

Estrategia de control tensión-reactiva en sistemas de distribución a partir de bancos de capacitores y cambia tomas en transformadores utilizando máquinas de aprendizaje

Maicol Owen Suárez Cepeda y David Felipe Garces Durán

Trabajo de Grado para optar al título de Ingeniero Electricista

Director

César Antonio Duarte Gualdrón  
Doctor en Ingeniería Eléctrica

Codirector

César Augusto Cristancho Castro  
Ingeniero Electricista

Universidad Industrial de Santander  
Facultad de Ingenierías Fisicomecánicas  
Escuela de ingenierías Eléctrica, Electrónica y de Telecomunicaciones  
Ingeniería Eléctrica  
Bucaramanga  
2024

### **Dedicatoria**

A nuestras madres Luz Mireya Cepeda Aceros y Libia Yaneth Duran.  
*A ustedes, por ser el pilar de nuestra vida y el ejemplo más puro de amor incondicional.*

### **Agradecimientos**

En primer lugar, expresamos nuestro más profundo agradecimiento a nuestras familias, quienes siempre estuvieron a nuestro lado, brindándonos amor, motivación y soporte. Sus palabras de aliento y su confianza en nosotros fueron una fuente de energía en los momentos más complicados.

A nuestros amigos, que se convirtieron en compañeros de este viaje, les agradecemos por compartir risas, preocupaciones y sueños. Su compañía y apoyo hicieron que el camino fuera más llevadero y enriquecedor. Un agradecimiento especial a nuestro amigo Emmanuel Manzano, por su ayuda y sus consejos brindados durante la elaboración del documento.

Finalmente, queremos expresar nuestra sincera gratitud a nuestros maestros, quienes con su conocimiento, paciencia y dedicación, guiaron nuestra formación académica. Sus enseñanzas no solo ampliaron nuestros horizontes intelectuales, sino que también nos inspiraron a superarnos cada día.

### Tabla de contenido

	Pág.
Nomenclatura . . . . .	7
Introducción . . . . .	10
1. Control tensión-reactiva en sistemas de distribución . . . . .	11
1.1. Objetivos . . . . .	12
1.1.1. Objetivo general . . . . .	12
1.1.2. Objetivos específicos . . . . .	12
2. Revisión de literatura . . . . .	13
2.1. Redes neuronales artificiales . . . . .	13
2.2. Máquinas de soporte vectorial . . . . .	13
2.3. Aprendizaje por refuerzo . . . . .	14
2.4. Aprendizaje por refuerzo profundo . . . . .	14
2.5. Aprendizaje por refuerzo multiagente . . . . .	14
3. Selección de un artículo de investigación . . . . .	14
3.1. Artículo seleccionado . . . . .	15
3.2. Problema de optimización . . . . .	15
3.3. Teoría de la máquina de soporte vectorial . . . . .	16
3.4. Máquina de aprendizaje multiclase . . . . .	18
4. Máquinas de soporte vectorial aplicada al problema de control tensión-reactiva . . . . .	19
4.1. Esquema SVM aplicado al VVC . . . . .	19
4.2. Normalización de los datos de entrada . . . . .	21
4.3. Entrenamiento de la máquina de soporte vectorial . . . . .	22
5. Casos de estudio y métodos para evaluar la SVM . . . . .	22
5.1. Descripción del sistema IEEE 33 barras . . . . .	23
5.2. Potencia base y representación gráfica del sistema . . . . .	23
5.3. Algoritmo DCD . . . . .	23
5.4. Condiciones iniciales para los experimentos propuestos por el artículo . . . . .	24
5.5. Escenarios de prueba planteados en el artículo seleccionado . . . . .	27
5.5.1. Experimento con 8 barras . . . . .	27
5.5.2. Experimento con ruido blanco Gaussiano . . . . .	27
5.5.3. Experimento con capacitor fijo . . . . .	28
5.6. Escenarios planteados por Cristancho Castro (2023) . . . . .	28
6. Resultados obtenidos . . . . .	31
6.1. Resultados de la variación de los datos de entrenamiento . . . . .	31
6.2. Resultados de los experimentos del artículo seleccionado . . . . .	32
6.3. Resultados de los escenarios planteados por Cristancho Castro (2023) . . . . .	33
6.3.1. Resultados del caso base . . . . .	33
6.3.2. Resultados de las simulaciones por el método de Montecarlo . . . . .	35
7. Conclusiones . . . . .	37
Referencias Bibliográficas . . . . .	40

**Lista de Tablas**

	Pág.
Tabla 1	Características del transformador. . . . . 23
Tabla 2	Ubicación, capacidad y cantidad de tomas de los bancos de capacitores. . . . . 24
Tabla 3	Potencia base de las 32 barras <i>PQ</i> del sistema de distribución. . . . . 25
Tabla 4	Curva de demanda horaria del operador de red. . . . . 30
Tabla 5	Resultados para diferentes variaciones en la potencia base. . . . . 31
Tabla 6	Precisión de las SVM de las tres variantes de datos generados. . . . . 32
Tabla 7	Resultados para diferentes condiciones de prueba. . . . . 32
Tabla 8	Precisión de la predicción de la SVM ante diferentes condiciones de prueba en el sistema de distribución. . . . . 33
Tabla 9	Resultados con diferentes coeficientes de variación. . . . . 36
Tabla 10	Precisión de las cuatro SVM entrenadas. . . . . 37
Tabla 11	Tiempos de ejecución con diferentes coeficientes de variación. . . . . 37

**Lista de Figuras**

	Pág.
Figura 1	Clasificación de una SVM binaria. . . . . 17
Figura 2	Esquema unificado de control tensión-reactiva basado en SVM. . . . . 20
Figura 3	Esquema del entrenamiento y predicción de una SVM multiclase. . . . . 21
Figura 4	Sistema de distribución IEEE de 33 nodos. . . . . 26
Figura 5	Potencia aparente en cabecera. . . . . 33
Figura 6	Comparación entre la optimización y las predicciones de la SVM en el perfil de tensión en la barra 2. . . . . 34
Figura 7	Factor de potencia en la barra de alimentación. . . . . 34
Figura 8	Coefficiente de variación del 10 %. . . . . 35
Figura 9	Coefficiente de variación del 30 %. . . . . 35
Figura 10	Coefficiente de variación del 60 %. . . . . 36

