPG combina la idea de políticas deterministas con las funciones de valor aproximadas de las redes profundas lo que ayuda a mejorar el aprendizaje en los espacios de acción continuo de un sistema complejo [19], [20].

3.3.1 Incorporación del algoritmo Deep Deterministic Policy Gradient (DDPG)

Para la integración del algoritmo DDPG en coordinación de relés de protección se hizo uso de Python con Pandapower los cuales son los encargados de construir la red IEEE de 33 barras con GD y realizar cortocircuitos en cada barra para poder obtener las corrientes I_k'' según la norma IEC 60909, con todo ello se procede a parametrizar los relés obteniendo una

corriente de arranque (I_s) y dial de tiempo (TMS) calculados manualmente para cada relé ubicado en la red, sobre todo esto se construye un entorno de aprendizaje por refuerzo profundo en donde el DDPG observa el estado del problema y propone los ajustes óptimos para cada relé [19].

Dentro del entorno actor – crítico implementado en el proyecto ambas redes trabajan en equipo para poder encontrar los mejores ajustes para cada relé, primero se definen los límites superiores e inferiores mediante los cálculos manuales, la red actor utiliza esos límites y comienza a proponer valores dentro del rango permitido en donde la red crítica evalúa que tan buena es la combinación, en función de esa evaluación el algoritmo penaliza soluciones en donde I_s y TMS es muy alta o el agente premia aquellas respuestas en donde I_s y TMS son bajas, para la función de la recompensa la red crítica se entrena tanto a sí misma como al actor de forma que a lo largo de un número determinado de episodios de prueba y error la red actor aprende a proponer I_s y TMS cada vez más adecuados hasta llegar a una solución óptima inclusive con la ubicación o reubicación de la generación distribuida [21].

3.3.2 Función Objetivo

$$FO = \min \sum_{i=1}^n t_i \quad (4)$$

La función objetivo (FO) se define en la ecuación (4) en donde:

t_i : es el tiempo de operación del relé i
 n : número de relés parametrizados

Diversos trabajos relacionados al estudio de protecciones eléctricas utilizan la función objetiva tradición como [17], debido a que ayuda a minimizar los tiempos de operación de n relés dentro del sistema eléctrico.

Para ello la FO se la define implícitamente a través de la función de recompensa en el entorno de aprendizaje, debido a que cada episodio en cada relé debe llegar a cumplir con la ecuación (5).

$$\begin{aligned}
FO &= \min \left[\alpha_1 \sum_{i=1}^n t_i(Is_i, TMS_i) \right. \\
&\quad \left. + \alpha_2 \sum_{i=1}^n (\max(0, t_{backup,i} - t_{primary,i} - CTI))^2 \right] \quad (5)
\end{aligned}$$

En donde:

FO : es la función objetiva

t_i : tiempo de operación del relé i

Is_i : corriente de arranque del relé i

TMS_i : dial de tiempo del relé i

$t_{primary,i}$: tiempo del relé principal

$t_{backup,i}$: tiempo del relé de respaldo

CTI : intervalo mínimo de coordinación

α_1 : peso asociado a la minimización del despeje

α_2 : peso asociado a la coordinación entre zonas

Nota: La ecuación (5) muestra $\max(0, \dots)$ esta parte se usa para que la penalización nunca sea negativa, si la coordinación se cumple el término dentro de $\max(0, \dots)$ es ≤ 0 no existe penalización y si la coordinación no se cumple el término dentro de $\max(0, \dots)$ es ≥ 0 existen penalizaciones, pero todo esto no afecta a la función objetiva, estas son operaciones internas usadas para construir las penalizaciones por mala coordinación del algoritmo.

De acuerdo a la ecuación (5) al tener un α_1 alto el algoritmo va intentar bajar Is lo más que pueda y como resultado se tendrá mayor sensibilidad, pero se debe tener en cuenta que se tiene riesgo de disparos

indeseados de la protección, mientras que un α_1 bajo puede dar como resultados Is muy altos lo que reduce la sensibilidad.

En cuando a α_2 alto el DDPG intenta mantener el TMS lo más pequeño posible y se obtiene tiempos de despeje muy rápidos, pero se debe tener en cuenta los límites operativos del relé y con α_2 bajos el algoritmo puede escoger TMS muy grandes que pueden salir de las restricciones penalizándola fuertemente [22].

3.4 Restricciones para el ajuste de la protección

$$Is_{min,i} \leq Is_i \leq Is_{max,i} \quad (6)$$

La ecuación (6) define una restricción por hardware en la cual el algoritmo no puede elegir cualquier Is , debe elegir valores dentro del rango que el relé deja parametrizar y el valor calculado.

$$TMS_{min,i} \leq TMS_i \leq TMS_{max,i} \quad (7)$$

La restricción planteada en la ecuación (6) es similar a la ecuación (7), plantea una nueva restricción operativa para TMS debido a que si el algoritmo converge en valores fuera del ajuste del relé físico no se puede parametrizar [12],[17], [23].

3.5 Restricción de selectividad

En la red eléctrica de potencia es indispensable que cuente con protecciones eléctricas selectivas, es por ello que la selectividad es uno de los parámetros más importantes dentro de coordinación de protecciones. Debido a ello en la ecuación (8) se plantea que el relé de respaldo debe actuar más tarde que el relé primario y con una diferencia mínima según se establezca el CTI [12],[17].

$$t_{backup} - t_{primary} \geq CTI \quad (8)$$

3.6 Formulación matemática del algoritmo Deep Deterministic Policy Gradient

$$\alpha = \mu(s|\theta^\mu) \quad (9)$$

La ecuación (9) representa la política determinista (actor) en donde s representa el estado del sistema mientras que α es la acción que toma el agente ante las variables continuas, μ es la red neuronal actor que es la encargada de ver el estado y proporcionar una acción y θ^μ son los pesos asignados de la red actor.

$$Q(s, a | \theta^Q) \quad (10)$$

En la ecuación (10) expresa la función Q del crítico Q expresa el valor esperado, a es la acción y θ^Q son los pesos asignados para la red crítica.

$$y = r + \gamma Q'(s', \mu'(s'|\theta^\mu)|\theta^Q) \quad (11)$$

Para la ecuación (11) es la representación de Bellman para la red crítica, y es el valor objetivo que la red crítica debe llegar, r es el valor de la recompensa asignada durante la iteración mientras que $Q'(|\theta^Q)$ es la red crítica objetivo y $\mu'(s'|\theta^\mu)$ es la red actor objetivo, en esta fórmula la red crítica aprende de y que mezcla la recompensa con un valor futuro.

$$\begin{aligned} L(\theta^Q) &= \mathbb{E}_{(s,a,r,s')} [(y - Q(s, a|\theta^Q))^2] \end{aligned} \quad (12)$$