### Nomenclatura

$\alpha_j$	Multiplicadores de Lagrange.
$\mathbf{x}_i$	Vectores de datos de entrada.
$\mathbf{x}_j^{sv}$	Vectores de soporte.
$\mathbf{y}_j^{sv}$	Etiqueta que corresponde a $j$ -ésimo vector.
$\Gamma$	Función gamma.
$\gamma$	Parámetro que maneja la anchura de la función kernel RBF.
$\lambda$	Factor de escalamiento.
$\xi_i$	Variables de holgura.
$b$	Término de sesgo.
$BR$	Conjunto de todas las ramas.
$C$	Penalización positiva predefinida.
$CAP$	Conjunto de nodos con condensadores conmutados conectados a ellos.
$D$	Número de características.
$DG$	Conjunto de nodos con generación distribuida conectada a ellos.
$I_i$	Valores complejos de corriente de inyección en el nodo $i$ .
$k$	Factor de forma de la función Weibull.
$N$	Número de observaciones.
$N^{sv}$	Número de vectores de soporte.
$n_t$	Número total de taps en un transformador dado.
$P$	Potencia activa.
$Q$	Potencia reactiva.
$t_{ij}$	Posición del tap del transformador en la rama $ij$ , elegido del conjunto $t_{ij}^{(1)}, \dots, t_{ij}^{(n_t)}$ .
$TR$	Conjunto de ramas de transformadores con cambiador de tomas.
$V$	Tensión eficaz.
$V_i$	Valores complejos de tensión nodal en el nodo $i$ .
$w$	Vector perpendicular al hiperplano.
$y_{ij}$	Admitancia en serie de la rama $ij$ .
$y_i$	Etiquetas de clases asignada.

## Resumen

**Título:** Estrategia de control tensión-reactiva en sistemas de distribución a partir de bancos de capacitores y cambia tomas en transformadores utilizando máquinas de aprendizaje. \*

**Autor:** Maicol Owen Suárez Cepeda y David Felipe Garces Durán. \*\*

**Palabras clave:** capacitores, medición de tensión, potencia reactiva, transformadores, máquina de aprendizaje, control tensión-reactiva.

### Descripción:

Este trabajo de grado se enfoca en la implementación de una máquina de aprendizaje para el control tensión-reactiva en un sistema de distribución eléctrica. Las variables de decisión son los ajustes en cambia tomas de bancos de capacitores y transformadores de potencia de la subestación. Basado en una revisión de literatura, se selecciona un artículo que emplea máquinas de soporte vectorial (SVMs) de tipo clasificación, modeladas mediante generación de datos a partir de un caso base de potencia activa y reactiva en un sistema de distribución IEEE de 33 barras. Estos datos se utilizan para resolver flujos de potencia sin control, obteniendo datos de tensión y completando los descriptores de entrada necesarios para la máquina de aprendizaje (potencia activa, potencia reactiva y tensión eficaz). El trabajo se divide en dos partes. La primera modela y evalúa el desempeño de la máquina de aprendizaje en diferentes escenarios de operación que afectan a los datos de prueba, tal como son descritos en el artículo seleccionado, en el que se presentan resultados como la mayor desviación de tensión, casos de sobretensión y subtensión. En la segunda parte se utiliza el método desarrollado en el trabajo de grado titulado «*Estrategia de control tensión-reactiva en sistemas de distribución a partir de bancos de condensadores y cambia tomas en transformadores*» de la Universidad Industrial de Santander. Aquí, se presenta un algoritmo de optimización por descenso de coordenadas discretas para determinar las variables óptimas de control. Además se generan datos mediante simulaciones de Montecarlo con una distribución de probabilidad de Weibull en escenarios de demanda horaria. Estos datos son usados para modelar cuatro SVMs con el objetivo de predecir la posición de las variables de decisión para las 24 horas de la demanda horaria. Finalmente, se compara la optimización con las predicciones de la máquina de aprendizaje, evaluando tiempo de ejecución, casos de sobretensión y subtensión, y la mayor desviación de tensión.

---

\* Trabajo de grado

\*\* Facultad de Ingenierías Fisicomecánicas. Escuela de ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Director: César Antonio Duarte Gualdrón. Doctor en Ingeniería Eléctrica. Codirector: César Augusto Cristancho Castro. Ingeniero Electricista

### Abstract

**Title:** Voltage-reactive control strategy in distribution systems Using Capacitor Banks and Transformer Tap Changers with Machine Learning. \*

**Author:** Maicol Owen Suárez Cepeda y David Felipe Garces Durán. \*\*

**Keywords:** capacitors, voltage measurement, reactive power, transformers, machine learning, voltage-reactive control

### Description:

This degree work focuses on the implementation of a machine learning approach for voltage-reactive control in an electrical distribution system. The decision variables are the tap settings of capacitor banks and substation power transformers. Based on a literature review, an article that employs classification-type support vector machines (SVMs) is selected, where SVMs are modeled using data generation from a base case of active and reactive power in an IEEE 33-bus distribution system. These data are used to solve uncontrolled power flows, obtaining voltage data and completing the necessary input descriptors for the machine learning model (active power, reactive power, and effective voltage). The work is divided into two parts. The first part models and evaluates the performance of the machine learning approach in different operating scenarios affecting the test data, as described in the selected reference article, presenting results such as the highest voltage deviation, overvoltage, and undervoltage cases. In the second part, the method developed in the thesis titled «*Estrategia de control tensión-reactiva en sistemas de distribución a partir de bancos de condensadores y cambia tomas en transformadores*» from the Industrial University of Santander is used. Here, a discrete coordinate descent optimization algorithm is presented to determine the optimal control variables. Additionally, data are generated through Monte Carlo simulations with a Weibull probability distribution in hourly demand scenarios. These data are used to model four SVMs with the goal of predicting the position of the decision variables for 24 hours of hourly demand. Finally, the optimization is compared with the machine learning predictions, evaluating execution time, overvoltage and undervoltage cases, and the highest voltage deviation.

---

\* Degree work

\*\* Faculty of Physical-Mechanical Engineering. Electrical, Electronic and Telecommunications Engineering School. Director: César Antonio Duarte Gualdrón. Ph.D. in Electrical Engineering. Co-director: César Augusto Cristancho Castro. Electrical Engineer

## Introducción

El control de tensión y potencia reactiva en sistemas de distribución eléctrica es fundamental para garantizar la estabilidad y eficiencia operativa de la red. Este control tiene como objetivo mantener los niveles de tensión dentro de los límites establecidos, minimizar las pérdidas de potencia y asegurar un suministro de energía adecuado a los usuarios. Tradicionalmente, las estrategias de control se han basado en métodos convencionales, como el ajuste de cambiadores de tomas en transformadores y la operación de bancos de capacitores. No obstante, la creciente complejidad de las redes eléctricas modernas, impulsada por la integración de fuentes de energía renovable y el aumento en la demanda de energía, ha generado nuevos retos que requieren soluciones más avanzadas y adaptativas.

En este contexto, las técnicas de aprendizaje automático se presentan como herramientas útiles para abordar problemas complejos en la gestión de redes eléctricas. Las máquinas de soporte vectorial (SVM) destacan por su capacidad de clasificación y predicción, lo que las convierte en candidatas para aplicaciones en el control de tensión y potencia reactiva.

Este trabajo tiene como objetivo implementar y evaluar el uso de máquinas de soporte vectorial en el control tensión - reactiva en un sistema de distribución eléctrica. Se realiza un modelado de SVM utilizando datos generados a partir de un caso base de un sistema de 33 nodos, siguiendo las directrices del estándar IEEE. Los descriptores de entrada incluyen variables como la potencia activa, la potencia reactiva y la tensión eficaz en los nodos. A partir de este modelo, se evalúa el desempeño de la SVM en diferentes escenarios operativos y se comparan los resultados obtenidos con los métodos de control convencionales, resaltando las ventajas y limitaciones del enfoque propuesto.

Este estudio busca contribuir al desarrollo de estrategias más robustas y eficientes para el control tensión - reactiva en sistemas de distribución eléctrica, aprovechando las capacidades de predicción y optimización que ofrece el aprendizaje automático.

## 1. Control tensión-reactiva en sistemas de distribución

En los sistemas de distribución eléctrica, el control adecuado de los niveles de tensión y de la potencia reactiva es esencial para garantizar la estabilidad y eficiencia operativa del sistema. Los operadores de redes de distribución deben mantener las tensiones dentro de rangos aceptables para evitar problemas como la sobrecarga de equipos, pérdidas de energía, y daños en la infraestructura eléctrica. Con la creciente demanda de energía y la complejidad de las redes de distribución, el control tensión-reactiva se ha convertido en un desafío fundamental. Las técnicas tradicionales de control tensión-reactiva, como el ajuste de cambiadores de tomas en transformadores y la operación de bancos de capacitores, se basan en modelos estáticos y reglas heurísticas. Estas técnicas pueden ser insuficientes para adaptarse rápidamente a los cambios en la demanda, ya que requieren de un tiempo considerable para obtener una respuesta óptima, y en consecuencia, comprometer la calidad del servicio eléctrico. El control inadecuado de la tensión-reactiva no solo afecta la estabilidad del sistema, sino que también puede tener consecuencias económicas, como penalizaciones por incumplimiento de los estándares de calidad del servicio establecidos por regulaciones como la NTC 5001 y las resoluciones de la CREG. Además, un control ineficiente puede aumentar las pérdidas técnicas en el sistema, incrementando los costos operativos y reduciendo la vida útil de los equipos.

Las causas principales del problema incluyen la rigidez de los métodos actuales de control, que no consideran de manera adecuada la variabilidad temporal de la demanda. Además, la falta de herramientas avanzadas de predicción y la dependencia de operadores humanos para realizar ajustes manuales en los equipos contribuyen a la ineficiencia del sistema. La descripción se centra en el impacto del control tensión-reactiva en la calidad del servicio y en la eficiencia operativa de los sistemas de distribución de energía eléctrica, sin considerar la influencia de fuentes de energía renovable. Se plantea la hipótesis de que la implementación de técnicas de aprendizaje automático, como las máquinas de soporte vectorial (SVM), puede mejorar significativamente el tiempo requerido para realizar el control tensión-reactiva al permitir la predicción de los ajustes óptimos en los dispositivos de control.

El problema del control tensión-reactiva ha sido un desafío constante en los sistemas eléctricos, y con la evolución de las redes y el aumento de la demanda de energía, la urgencia de mejorar las estrategias de control es mayor que nunca. Para abordar este desafío, se propone utilizar simulaciones de flujo de potencia en el lenguaje de programación Python, para generar un conjunto de datos que alimente al modelo SVM, optimizando dicho modelo mediante técnicas de validación cruzada y evaluando su desempeño en escenarios de prueba que simulen condiciones reales del sistema de distribución. La aplicación de técnicas de aprendizaje automático, como SVM, tiene el potencial de mejorar la eficiencia y estabilidad del sistema, mitigando las deficiencias de los métodos tradicionales.

## **1.1. Objetivos**

### ***1.1.1. Objetivo general***

Evaluar el desempeño de una estrategia de control tensión - reactiva en un sistema de distribución, a partir de banco de capacitores y cambia tomas en transformadores, utilizando máquinas de aprendizaje y considerando diferentes escenarios de operación.

### ***1.1.2. Objetivos específicos***

- Recopilar información sobre las estrategias de control tensión-reactiva en sistemas de distribución partiendo de la búsqueda de artículos científicos que involucren el uso de máquinas de aprendizaje.
- Implementar una máquina de aprendizaje basada en máquina de soporte vectorial (SVM) para el control tensión-reactiva seleccionada y que considere como elementos de control bancos de capacitores y cambia tomas en transformadores de potencia.
- Evaluar mediante simulación el desempeño de la máquina de aprendizaje implementada en un sistema de prueba IEEE considerando distintos escenarios de operación.

## 2. Revisión de literatura

Para la selección de un artículo, se realiza una revisión de la literatura científica en las bases de datos de la Universidad Industrial de Santander (UIS) y utilizando herramientas de búsqueda como Google Scholar y Semantic Scholar. Esta revisión se lleva a cabo mediante el uso de palabras clave como *Volt-Var Control*, *capacitor banks*, *distribution systems* y *Machine Learning*. Además, se filtran los resultados por fechas de publicación, abarcando desde el año 2010 en adelante. Los artículos sugeridos por las bases de datos presentan diferentes técnicas de *machine learning* aplicadas al control *Volt-Var* (VVC), las cuales se detallan a continuación.

### 2.1. Redes neuronales artificiales

Las redes neuronales artificiales (*artificial neural networks*, ANN) son modelos computacionales inspirados en el funcionamiento del cerebro humano. En estas redes, las neuronas están interconectadas a través de enlaces. Cada neurona recibe entradas, las procesa mediante una función de activación y transmite la salida a otras neuronas. Cada conexión tiene un peso específico que determina la activación de las neuronas adyacentes. Las ANN son especialmente útiles para resolver problemas complejos que involucran grandes cantidades de datos y patrones no lineales. En el trabajo de Biserica et al. (2012), las ANN se utilizan para el control tensión-reactiva, permitiendo optimizar el rendimiento del sistema y reducir las pérdidas de energía, incluso cuando se trata de redes eléctricas modernas con alta penetración de generación distribuida.