El error cuadrático medio o función de pérdidas del crítico y es definido por la ecuación (12) en donde $L(\theta^Q)$ es una función de pérdida de la red crítica, $\mathbb{E}_{(s,a,r,s')}$ representa el buffer de experiencia que se adquiere, mientras que y representa la ecuación (11) y $Q(s, a|\theta^Q)$ es la salida actual del crítico.

$$\begin{aligned} \nabla_{\theta^\mu} J &\approx \mathbb{E}_s [\nabla_a Q(s, a | \theta^Q)|_{a=\mu(s)} \\ &\quad \nabla_{\theta^\mu} \mu(s | \theta^\mu)] \end{aligned} \quad (13)$$

La ecuación (13) expresa la función de pérdida del actor en donde $\nabla_{\theta^\mu} J$ es el gradiente de desempeño, mientras que J es la función de desempeño y \mathbb{E}_s es el promedio de estados s , esta fórmula indica como se va ajustar los pesos de la red actor para que defina valores mayores para Q .

$$\begin{aligned} \theta^{Q'} &\leftarrow \tau \theta^Q + (1 - \tau) \theta^{Q'} \\ , \theta^{\mu'} &\leftarrow \tau \theta^\mu + (1 - \tau) \end{aligned} \quad (14)$$

El soft update de las redes objetivas son expresadas en la ecuación (14), donde $\theta^{Q'}$ son los parámetros de la red crítica objetivo, $\theta^{\mu'}$ son los parámetros de la red actor objetivo y θ^Q, θ^μ son los parámetros de la red principal crítico-actor y τ es un factor de mezcla pequeño (10^{-3}), la ecuación brinda estabilidad al entrenamiento de las redes porque el tarjet y que cambia muy rápido y por ende requiere actualizaciones suaves para que el algoritmo converja.

Algoritmo DRL – DDPG para ajuste de relés de sobrecorriente

Paso 1 Datos de entrada

Barras, cargas, líneas, GD
Definir relés de sobrecorriente
{A, B, C, D}, OLF, TC, curva
IEC

Paso 2 Inicializar parámetros

Flujo de carga
Cálculo de corrientes de
cortocircuito
Cálculos manuales de Is y TMS

Paso 3 Definir función objetivo

OF
Ecuación (4)

Sujeto:
 Ecuación (6), Ecuación (7) y
 Ecuación (8)

Paso 4 Construcción del entorno RL

Para cada rele i :
 RelayEnv_i(Ik''
 near, i , α_i , β_i ,
 rangos Is_i, rangos TMS_i,
 CTI_min,t_target,i)

Fin para

Paso 5 Optimización con DDPG

Inicializa las redes neuronales
 Actor $\mu(s|\theta_\mu)$ y critico $Q(s,a|\theta_Q)$

Para k=1: k #episodios

s = RelayEnv_i.reset()

done = false

mientras no done

a = $\mu(s|\theta^\mu)$ + ruido

→ a = [Is_i, TMS_i]

(s', r, done, info) =

RelayEnv_i.steep(a)

Guardar (s,a,r,s',done)

s = s'

fin mientras

fin para

Guardar (Is_i*, TMS_i*) por
 cada relé I del mejor episodio

Paso 6 Mostrar resultados

Para cada relé i

Is_cal

TMS_cal

Is_opt

TMS_opt

Fin para

Esta parte describe la metodología que utiliza el DDPG para coordinar todos los relés de la red eléctrica, primero se construye el modelo eléctrico incluyendo

líneas, cargas y barras con la GD, se fijan parámetros para los cortocircuitos según IEC 60909, posterior a ello se definen los relés ordenados de forma radial dentro del sistema porque la coordinación comienza de atrás hacia adelante. Para cada relé la metodología calcula corrientes de cortocircuito que serán usados para definir los límites permitidos para Is y TMS respetando límites de hardware y CTI [24]. Con todos estos datos adquiridos se construye el entorno de aprendizaje (estados, acciones y recompensas) para que el DDPG busque ajustes de Is y TMS dentro de los límites previamente definidos y con ello cada relé posee un ajuste adecuado.

El DDPG inicializa dos redes neuronales: el actor que define acciones continuas (Is y TMS) y el crítico que evalúa que tan buena es cada acción de acuerdo a la recompensa, con ello se crean copias de las redes denominadas replay buffer que son las encargadas de almacenar experiencia de acuerdo a cada episodio [19], con ello el algoritmo observa el estado de las variables Is y TMS para de acuerdo a esa observación explore y devuelva valores aleatorios utilizando la política actual que verifica si cumple con las restricciones y la función objetiva propuesta, una vez realizado esta observación la experiencia adquirida se guarda en un buffer y la red critico aprende a aproximar la salida $Q(s,a)$ y el actor escoge las mejores respuestas que el crítico devuelva como respuestas óptimas.

3.7 Configuración del sistema de prueba IEEE 33 barras con GD

En este apartado se realizó la parametrización de la red de IEEE de 33 barras, el modelo fue implementado primero con los datos de la tabla 6, e incorporado en PowerFactory (PF) con el fin de tener una guía para poder incorporar la GD. Una vez teniendo la red modelada en PF se procede a considerar la ubicación de la GD motivo por el cual se toma en cuenta

los datos de [8] y con todo ello poder proponer los escenarios para los casos de estudio.

Una vez teniendo todo en consideración se procede a establecer estratégicamente la ubicación de la GD y al definir la ubicación de cada GD se colocó una protección de sobrecorriente temporizada (51) en cada barra en donde esta alojada la generación distribuida, esto con el objetivo de tener una red radial que ayudará a proteger cada generación.

potencia como se muestra en la figura 2. Los arreglos fotovoltaicos son agrupados y cuya salida de DC es canalizada hacia los inversores por medio de seccionadores DC.

De esta forma la planta se maneja a un voltaje de 0.46 kV en el lado de baja tensión y es aumentada por medio de un transformador elevador hasta 12.66 kV que es el voltaje que maneja la red en la que se desarrolla el proyecto.