### 2.2. Máquinas de soporte vectorial

Las máquinas de soporte vectorial, conocidas por sus siglas en inglés como SVM (*support vector machine*) son un modelo de aprendizaje supervisado que se utiliza para la regresión o clasificación. El objetivo del SVM es buscar un hiper-plano óptimo para realizar la separación de los datos en diferentes clases. Los puntos más cercanos al hiper-plano son los llamados vectores de soporte, estos vectores se encargan de determinar la posición y orientación del hiper-plano. Salles et al. (2016) utilizan una máquina de soporte vectorial para tratar el problema del VVC.

### **2.3. Aprendizaje por refuerzo**

El aprendizaje por refuerzo es un aprendizaje en el cual un agente toma acciones en un espacio con el objetivo de conseguir una recompensa. La situación en la que se encuentra el agente en un momento dado se conoce como estado. La estrategia que utiliza el agente para tomar acciones en función del estado que se encuentre se conoce como política. En (S. Zhang et al., 2022) se utiliza el aprendizaje por refuerzo para resolver el VVC en sistemas de distribución con alta penetración solar.

### **2.4. Aprendizaje por refuerzo profundo**

El aprendizaje por refuerzo profundo es una técnica en donde se combina el aprendizaje por refuerzo con el aprendizaje profundo (el aprendizaje profundo es un subconjunto del *machine learning* que utiliza redes neuronales multicapas con el objetivo de modelar y analizar datos). Con esta combinación la política óptima se obtiene a partir de las redes neuronales multicapas. En (Liu et al., 2021) se resuelve el problema de VVC en un sistema IEEE de 33 buses utilizando aprendizaje por refuerzo profundo.

### **2.5. Aprendizaje por refuerzo multiagente**

Este tipo de aprendizaje es una extensión del aprendizaje por refuerzo que consiste en la interacción de varios agentes en un mismo entorno, cada agente aprende a tomar decisiones a partir de sus propias recompensas. En (Gao et al., 2021) se utiliza el aprendizaje por refuerzo multiagente que permite que cada agente aprenda una política de control grupal usando las recompensas locales para tratar el problema del VVC.

## **3. Selección de un artículo de investigación**

En este capítulo se presenta la estrategia de selección de un artículo de acuerdo a ciertos criterios y además se realiza una explicación a profundidad de la máquina de aprendizaje del artículo seleccionado. Los criterios para seleccionar el artículo son los siguientes:

- El artículo debe explicar de manera detallada el modelado de la máquina de aprendizaje utilizada,
- el sistema eléctrico analizado en el artículo debe ser un sistema de distribución basado en un estándar de la IEEE,
- las variables de control discretas utilizadas en el artículo deben incluir bancos de capacitores conmutables y transformadores con cambia tomas,
- los resultados deben estar enfocados en mantener los niveles de tensión dentro de los límites permitidos y en la reducción de pérdidas de potencia, sin tener en cuenta la generación distribuida.

### 3.1. Artículo seleccionado

El artículo seleccionado es «*Integrated Volt/Var Control in Modern Distribution Power Systems Based on Support Vector Machines*» (Salles et al., 2016). Este artículo cumple con los criterios de selección, ya que emplea una máquina de soporte vectorial para el control tensión-reactiva en un sistema de prueba IEEE de 33 barras. El artículo propone varios escenarios para evaluar la eficiencia de la máquina de aprendizaje y presenta los resultados obtenidos a través de la optimización y la predicción.

### 3.2. Problema de optimización

El problema de optimización empleado en Cristancho Castro (2023) es utilizado para determinar los estados de conexión y desconexión de bancos de capacitores así como la configuración de los tomas del transformador es el siguiente:

$$\underset{v_i^{\text{Re}}, v_i^{\text{Im}}}{\text{minimizar}} \sum_{i=1}^n \sum_{j=1}^n v_i^{\text{Re}} Y_{ij}^{\text{Re}} v_j^{\text{Re}} + \sum_{i=1}^n \sum_{j=1}^n v_i^{\text{Im}} Y_{ij}^{\text{Im}} v_j^{\text{Im}} \quad (1a)$$

$$\text{sujeto a} \quad V_i^{\text{min}} \leq V_i \leq V_i^{\text{máx}}, \quad i = 1, \dots, n, \quad (1b)$$

$$I_{ij} \leq I_{ij}^{\text{máx}}, \quad ij \in BR, \quad (1c)$$

$$t_{ij} \in \{t_{ij}^{(1)}, t_{ij}^{(2)}, \dots, t_{ij}^{(n_i)}\}, \quad i, j \in TR, \quad (1d)$$

$$Q_{Ci} = Q_{0i} V_i^2, \quad Q_{0i} \in \{Q_{0i}^{(1)}, Q_{0i}^{(2)}, \dots, Q_{0i}^{(n_i)}\}, \quad i \in CAP, \quad (1e)$$

$$V_i^2 = (V_i^{\text{Re}})^2 + (V_i^{\text{Im}})^2, \quad (1f)$$

$$I_{ij}^2 = \left( y_{ij}^{\text{Im}} (V_i^{\text{Re}} - V_j^{\text{Re}}) + y_{ij}^{\text{Re}} (V_i^{\text{Im}} - V_j^{\text{Im}}) \right)^2 + \left( y_{ij}^{\text{Im}} (V_i^{\text{Im}} - V_j^{\text{Im}}) - y_{ij}^{\text{Re}} (V_i^{\text{Re}} - V_j^{\text{Re}}) \right)^2. \quad (1g)$$

### 3.3. Teoría de la máquina de soporte vectorial

El proceso de clasificación mediante máquinas de soporte vectorial (SVM) se inicia con un conjunto de datos de entrenamiento como,

$$\mathcal{D} = \{\mathbf{X}, \mathbf{y}\} = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_N, y_N)\}, \quad (2)$$

donde  $N$  es el número de observaciones,  $\mathbf{x}_i \in \mathbb{R}^D$  son los vectores de datos de entrada de dimensión  $D$ , que representan el número de características o descriptores (por ejemplo, la potencia activa y reactiva de la carga), y  $y_i \in \{-1, 1\}$  son las etiquetas de clases asignadas (por ejemplo, banco de capacitores conectado o desconectado). El objetivo del algoritmo de la máquina de soporte vectorial es encontrar una función de decisión óptima que permita clasificar nuevos datos (es decir, aquellos que no forman parte del conjunto de entrenamiento) en una u otra categoría (en el caso de haber dos categorías) con el mínimo error de clasificación.

La función de decisión está dada por:


$$f(x) = \text{sign}[g(x)], \quad (3)$$

donde  $g(x)$  es el límite de decisión que proviene del conjunto de muestras de entrenamiento  $\mathbf{x}_i \in \mathbb{R}^D$ . El límite de decisión es un hiper-plano que tiene la mayor distancia al punto de datos de

entrenamiento más cercano de cualquier clase, como se muestra en la Figura 1. En general, un

**Figura 1**

*Clasificación de una SVM binaria.*



margen más amplio tiende a reducir el error de generalización del clasificador. El límite de decisión  $g(x)$  está dado por,

$$g(x) = \sum_{j=1}^{N^{sv}} \alpha_j y_j^{sv} [K(\mathbf{x}, \mathbf{x}_j^{sv})] + b, \quad (4)$$

donde  $K(\mathbf{x}, \mathbf{x}_j^{sv})$  es denominada función kernel y es utilizada para mapear los datos de entrada en espacios de mayor dimensión, aquí  $\mathbf{x}_j^{sv}$  son los vectores de soporte,  $y_j^{sv}$  es la etiqueta que corresponde a  $j$ -ésimo vector,  $N^{sv}$  es el número de vectores de soporte,  $b$  es un término de sesgo y  $\alpha_j$  son los multiplicadores de Lagrange. Las funciones kernel pueden ser lineales o no lineales, y la elección de la función kernel dependerá del problema en cuestión. Dado que el problema de *Volt-Var* es fuertemente no lineal, la selección del kernel debe adaptarse a estas condiciones de no linealidad. Un ejemplo común es la función kernel de base radial, conocida en inglés como *Radial Basis Function* (RBF), que se expresa de la siguiente manera,

$$K(x, x_j^{sv}) = \exp\left(-\gamma \left\| \mathbf{x} - \mathbf{x}_j^{sv} \right\|^2\right), \quad (5)$$

donde el parámetro  $\gamma$  maneja la anchura de la función kernel RBF. Los multiplicadores de Langrange  $\alpha_j$  de la ecuación (4) pueden ser obtenidos resolviendo el siguiente problema de optimización dual,

$$\begin{aligned} \underset{w, b, \xi}{\text{minimizar}} \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \\ \text{sujeto a} \quad & y_i(w \cdot x + b) \geq 1 - \xi_i \geq 0, \quad \forall i = 1, \dots, N, \\ & \xi_i \geq 0, \quad \forall i = 1, \dots, N. \end{aligned} \quad (6)$$

La optimización descrita en la ecuación (6) es clave para entrenar el modelo de la máquina de aprendizaje, encargándose de identificar los vectores de soporte en el conjunto de datos de entrenamiento (datos de entrada). La norma  $\|w\|$  representa un vector que es perpendicular al hiperplano que divide las clases. El parámetro  $C$  actúa como una penalización positiva predefinida, ajustando el equilibrio entre el margen de separación y los errores durante el entrenamiento. Las variables de holgura  $\xi_i$  se utilizan para evaluar el nivel de error en la clasificación o fallos durante el proceso de entrenamiento.

El parámetro kernel  $\gamma$  y de regularización  $C$  son entradas fundamentales durante el entrenamiento de la máquina de aprendizaje, y su ajuste es crucial para asegurar que el modelo pueda clasificar con precisión datos desconocidos, como los datos de prueba. Actualmente, no existe una guía definitiva, más allá del enfoque de prueba y error, sobre cómo fijar  $C$  y  $\gamma$ . Este trabajo no aborda métodos avanzados de selección de parámetros porque solo se trabajan dos parámetros ( $C$  y  $\gamma$ ), y el número de combinaciones posibles no es considerablemente grande (Salles et al., 2016).

### 3.4. Máquina de aprendizaje multiclase

Las máquinas de soporte vectorial fueron creadas originalmente para resolver problemas de clasificación binaria. Sin embargo, se han desarrollado varios métodos en los cuales se construye un clasificador multiclase combinando varios clasificadores binarios. En este trabajo, se utiliza el método “uno contra uno” para la clasificación multiclase. Este método consiste en construir clasificadores SVM para cada par de clases, donde cada clase se define como un conjunto que incluye una combinación de configuraciones de control de acción, como por ejemplo la posición de el toma de un transformador y el estado del banco de capacitores. En total, se tienen  $(k(k - 1))/2$

pares, donde  $k$  representa el número de clases. Es decir, para cada par de clases, se aborda un problema SVM binario. La función de decisión asigna una instancia a la clase que reciba la mayor cantidad de votos, utilizando la estrategia denominada *Max Wins*. Cada instancia corresponde a una observación derivada de la condición de la cuadrícula (es decir, los datos  $P$ ,  $Q$  y  $V$ ). Luego, se aplica una instancia al modelo, y cada clasificador binario SVM le otorga un voto a una clase específica. En caso de que persistan los empates, se asigna una etiqueta a cada muestra basándose en la clasificación derivada del hiper-plano más distante. Una de las ventajas de este método es que, al tratar cada par de clases, enfrentamos un problema de optimización mucho más reducido en comparación con el enfoque “uno contra todos”. Dado que los algoritmos de optimización QP empleados en las SVMs son polinómicos en relación con el tamaño del problema, esta reducción puede llevar a un ahorro considerable en el tiempo total de cálculo (Salles et al., 2016).

#### **4. Máquinas de soporte vectorial aplicada al problema de control tensión-reactiva**

Siguiendo el esquema propuesto en el artículo seleccionado, este capítulo se presenta el esquema del modelo SVM aplicado al VVC, la normalización de los datos de entrada y el entrenamiento de la SVM.

##### **4.1. Esquema SVM aplicado al VVC**

La Figura 2 y 3 muestran la estructura general del esquema SVM aplicado al VVC. Los pasos para entrenar la SVM y desarrollar un modelo que pueda predecir datos no conocidos (es decir, datos de prueba  $\mathcal{D}$ ) son los siguientes.