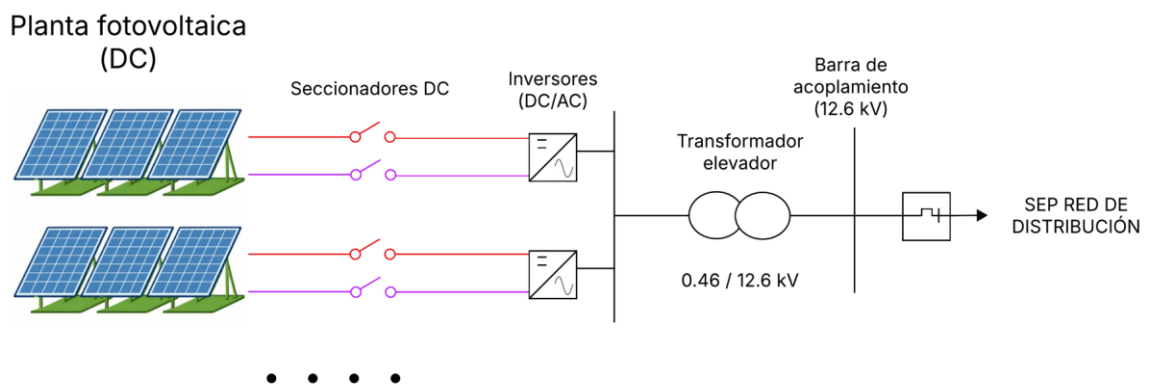


Figura 2. Configuración genérica para la GD fotovoltaica

Finalmente, la generación distribuida fotovoltaica se acopla a la red de distribución a través de una barra de acoplamiento permitiendo la inyección de potencia activa hacia la red eléctrica, de esta manera la configuración mostrada en la figura 2 es un modelo genérico de conexión de generación distribuida la cual es replicada para cada unidad de GD empleada en distintos puntos de la red eléctrica utilizada en el presente estudio.

Las relaciones de los TCs son seleccionadas de acuerdo a las corrientes que circulan en condiciones normales de operación mismas que son obtenidas de acuerdo al flujo de carga del sistema. Una elección errónea del TC puede comprometer el diseño de protecciones porque puede producir pérdida de sensibilidad, alta saturación en los TC o errores de medición que afecten directamente la correcta parametrización de los relés de sobrecorriente.

La conexión de las centrales de generación distribuida fotovoltaica hacia la red IEEE de 33 barras se realiza mediante una arquitectura típica basada en electrónica de

Debido a esto cada TCs es asignado de acuerdo al nivel de corriente por la rama a proteger y empelando las relaciones más estándar de (1A o 5A) en el secundario debido a que son valores típicamente usados

en los relés de protección, de acuerdo a ello en el entorno de Python también se utiliza la misma relación del TCs o se considera relaciones de TC normadas por la IEC para evitar errores en los cálculos, estos valores permiten realizar los cálculos manuales de Is y TMS que son datos requeridos que brinda Python para que el algoritmo de aprendizaje por refuerzo profundo DDPG pueda definir los límites superiores e inferiores en donde la metodología podrá explorar para encontrar el resultado más adecuado y presentarlo como solución óptima para posterior a ello ponerlo en validación.

Para la verificación de resultados y obtención de curvas tiempo – corriente se utilizó DIgSILENT PowerFactory como herramienta de validación. En este software se ingresan manualmente los datos manuales y los valores dados por el algoritmo para implementarlos en la red modelada de acuerdo a cada escenario propuesto en PF, para ello se utilizó un relé genérico F50_F51 Phase Overcurrent para obtener las gráficas tiempo – corriente y así poder comparar con los ajustes tradicionales y los propuestos por el DDPG permitiendo evidenciar la eficiencia de la metodología usada para este proyecto.

Tabla 2: Parámetros de la generación distribuida caso 2

Bus	Generación distribuida	P [MW]	Q [Mvar]
10	GD1	1.215	0
30	GD2	1.025	0
24	GD3	0.955	0

Tabla 3: Parámetros de la generación distribuida caso 3

Bus	Generación distribuida	P [MW]	Q [MVA]
10	GD1	1.100	0
30	GD2	0.800	0
19	GD3	1.200	0

En la tabla 2 y tabla 3 se presenta los parámetros asociados a las generaciones distribuidas consideradas de acuerdo a cada caso de estudio.

4 Casos de estudio

Con el objetivo de poder analizar el impacto de la GD en el comportamiento de los relés de sobrecorriente y poder evaluar el desempeño de la metodología propuesta se definieron tres configuraciones operativas distintas sobre la red de distribución de 33 barras. Los casos son definidos en función de los cambios realizados a la red tales como, la incorporación progresiva de la GD, variaciones de potencia activa que inyecta cada unidad generadora, todo esto con el fin de poder presentar escenarios con condiciones operativas similares a las reales propias de los sistemas eléctricos actuales.

Es por ello que en este estudio los escenarios planteados parten de un escenario base sin generación distribuida y extendiéndose hacia otros dos escenarios con GD cuyos parámetros son propuestos en la tabla 2 y tabla 3 permitiendo obtener escenarios distintos que ayuden a comparar los ajustes tradiciones y los ajustes obtenidos mediante la metodología propuesta en este trabajo.

4.1 Escenario 1




Figura 3. Caso 1 sin GD

De acuerdo a ello los casos de estudios comienzan con el escenario 1 el cual es base para todos los demás casos, es por ello que el primero escenario a considerarse es uno que no posea GD es por ello que en la figura 3 se observa el diagrama unifilar del sistema a utilizarse y en este se va analizar la red IEEE de 33 barras sin el uso de la GD, este escenario posee un relé principal colocado en la barra 1 misma que es considerada como barra slack de todo el sistema y por medio de este sistema se verifica el comportamiento de la red sin aporte de la GD, es por ello que este caso sirve para comparar los cálculos manuales y los obtenidos por el algoritmo DDPG, en este estudio se realizaron cortocircuitos trifásicos en diferentes barras del sistema para verificar los datos obtenidos mismos que son usados para obtener los parámetros esenciales para el primer ajuste manual y con ello el DDPG pueda ajustarlo usando las restricciones planteadas anteriormente.

Tabla 4: Ajustes para el escenario 1

Relé	Ajuste	Valor calculado	Valor optimizado
RA	Is	1.582	1.313
	TMS	0.363	0.136

De acuerdo a la tabla 4 se puede observar los ajustes manuales obtenidos al usar las corrientes de cortocircuito en el punto más lejano obteniendo un Is y TMS para el relé A por otra parte, también se obtiene los ajustes propuestos por la metodología notando que existe cambios que pueden ser vistos de mejor manera al realizar la curva tiempo – corriente para poder constatar el tiempo que el relé requiere para despejar la falla.




Figura 4. Falla trifásica nodo 13 sin DDPG

Para evaluar el desempeño del ajuste propuesto se realizó una falla trifásica en el nodo 13, en la figura 4 se utilizaron los ajustes tradicionales para el relé A según la IEC 60909 obteniendo como resultado una actuación a los 3.962 seg con una corriente de 594.534 [A] primarios debido a que es una falla lejana.




Figura 5. Falla trifásica nodo 13 con DDPG

El algoritmo explora en un espacio continuo y converge bajo las restricciones y límites impuestos, debido a esto los resultados obtenidos en la tabla 4 para el relé A son nuevamente ajustados y de acuerdo a ello se puede evidenciar que el tiempo de actuación mostrado en la figura 5 para el mismo relé A se obtiene un tiempo de actuación de 1.186 seg con una corriente de 594.534 [A] primarios demostrando así que para este escenario los parámetros óptimos encontrados por el DDPG son adecuados.