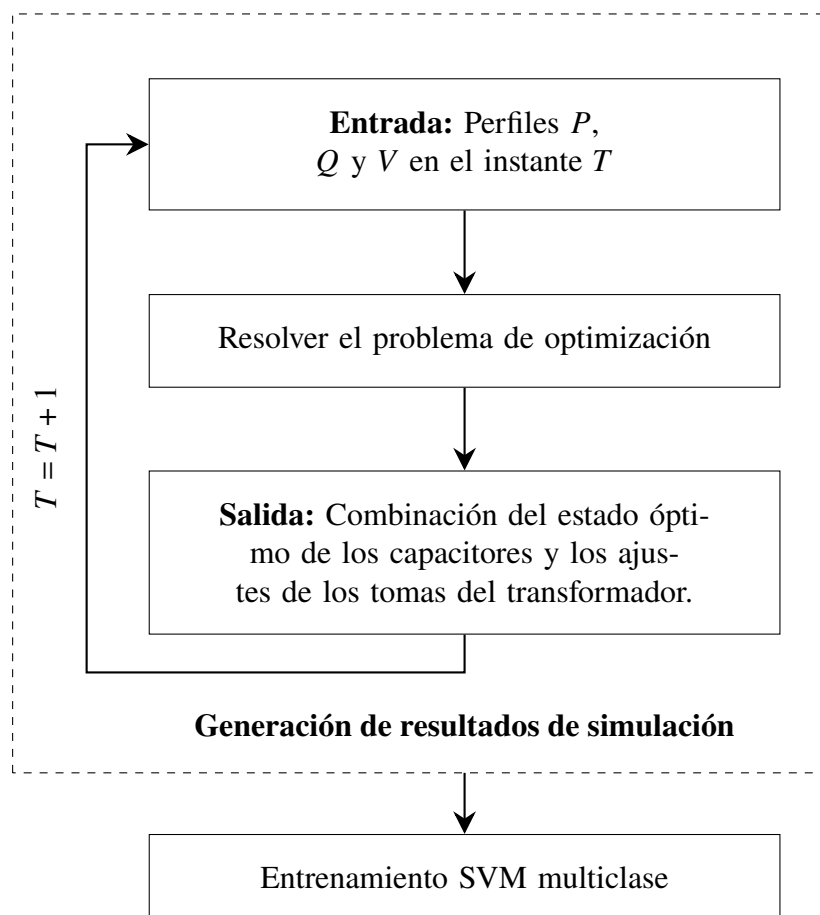
1. El primer paso implica la generación de datos para las entradas ( $X$ ) y salidas ( $y$ ) necesarias para los procesos de entrenamiento y prueba de la SVM. Como se observa en la Figura 2, las entradas incluyen la potencia activa ( $P$ ), la potencia reactiva ( $Q$ ) y la tensión eficaz ( $V$ ) registradas en cada barra  $PQ$  del sistema de distribución. Las salidas correspondientes son la posición óptima del toma del transformador de potencia y la potencia reactiva óptima inyectada por los capacitores conmutados, obtenidas al resolver el problema de optimización

que se encuentra en la Sección 3.2. Este problema necesita un esquema SVM multiclase, en el que cada clase hace referencia a una combinación específica de las posiciones de los cambia tomas del transformador de potencia y los bancos de capacitores.

2. Los datos de entrada que fueron generados se normalizan entre 0 y 1. Esta normalización se explica con más detalle en la Sección 4.2.

**Figura 2**

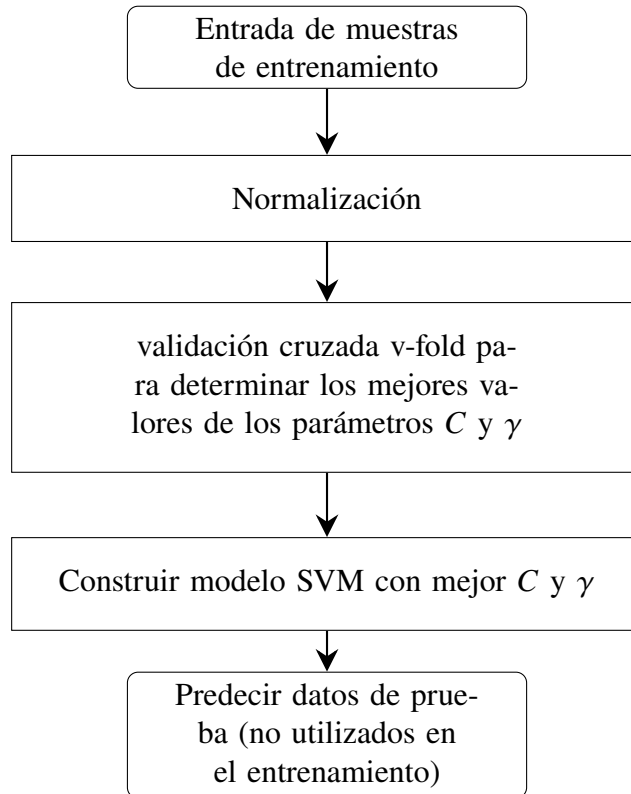
*Esquema unificado de control tensión-reactiva basado en SVM.*



*Nota: Adaptado de (Salles et al., 2016).*

**Figura 3**

Esquema del entrenamiento y predicción de una SVM multiclase.



Nota: Adaptado de (Salles et al., 2016).

#### 4.2. Normalización de los datos de entrada

Antes de aplicar la SVM, es fundamental normalizar los datos de entrada. El principal beneficio de la normalización es reducir el riesgo de que las características con valores numéricos más altos eclipsen a aquellas con valores más bajos. Además, la normalización evita problemas numéricos durante los cálculos. En este trabajo, se utiliza la normalización *Min-Max*, un método que escala los datos para que se encuentren dentro de un rango definido, en este caso, de 0 a 1. Este enfoque transforma cada valor  $x$  de una característica según la fórmula:

$$x_{\text{normalizado}} = \frac{x - x_{\text{mín}}}{x_{\text{máx}} - x_{\text{mín}}}, \quad (7)$$

donde  $x_{min}$  y  $x_{max}$  son el valor mínimo y máximo de la característica, respectivamente. De esta manera, se asegura que todos los valores estén dentro del rango especificado. Los datos de entrada  $P$ ,  $Q$  y  $V$  se escalaron individualmente (sin mezclar datos entre descriptores).

### 4.3. Entrenamiento de la máquina de soporte vectorial

Después de normalizar los datos, una parte se utiliza para entrenar la SVM y la otra para evaluar el modelo. La Figura 3 presenta un diagrama de flujo del proceso de entrenamiento. La precisión óptima del clasificador SVM se determina optimizando los parámetro del kernel RBF ( $\gamma$ ) y el parámetro de penalización de error ( $C$ ). El objetivo es encontrar los parámetros óptimos para que el clasificador prediga con precisión datos no vistos (es decir, datos de prueba). En este estudio, se utiliza el método de búsqueda en cuadrícula (*gridsearch*), que evalúa secuencias de parámetros con crecimiento exponencial para identificar aquellos que ofrecen la mejor precisión en la validación cruzada (*cross-validation*). En la validación cruzada *k-fold*, el conjunto de entrenamiento se divide en  $k$  subconjuntos de tamaño similar, y cada uno se prueba sucesivamente usando el clasificador entrenado en los otros  $(k - 1)$  subconjuntos. Para cada par de  $C$  y  $\gamma$ , se realiza una validación cruzada de 3 *fold*s con el objetivo de minimizar el error de clasificación, mejorar la capacidad de generalización y evitar que el clasificador *sobreajuste* los datos de entrenamiento. Una vez identificados los valores óptimos de  $C$  y  $\gamma$  la SVM está lista para clasificar nuevos datos (de prueba). En otras palabras, se utiliza la mejor combinación de  $C$  y  $\gamma$  para entrenar el modelo de la SVM, lo que permite predecir los ajustes óptimos del capacitor y el toma del transformador de potencia para los datos no vistos.

## 5. Casos de estudio y métodos para evaluar la SVM

El sistema de distribución utilizado en este trabajo de grado es un sistema IEEE de 33 barras (Baran & Wu, 1989). En este capítulo se describe los elementos, la potencia base y su representación gráfica. Además, se presenta el algoritmo DCD, las condiciones iniciales para los experimentos propuestos en el artículo y los escenarios planteados en (Cristancho Castro, 2023).

### 5.1. Descripción del sistema IEEE 33 barras

El sistema se compone de un transformador de potencia con cambia tomas y 7 bancos de capacitores conmutables. El transformador tiene 33 posiciones para el cambia tomas, ubicado en el devanado de alta tensión, y la relación de transformación 1:1 se encuentra en la posición 16. Los demás datos del transformador están detallados en la Tabla 1.

**Tabla 1**

*Características del transformador.*

Característica	Valor
Fases	3
Devanados	2
Reactancia de dispersión	8 %
Tensión	110/12,666 kV
Potencia aparente	5500 kVA
Conexión	$\Delta/Y$

*Nota: Datos del transformador, tomado de (Cristancho Castro, 2023).*

La ubicación de cada capacitor en el sistema de distribución, su capacidad en kVAr y el número de tomas están detallados en la Tabla 2. Cada incremento en la posición del cambia tomas corresponde a un aumento de 50 kVAr en la capacidad de los bancos de capacitores; por lo tanto, los equipos con 6 tomas pueden inyectar hasta 300 kVAr. La posición 0 indica la desconexión del equipo

### 5.2. Potencia base y representación gráfica del sistema

La potencia base del sistema se encuentra en la Tabla 3 y la representación gráfica se encuentra en la Figura 4.

### 5.3. Algoritmo DCD

El algoritmo de descenso de coordenadas discretas conocido por sus siglas en inglés como DCD (*Discrete Coordinate Descent*) es una técnica de optimización que se utiliza para resolver

**Tabla 2**

*Ubicación, capacidad y cantidad de tomas de los bancos de capacitores.*

Barra	Capacidad (kVAr)	Tomas
6	150	3
8	150	3
13	150	3
23	300	6
27	150	3
29	300	6
30	150	3

*Nota: Adaptado de Khodr et al. (2008)*

problemas donde las variables solo pueden asumir valores discretos.

#### **5.4. Condiciones iniciales para los experimentos propuestos por el artículo**

El artículo propone generar datos de entrenamiento y prueba variando la potencia base (Tabla 3) en un rango de pm 40 % respecto a sus valores nominales. Además de esto, se decide realizar un análisis comparativo de la precisión de la máquina de aprendizaje ante distintos porcentajes de variación de la potencia. Este análisis considera tres casos de variación, que se describen a continuación, donde los escenarios de prueba corresponden al 30 % de la cantidad de datos presentados en cada variación.

1. 300 escenarios de operación, variando la potencia base en un rango de 60 % y 140 %.
2. 300 escenarios de operación, variando la potencia base en un rango de 80 % y 100 %.
3. 1200 escenarios de operación, variando la potencia base en un rango de 80 % y 100 %.

Cada caso de variación, sigue este procedimiento: primero, se simula el flujo de potencia en OpenDSS por medio de su respectiva librería en Python, sin aplicar ningún control, es decir, con el cambia tomas del transformador en la posición 16 y los bancos de capacitores desconectados con el objetivo de determinar la tensión eficaz en cada barra. Los valores de potencia activa

**Tabla 3**

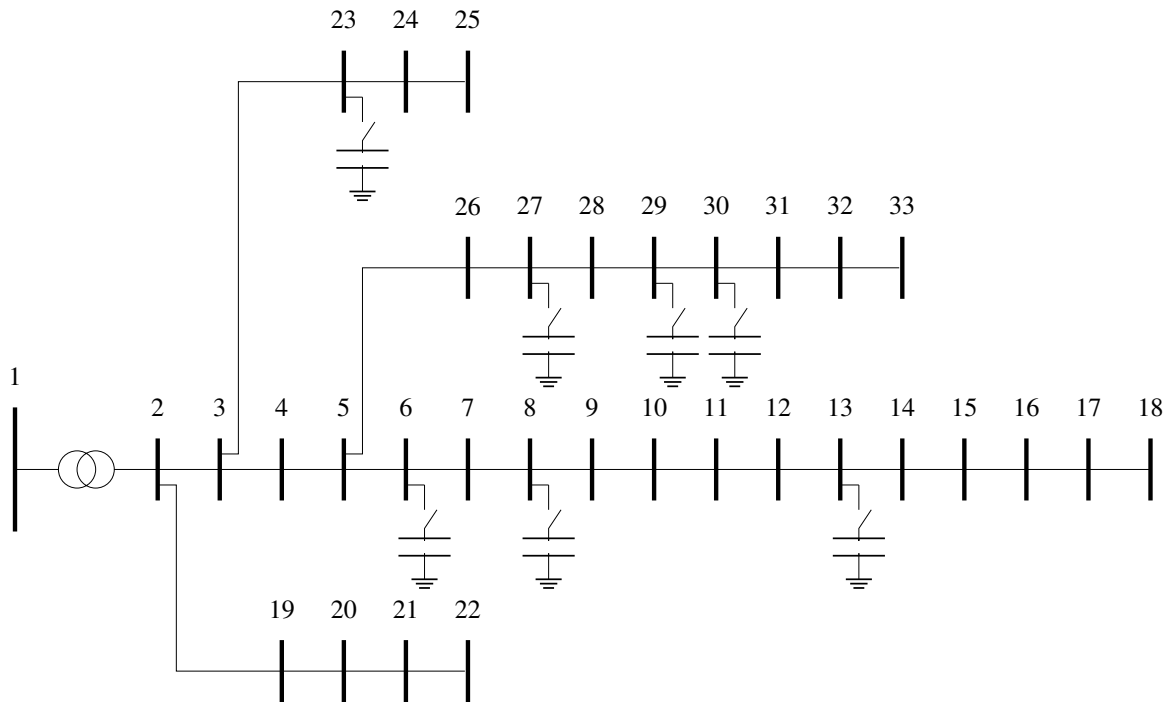
*Potencia base de las 32 barras PQ del sistema de distribución.*