4.2 Escenario 2




Figura 6. Escenario 2 con GD

Para el escenario 2 la red se encuentra con generación distribuida ubicada en los nodos 10,30 y 24, para este caso se mantiene la topología original del caso 1 pero el objetivo del escenario 2 es que la metodología usada en el proyecto pueda reasignar nuevos valores optimizados con la inclusión de la generación distribuida. De acuerdo a ello el algoritmo sigue optimizando los parámetros del relé con el fin de que el sistema siga manteniendo coordinación.

Tabla 5: Ajustes para el escenario 2

Relé	Ajuste	Valor calculado	Valor optimizado
RA	Is	0.830	0.665
	TMS	0.443	0.379
RB	Is	0.748	0.698
	TMS	0.355	0.195
RC	Is	0.528	0.528
	TMS	0.389	0.105
RD	Is	0.514	0.514
	TMS	0.467	0.125

De acuerdo a ello la topología planteada y a diferencia del caso 1 se propone un dispositivo de protección por cada GD contando con 4 relés de protección para toda la red, de acuerdo a ello el relé A va actuar como principal en barra 1 misma que encabeza todo el sistema, el relé B está ubicado en la GD_1 en barra 10, la GD_2 cuenta con el relé C en la barra 30 y por último el relé D está ubicado en la barra 24 con la GD_3.

Mediante esta distribución se definen los parámetros mostrados en la tabla 5 recordando que esta tabla presenta ajustes manuales y los ajustes optimizados por el DDPG y de igual forma que el caso anterior se presenta las curvas tiempo – corriente de los dispositivos de protección que ayudan a verificar en este nuevo caso si la metodología propuesta se adapta a los nuevos cambios de la red con la inclusión de la GD.




Figura 7. Falla trifásica barra 11 relé A-B sin DDPG




Figura 8. Falla trifásica barra 11 relé A-B con DDPG

En la figura 7 se observa la gráfica tiempo – corriente para el relé A y relé B con los datos del cálculo manual y una falla trifásica en barra 11, se puede visualizar que el relé B dispara primero a los 0.748 seg mientras que A lo respalda a los 2.100 seg cuando mide una corriente de 704.401 [A] primarios, por otra parte existe una diferencia al parametrizarlos con los ajustes del algoritmo, en la figura 8 se puede evidenciar los tiempos de la curva tiempo – corriente y se observa que el relé B se activa a los 0.407 seg mientras que el relé A que es su respaldo se activa a los 1.576 seg con una corriente de 704.401 [A].




Figura 9. Falla trifásica barra 33 relé A-C sin DDPG




Figura 10. Falla trifásica barra 33 relé A-C con DDPG

En función de la figura 9 el relé C actúa a los 0.776 seg y su respaldo el relé A se activa a los 2.298 seg con una corriente de 623.146 [A] primarios mientras que al aplicar la metodología la figura 10 presenta al relé C el cual actúa a los 0.219 seg mientras que el respaldo el relé A actúa en 1.704 seg.




Figura 11. Falla trifásica barra 25 relé A-D sin DDPG




Figura 12. Falla trifásica barra 25 relé A-D con DDPG

De acuerdo a la figura 11 el relé D se activa en 0.935 seg y el relé A en 1.371 seg, mientras que usando los nuevos ajustes el relé D se activa a los 0.259 seg y el respaldo el relé A actúa en 1.076 seg mostrados en la figura 12.

En función de las gráficas mostradas anteriormente se puede decir que la metodología propuesta es viable porque muestra que si existe diferencias entre los tiempos de actuación cuando se ocupa los datos brindados por el agente DDPG.

4.3 Escenario 3




Figura 13. Caso 3 con GD

En el escenario 3 la red parte de una configuración similar del escenario 2, pero ahora se considera la presencia de la reubicación de la generación distribuida 3, evidenciado así el cambio de la topología de la red y por ende la dirección de las corrientes de carga. Debido a esto el propósito del algoritmo es verificar que la metodología usada se adapta a los cambios topológicos que puede sufrir la red. Es por ello que la nueva distribución se mantiene en las barras 10,30 y 19.

Tabla 6: Ajustes para el escenario 3

Relé	Ajuste	Valor calculado	Valor optimizado
RA	Is	0.817	0.665
	TMS	0.445	0.444
RB	Is	0.750	0.693
	TMS	0.358	0.222
RC	Is	0.530	0.530
	TMS	0.390	0.105
RD	Is	0.325	0.325
	TMS	0.554	0.148

Para hacerlo un caso más real se tomó en consideración el cambio de las potencias de cada generación distribuida mismas que son presentadas en la tabla 3, estos cambios realizados alteran la dirección y magnitud de las corrientes de carga lo que puede afectar directamente en la selectividad y márgenes de coordinación del relé principal o de respaldo.

El objetivo de este último escenario es comprobar si la metodología propuesta brinda el mismo desempeño ante variaciones de potencia o cambios topológicos de la red respecto a los escenarios 1 y 2, es por ello que los ajustes mostrados en la tabla 6 se muestra los ajustes propuestos por la metodología tradicional y los valores óptimos dados por el DDPG mismos valores que son parametrizados y analizados en las siguientes gráficas para evaluar el desempeño del aprendizaje por refuerzo profundo para adaptarse a escenarios mas exigentes.




Figura 15. Falla trifásica barra 14 relé A-B sin DDPG




Figura 14. Falla trifásica barra 14 relé A-B con DDPG

En función de la figura 14 se puede observar una falla trifásica en barra 14 y el accionar del relé B a los 0.848 seg mientras que su respaldo A se activa 2.917 seg con una corriente de 477.396 [A] primarios, mientras que en la figura 15 se observa el mismo escenario, pero el relé B es activado a los 0.503 seg y el relé A en 2.394 seg.




Figura 17. Falla trifásica barra 33 relé A-C sin DDPG




Figura 16. Falla trifásica barra 33 relé A-C con DDPG

En la figura 16 se muestra la curva tiempo – corriente del relé C con un accionamiento a los 0.776 seg y el relé A en 2.318 seg cuando marca una corriente de 626.760 [A] primarios. Por otra parte, en la figura 17 se evidencia que el relé C es activado a los 0.219 seg mientras que el respaldo relé A en 1.966 seg con una corriente de 626.760 [A] primarios.




Figura 18. Falla trifásica barra 22 relé A-D sin DDPG




Figura 19. Falla trifásica barra 22 relé A-D con DDPG

En la figura 18 se puede observar que el relé D se activa en 1.094 seg y el relé A en 1.477 seg con una corriente de 1324.329 [A] primarios. Mientras que haciendo uso de los ajustes proporcionados por el DDPG en la figura 19 se obtiene que el relé D actúa en 0.298 seg y el respaldo relé A se activa en 1.314 seg, demostrando que la metodología se adapta a los cambios topológicos que se puedan presentar en el sistema de distribución.

5 Análisis de resultados

De acuerdo a las figuras presentadas se pudo observar que, si existen cambios en cuanto a los tiempos de actuación de los relés de acuerdo a cada escenario, en ellos se comparó los valores ajustados de forma tradicional y los ajustes proporcionados por el DDPG para este trabajo.

5.1 Caso 1 sin GD

Relé RA es el primer y único relé principal que existe en este escenario su actuación es en 3.962 seg y se reduce a 1.186 seg al utilizar la metodología demostrando que existe una mejora del 70.06% en el tiempo de operación evidenciando el cambio significativo que se visualiza para este caso.

5.2 Caso 2 con GD en (10,30 y 24)

Relé RA presento una mejora aproximada de 24.95% porque al inicio demostró una actuación de 2.100 seg y el DDPG logró reducirlo a 1.576 seg, este resultado muestra una respuesta más rápida.

Relé RB obtuvo un tiempo de actuación de 0.748 seg y se redujo a 0.407 seg alcanzado una reducción de 45.58%, esta respuesta demuestra que el algoritmo es capaz de ajustes óptimos según el escenario de estudio.

Relé RC alcanzó una mejora del 71.77% con una disminución del tiempo de 0.776 seg a 0.219 seg disminuyendo el tiempo de despeje de una falla eficientemente.

Relé RD mostró una mejora significativa que está alrededor de 72.29%, porque inicialmente despejaba en 0.935 seg mientras que el DDPG lo redujo a 0.259 seg poniendo en consideración que es el dispositivo que obtuvo una mejora significativa haciéndola que garantiza

sensibilidad y rapidez en el momento adecuado.

5.3 Caso 3 con GD en (10,30 y 19)

Relé RA redujo el tiempo de actuación de 2.917 seg a 2.394 seg, mejorando aproximadamente un 17.92% al implementar los ajustes óptimos, su mejora no es muy significativa como el caso anterior, pero puede ser crucial durante una falla imprevista.

Relé RB demostró ser 40.68% más eficiente porque su tiempo inicial de operación es de 0.848 seg y al implementar el DDPG se reduce a 0.503 seg.

Relé RC reveló una mejora del 71.77% lo cual muestra un aumento similar al caso anterior reduciendo el tiempo de 0.776 seg a 0.219 seg.

Relé RD es el único dispositivo que muestra una mejora del tiempo de actuación del 72.76% de 1.094 seg a 0.298 seg, este resultado demuestra que el DDPG es una opción óptima para preservar la coordinación de relés de protección.

6 Conclusiones

El trabajo realizado se centró en el uso de aprendizaje por refuerzo profundo por medio del DDPG mismo que fue usado en respuesta al problema de la coordinación de relés de sobrecorriente en redes de distribución con generación distribuida, debido a que esta tecnología modifica corrientes de cortocircuito y la topología de la red lo que compromete la efectividad de ajuste de los métodos tradicionales. Por lo tanto, la correcta parametrización de Is y TMS resulta esencial para garantizar una operación adecuada ante fallas en cualquier punto del sistema.

La metodología propuesta en solución a este problema es implementada en el entorno de

Python sobre el sistema IEEE de 33 barras considerando múltiples escenarios operativos con GD bajo diferentes parámetros, la implementación del algoritmo de aprendizaje por refuerzo profundo DDPG permitió determinar ajustes óptimos de Is y TMS por medio de la función actor – crítico que consiste en el uso de dos redes neuronales que analizan la respuestas en función de las restricciones y márgenes de coordinación dadas para cada relé empleado en el sistema.

Mediante el análisis de cada caso de estudio se observa que los relés RA, RB, RC y RD presentan un mejor desempeño en términos de rapidez en el despeje de fallas, esto lo hacen respetando márgenes de coordinación entre relés y como resultado demuestran una reducción significativa en los tiempos de actuación respecto a los ajustes tradicionales teniendo un comportamiento más óptimo en la coordinación de protecciones sin perder selectividad.

En función de todo lo expuesto se concluye que el uso de técnicas de aprendizaje por refuerzo profundo como el DDPG es capaz de adaptarse a variaciones topologías u operativas del sistema presentando una alternativa viable y prometedora frente a los ajustes tradicionales o técnicas heurísticas clásicas para la coordinación óptima de relés de sobrecorriente.

7 Trabajos Futuros

En este trabajo se observó el desempeño de los escenarios propuestos con generación distribuida para un sistema de 33 barras, como trabajo futuro se podría considerar la implementación de la metodología usada en este trabajo aplicada a otras funciones de protección como sobrecorriente direccional, sobrecorriente diferencial o protección de distancia, un estudio más real sería el uso de valores reales adquiridos a través de un PMU. También se podría considerar una red más grande con centros de generación

distribuida mixtos para probar que tan robusto es el DDPG frente a condiciones más realistas y que conlleven una mayor complejidad.

8 Referencias

- [1] A. O. Abdul-lateef, “Adaptive overcurrent distribution protection scheme coordination in the presence of distributed generation using artificial neural network,” vol. 30, no. 2, pp. 7–21, 2024, doi: <https://doi.org/10.29081/jesr.v30i2.001>.
- [2] H. Ke and H. He, “A Method of Distribution Network Protection and Application with Penetration of Renewable Generation,” *2022 China Int. Conf. Electr. Distrib.*, pp. 1473–1476, 2022, doi: [10.1109/CICED56215.2022.9928846](https://doi.org/10.1109/CICED56215.2022.9928846).
- [3] S. D. Saldarriaga-zuluaga and J. M. López-lezama, “Applied sciences Hybrid Harmony Search Algorithm Applied to the Optimal Coordination of Overcurrent Relays in Distribution Networks with Distributed Generation,” 2021, doi: <https://doi.org/10.3390/app11199207>.
- [4] A. U. Khan, Q. Hong, C. Booth, and U. Kingdom, “Performance Analysis of the Overcurrent Protection for the Renewable Distributed Generation Dominated Microgrids,” no. June, pp. 5–7, 2020.
- [5] W. A. A. Orbe, “Método de optimización de algoritmo de búsqueda gravitacional (GSA) aplicado a la coordinación de protecciones eléctricas de sobrecorriente,” 2024, *Febrero 2024, DMQ*.
- [6] Q. Huang, R. Huang, W. Hao, J. Tan, R. Fan, and Z. Huang, “Adaptive Power System Emergency Control using Deep Reinforcement

- Learning,” pp. 1–8, 2019, doi: 10.1109/TSG.2019.2933191.
- [7] A. R. Arango, “Desarrollo de un Algoritmo de Aprendizaje por Refuerzo Profundo para Resolver el Despacho Hidrotérmico Colombiano Considerando Escenarios Hidrológicos y de Demanda Bajo Incertidumbre,” 2022.
- [8] L. O. Alexander Águila Téllez, Diego González, Gonzalo Gutiérrez, “Ubicación y dimensionamiento óptimo de generación distribuida fotovoltaica en redes de distribución usando PSO,” vol. 18, no. 1, pp. 50–68, 2022.
- [9] Q. Li, T. Lin, Q. Yu, H. Du, J. Li, and X. Fu, “Review of Deep Reinforcement Learning and Its Application in Modern Renewable Power System Control,” pp. 1–23, 2023, doi: <https://doi.org/10.3390/en16104143>.
- [10] M. A. Elsadd, H. A. A. B. D. Elghany, A. Y. Abdelaziz, and S. Member, “Optimum Coordination Approach for Directional Overcurrent Relays in Interconnected Power Systems Considering Uncertainty in Photovoltaic Generation,” *IEEE Access*, vol. 12, no. May, pp. 131681–131700, 2024, doi: 10.1109/ACCESS.2024.3456158.
- [11] E. Colombiana, J. G. Maestr, F. Garc, and R. M. Guerra, “Evaluación del esquema de coordinación de protecciones ante la inclusión de generación fotovoltaica en Bogotá,” 2020.
- [12] A. D. R. Tirado, “Método de optimización de algoritmo genético (GA) aplicado a la coordinación de protecciones eléctricas de sobrecorriente,” 2024.
- [13] H. R. Berrocal, “Análisis de protecciones de sobrecorriente para el mejoramiento de la continuidad de suministro eléctrico de la subestación Chimbote Norte,” 2019.
- [14] A. A. Hameed, A. J. Sultan, and M. F. Booneya, “Design and Implementation of Multifunction Relay Based on Microcontroller,” no. September, 2021, doi: <https://doi.org/10.51173/jt.v3i3.353>.
- [15] P. Alaei and T. Amraee, “Optimal Coordination of Directional Overcurrent Relays in Meshed Active Distribution Network,” vol. 9, no. 2, pp. 416–422, 2021, doi: 10.35833/MPCE.2019.000184.
- [16] A. Multi *et al.*, “Analysis of over current relay (OCR) and ground fault relay (GFR) protection on substation power transformers,” no. 021, pp. 1–9, 2022, doi: <https://doi.org/10.37277/stch.v32i1.1215>.
- [17] D. S. J. Soliz, “Método de optimización de algoritmo cuckoo optimization algorithm (COA) aplicado a la coordinación de protecciones eléctricas de sobre corriente,” p. 98, 2024.
- [18] D. Wu, S. Member, D. Kalathil, S. Member, and M. Begovic, “Deep Reinforcement Learning-Based Robust Protection in DER-Rich Distribution Grids,” pp. 1–10, 2021, doi: 10.1109/OAJPE.2022.3161904.
- [19] J. Vitay, “Deep Deterministic Policy Gradient 1 - Deterministic policy gradient theorem,” pp. 1–35, 2024, [Online]. Available: <https://julien-vitay.net/course-deeprl/slides/pdf/3.5-DDPG.pdf>
- [20] R. Dong, J. Du, Y. Liu, A. A. Heidari, and H. Chen, “An enhanced deep deterministic policy gradient algorithm for intelligent control of robotic arms,” no. January, pp. 1–12, 2023, doi: 10.3389/fninf.2023.1096053.
- [21] R. Lu, Z. Jiang, H. Wu, and S. Member, “Reward Shaping-Based

- Actor – Critic Deep Reinforcement Learning for Residential Energy Management,” *IEEE Trans. Ind. Informatics*, vol. 19, no. 3, pp. 2662–2673, 2023, doi: 10.1109/TII.2022.3183802.
- [22] R. Pandey, S. Bose, and P. Dwivedi, “DDPG algorithm for power optimization and control of solar PV-integrated DFIG wind energy systems,” pp. 1–12, 2025, doi: <https://doi.org/10.1038/s41598-025-19818-6>.
- [23] M. Pujiantara and V. Lystianingrum, “Overcurrent Relay Coordination Setting on Distribution Power System Using Grasshopper Optimization Algorithm,” *2023 Int. Semin. Intell. Technol. Its Appl.*, pp. 804–809, 2023, doi: 10.1109/ISITIA59021.2023.10221124.
- [24] X. Qiao, K. Qi, X. Y. Peng, X. Liu, and Y. Su, “Enhancing DER Scheduling in Active Distribution Networks: A Symbolic Deep Reinforcement Learning Approach for Improved Interpretability and Performance,” pp. 261–267, 2025, doi: 10.1109/AAIEE64965.2025.11100302.
- [25] D. Wu, X. Zheng, D. Kalathil, and L. Xie, “Nested Reinforcement Learning Based Control for Protective Relays in Power Distribution Systems,” 2019, doi: <https://doi.org/10.48550/arXiv.1906.10815>.
- [26] U. U. Uma *et al.*, “Adaptive overcurrent protection scheme coordination in presence of distributed generation using radial basis neural network,” *Prot. Control Mod. Power Syst.*, vol. 4, 2023, doi: 10.1186/s41601-023-00336-4.

8.1 Matriz de Estado del Arte

Tabla 7: Matriz de estado del arte

OPTIMIZACIÓN DE LOS TIEMPOS DE DISPARO EN LA COORDINACIÓN ADAPTATIVA DE PROTECCIONES DE SOBRECORRIENTE EN REDES DE DISTRIBUCIÓN CON GENERACIÓN DISTRIBUIDA MEDIANTE APRENDIZAJE POR REFUERZO PROFUNDO																							
ITEM	Año	TÍTULO DEL ARTÍCULO	REFERENCIAS	CITAS	TEMÁTICA				FORMULACIÓN DEL PROBLEMA				RESTRICCIONES DEL PROBLEMA			PROPUESTAS PARA RESOLVER EL PROBLEMA		SOLUCIÓN PROPUESTA					
					COORDINACIÓN DE RELES DE SOBRECORRIENTE CON GD	AJUSTE DE RELÉ DE SOBRECORRIENTE	SIMULACIÓN SOFTWARE	ALGORITMO DRL	COORDINACIÓN PRIMARIA Y RESPALDO	DESCOORDINACIÓN DE RELES	TIEMPOS DE OPERACIÓN INADECUADOS	AJUSTES DE PICKUP POCO REALISTAS	INEFICIENCIA DE METODOS MANUALES	DIFICULTAD PARA SIMULAR MÚLTIPLES ESCENARIOS	CORRIENTE DE CARGA	CORRIENTE DE CORTOCIRCUITO	LIMITES OPERATIVOS DE Is Y TMS	METODOLOGÍA ADAPTATIVA	ALGORITMO DRL - DDPG	FUNCION OBJETIVO Y RESTRICCIONES	VALIDACION EN EL SISTEMA IEEE DE BARRAS CON GD	AJUSTE OPTIMO Y AUTOMATICO DE Is Y TMS	REDUCCIÓN EN LOS TIEMPOS DE DISPARO DE LOS RELES
1	2024	Adaptive overcurrent distribution protection scheme coordination in the presence of distributed generation using artificial neural network	[1]	13	☒		☒			☒		☒			☒				☒			☒	
2	2022	A Method of Distribution Network Protection and Application with Penetration of Renewable Generation	[2]	99	☒	☒			☒										☒				
3	2021	Applied sciences Hybrid Harmony Search Algorithm Applied to the Optimal Coordination of Overcurrent Relays in Distribution Networks with Distributed Generation	[3]	15							☒				☒								
4	2020	Performance Analysis of the Overcurrent Protection for the Renewable Distributed Generation Dominated Microgrids	[4]	4					☒	☒				☒								☒	
5	2024	Método de optimización de algoritmo de búsqueda gravitacional (GSA) aplicado a la coordinación de protecciones eléctricas de sobrecorriente	[5]	1		☒	☒										☒		☒	☒			☒
6	2029	Adaptive Power System Emergency Control using Deep Reinforcement Learning	[6]	318					☒								☒						
7	2022	Desarrollo de un Algoritmo de Aprendizaje por Refuerzo Profundo para Resolver el Despacho Hidrotérmico Colombiano Considerando Escenarios Hidrológicos y de Demanda Bajo Incertidumbre	[7]	1															☒				

OPTIMIZACIÓN DE LOS TIEMPOS DE DISPARO EN LA COORDINACIÓN ADAPTATIVA DE PROTECCIONES DE SOBRECORRIENTE EN REDES DE DISTRIBUCIÓN CON GENERACIÓN DISTRIBUIDA MEDIANTE APRENDIZAJE POR REFUERZO PROFUNDO

ITEM	Año	TÍTULO DEL ARTÍCULO	REFERENCIA	CITAS	TEMÁTICA				[16]				RESTRICCIONES DEL PROBLEMA		PROPUESTAS PARA RESOLVER EL PROBLEMA			SOLUCIÓN PROPUESTA			
					COORDINACIÓN DE RELES DE SOBRECORRIENTE CON GD	AJUSTE DE RELÉ DE SOBRECORRIENTE	SIMULACIÓN SOFTWARE	ALGORITMO DRL	COORDINACIÓN PRIMARIA Y RESPALDO	DESCOORDINACIÓN DE RELES	TIEMPOS DE OPERACIÓN INADECUADOS	AJUSTES DE PICKUP POCO REALISTAS	INEFICIENCIA DE METODOS MANUALES	DIFICULTAD PARA SIMULAR MÚLTIPLES ESCENARIOS	CORRIENTE DE CARGA	CORRIENTE DE CORTOCIRCUITO	LIMITES OPERATIVOS DE Is Y TMS	METODOLOGÍA ADAPTATIVA	ALGORITMO DRL - DDPG	FUNCION OBJETIVO Y RESTRICCIONES	VALIDACION EN EL SISTEMA IEEE DE BARRAS CON GD
8	2022	Ubicación y dimensionamiento óptimo de generación distribuida fotovoltaica en redes de distribución usando PSO	[8]	1	☒																
9	2023	Review of Deep Reinforcement Learning and Its Application in Modern Renewable Power System Control	[9]	36	☒			☒								☒					
10	2024	Optimum coordination approach for directional overcurrent relays in interconnected power systems considering uncertainty in photovoltaic generation	[10]	4			☒		☒	☒				☒			☒	☒	☒		
11	2020	Evaluación del esquema de coordinación de protecciones ante la inclusión de generación fotovoltaica en Bogotá	[11]	1	☒	☒				☒					☒				☒		☒
12	2024	Método de optimización de algoritmo genético (GA) aplicado a la coordinación de protecciones eléctricas de sobrecorriente	[12]	1			☒			☒							☒	☒	☒	☒	
13	2019	Análisis de protecciones de sobrecorriente para el mejoramiento de la continuidad de suministro eléctrico de la subestación Chimbote Norte	[13]	1		☒			☒		☒	☒					☒				
14	2021	Design and implementation of multifunction relay based on microcontroller	[14]	15								☒		☒							
15	2021	Optimal coordination of directional overcurrent relays in meshed active distribution network	[15]	19						☒					☒				☒		☒
16	2022	Analysis of over current relay (OCR) and ground fault relay (GFR) protection on substation power transformers	[16]	1									☒								

OPTIMIZACIÓN DE LOS TIEMPOS DE DISPARO EN LA COORDINACIÓN ADAPTATIVA DE PROTECCIONES DE SOBRECORRIENTE EN REDES DE DISTRIBUCIÓN CON GENERACIÓN DISTRIBUIDA MEDIANTE APRENDIZAJE POR REFUERZO PROFUNDO

ITEM	Año	TÍTULO DEL ARTÍCULO	REFERENCIA	CITAS	TEMÁTICA				FORMULACIÓN DEL PROBLEMA				RESTRICCIÓNES DEL PROBLEMA			PROPUESTAS PARA RESOLVER EL PROBLEMA			SOLUCIÓN PROPUESTA		
					COORDINACIÓN DE RELES DE SOBRECORRIENTE CON GD	AJUSTE DE RELÉ DE SOBRECORRIENTE	SIMULACIÓN SOFTWARE	ALGORITMO DRL	COORDINACIÓN PRIMARIA Y RESPALDO	DESCOORDINACIÓN DE RELES	TIEMPOS DE OPERACIÓN INADECUADOS	AJUSTES DE PICKUP POCO REALISTAS	INEFICIENCIA DE METODOS MANUALES	DIFICULTAD PARA SIMULAR MÚLTIPLES ESCENARIOS	CORRIENTE DE CARGA	CORRIENTE DE CORTOCIRCUITO	LIMITES OPERATIVOS DE Is Y TMS	METODOLOGÍA ADAPTATIVA	ALGORITMO DRL - DDPG	FUNCION OBJETIVO Y RESTRICCIONES	VALIDACIÓN EN EL SISTEMA IEEE DE BARRAS CON GD
17	2024	Método de optimización de algoritmo cuckoo optimization algorithm (COA) aplicado a la coordinación de protecciones eléctricas de sobre corriente	[17]	1		☒	☒		☒	☒						☒			☒		☒
18	2021	Deep Reinforcement Learning-Based Robust Protection in DER-Rich Distribution Grids	[18]	20					☒												
19	2024	Deep Deterministic Policy Gradient 1 - Deterministic policy gradient theorem	[19]	1					☒						☒	☒					
20	2023	An enhanced deep deterministic policy gradient algorithm for intelligent control of robotic arms	[20]	19					☒							☒					
21	2023	Reward Shaping-Based Actor - Critic Deep Reinforcement Learning for Residential Energy Management	[21]	71					☒												
22	2025	DDPG algorithm for power optimization and control of solar PV-integrated DFIG wind energy systems	[22]	651									☒		☒	☒					
23	2023	Overcurrent Relay Coordination Setting on Distribution Power System Using Grasshopper Optimization Algorithm	[23]	3		☒			☒		☒								☒		☒
24	2025	Enhancing DER Scheduling in Active Distribution Networks: A Symbolic Deep Reinforcement Learning Approach for Improved Interpretability and Performance	[24]	46					☒						☒						

8.2 Resumen de indicadores

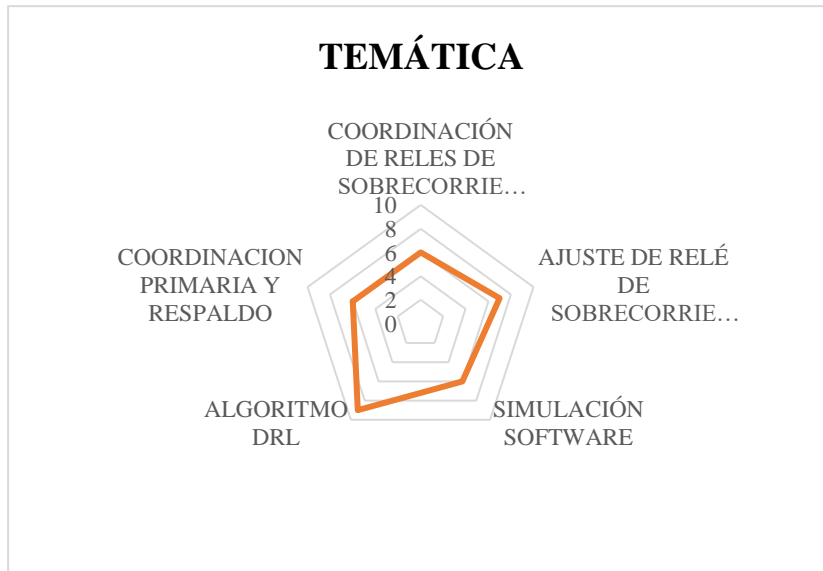


Figura 22. Indicador de la temática estado del arte

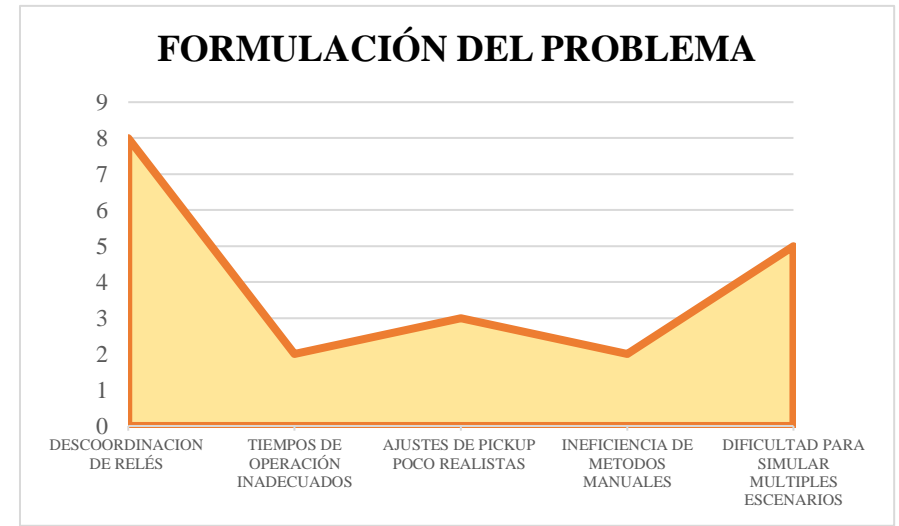


Figura 21. Indicador de formulación del problema-Estado del arte

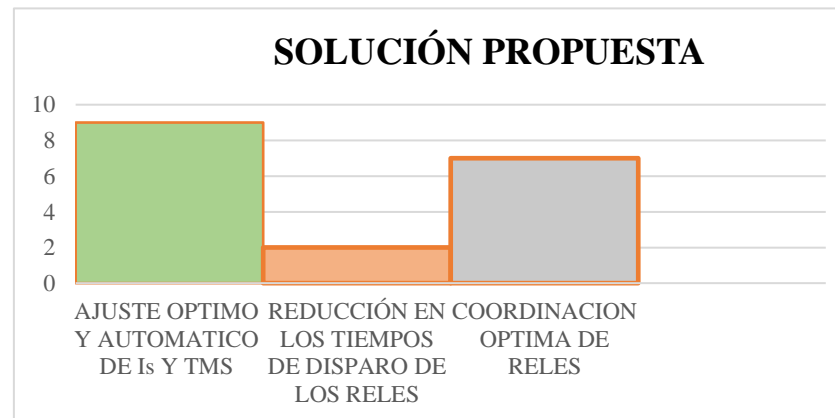


Figura 20. Indicador de la solución propuesta estado del arte

9 Anexos

Tabla 8: Parámetros de la red IEEE 33 barras

Line	R [Ω]	X [Ω]	Bus	P [kW]	Q [kvar]
Línea 1-2	0.0022	0.047	1	0	0
Línea 2-3	0.493	0.2511	2	100	60
Línea 3-4	0.366	0.1864	3	90	40
Línea 4-5	0.3811	0.1941	4	120	80
Línea 5-6	0.819	0.707	5	60	30
Línea 6-7	0.1872	0.6188	6	60	20
Línea 7-8	1.7114	1.2351	7	200	100
Línea 8-9	1.03	0.74	8	200	100
Línea 9-10	1.044	0.74	9	60	20
Línea 10-11	0.1966	0.065	10	60	20
Línea 11-12	0.3744	0.1238	11	45	30
Línea 12-13	1.468	1.155	12	60	35
Línea 13-14	0.5416	0.7129	13	60	35
Línea 14-15	0.591	0.526	14	120	80
Línea 15-16	0.7463	0.545	15	60	10
Línea 16-17	1.289	1.721	16	60	20
Línea 17-18	0.732	0.574	17	60	20
Línea 2-19	0.164	0.1565	18	90	40
Línea 19-20	1.5042	1.3554	19	90	40
Línea 20-21	0.4095	0.4784	20	90	40
Línea 21-22	0.7089	0.9373	21	90	40
Línea 3-23	0.4512	0.3083	22	90	40
Línea 23-24	0.898	0.7091	23	90	50
Línea 24-25	0.896	0.7011	24	420	200
Línea 6-26	0.203	0.1034	25	420	200
Línea 26-27	0.2842	0.1447	26	60	25
Línea 27-28	1.059	0.9373	27	60	25
Línea 28-29	0.8042	0.7006	28	60	20
Línea 29-30	0.5075	0.2585	29	120	70
Línea 30-31	0.9744	0.963	30	200	600
Línea 31-32	0.3105	0.3619	31	150	70
Línea 32-33	0.341	0.5302	32	210	100
			33	60	40