N° barra	$P$ (kW)	$Q$ (kVAr)
2	100	60
3	90	40
4	120	80
5	60	30
6	60	20
7	200	100
8	200	100
9	60	20
10	60	20
11	45	30
12	60	35
13	60	35
14	120	80
15	60	10
16	60	20
17	60	20
18	90	40
19	90	40
20	90	40
21	90	40
22	90	40
23	90	50
24	420	200
25	420	200
26	60	25
27	60	25
28	60	20
29	120	70
30	200	600
31	150	70
32	210	100
33	60	40
Total	3715	2300

*Nota: Adaptado de (Cristancho Castro, 2023)*

**Figura 4**

*Sistema de distribución IEEE de 33 nodos.*



( $P$ ), potencia reactiva ( $Q$ ) y tensión eficaz ( $V$ ) de cada barra pasan por el algoritmo DCD para obtener las configuraciones óptimas de las variables de control (las posiciones del cambia tomas del transformador y de los bancos de capacitores), de cada escenario. Estas configuraciones se agrupan en clases, donde cada clase representa una combinación óptima de dichas variables de control.

El entrenamiento de la máquina de aprendizaje se lleva a cabo siguiendo los pasos indicados en la Figura 3, donde los descriptores de entrada corresponden a los datos normalizados de potencia activa, potencia reactiva y tensión eficaz sin aplicar control. Durante este proceso, se determinan los hiper-parámetros óptimos ( $C$  y  $\gamma$ ) para construir la máquina de soporte vectorial. El objetivo de la máquina es predecir las clases de los descriptores no utilizados en el entrenamiento (datos de prueba). Al realizar el análisis de variación en la generación de datos, se selecciona la máquina que proporciona la mayor precisión en la predicción de las clases y obtenga los mejores resultados en los siguientes factores:

1. Reducción de pérdidas de potencia activa con respecto a las pérdidas obtenidas en el caso sin control.
2. Número de casos con sobretensión en cada barra por cada escenario de operación.
3. Número de casos con subtensión en cada barra por cada escenario de operación.
4. Mayor desviación de tensión con respecto a la tensión nominal (1 pu).

Los resultados de los factores anteriores se reflejan en la Tabla 5, mientras que la precisión obtenida por cada máquina de aprendizaje entrenada se presenta en la Tabla 6.

### **5.5. Escenarios de prueba planteados en el artículo seleccionado**

El artículo presenta cuatro escenarios de prueba; sin embargo, se llevan a cabo solo tres debido a la falta de claridad en la información proporcionada sobre el escenario restante. Además, se considera que estos escenarios afectan únicamente a los datos de prueba, los cuales se utilizan para la predicción de clases con la máquina de aprendizaje seleccionada en la sección 5.4..

#### **5.5.1. Experimento con 8 barras**

Este experimento utiliza 8 barras del sistema de distribución. Esto significa que, en lugar de ingresar 96 descriptores (correspondientes a las 32 barras  $PQ$ ), se ingresan solo 24 descriptores. Este enfoque representa situaciones en las que un sistema de distribución no cuenta con equipos de medición en todas las barras. Los resultados de este experimento se muestran en la Tabla 7 y la precisión de la predicción se detalla en la Tabla 8.

#### **5.5.2. Experimento con ruido blanco Gaussiano**

En este experimento, se aplica un ruido blanco gaussiano (un tipo de ruido estadístico que sigue una distribución normal) a los datos de prueba, simulando posibles señales de ruido en las medidas registradas por los equipos de medición del sistema de distribución. Los resultados se presentan en la Tabla 7. y la precisión de la SVM en este experimento se detalla en la Tabla 8.

### 5.5.3. Experimento con capacitor fijo

En este experimento se conecta un banco de capacitores fijo (no conmutable) con una capacidad de 50 kVAr a la barra 17 del sistema de distribución, simulando un posible caso en el que el operador de red considere la incorporación de dicho equipo al sistema. Los resultados se muestran en la Tabla 7 y la precisión de la SVM en este experimento se encuentra en la Tabla 8.

## 5.6. Escenarios planteados por Cristancho Castro (2023)

Cristancho Castro (2023) presenta un método para generar datos utilizando simulaciones de Monte Carlo basadas en la distribución de Weibull, explicando cómo la inversa de la función de distribución acumulada (CDF) se emplea para este propósito. En lugar de utilizar la función de probabilidad directamente, se trabaja con la inversa de la distribución acumulada porque, en los métodos de Monte Carlo, el proceso de generación de datos comienza con números aleatorios uniformemente distribuidos entre 0 y 1. Para convertir estos valores en datos que sigan una distribución específica, en este caso, Weibull, es necesario aplicar la función inversa de su CDF, la cual transforma esas probabilidades acumuladas en valores reales que siguen la distribución deseada.

La inversa de la CDF de Weibull se expresa de la siguiente manera,

$$F_{WBL}^{-1}(p; k, \lambda) = \lambda(-\ln(1 - p))^{1/k}, \quad (8)$$

donde  $p$  es un número aleatorio entre 0 y 1, y  $k$  y  $\lambda$  son los parámetros de forma y escala de la distribución de Weibull, respectivamente. Estos parámetros controlan cómo se ajustan los datos generados:  $k$  influye en la forma de la curva, afectando la asimetría y el sesgo de los valores, mientras que  $\lambda$  determina la escala de los mismos.

El uso de la función inversa es crucial en este tipo de simulaciones, ya que garantiza que los datos generados respeten la estructura probabilística definida por la distribución. Así, valores de  $p$  cercanos a 0 resultarán en valores cercanos al mínimo de la distribución, mientras que valores de  $p$  cercanos a 1 darán valores más grandes, reflejando la “cola” de la distribución.

La generación de datos en el contexto del trabajo aborda tres escenarios diferentes, cada

uno con un coeficiente de variación distinto ( $C_{\text{variación}}$ ). Este coeficiente mide la relación entre la desviación estándar y la media de la distribución, proporcionando una medida de la dispersión relativa de los datos,

$$C_{\text{variación}} = \frac{\sigma}{\mu} \cdot 100 \%, \quad (9)$$

donde  $\sigma$  es la desviación estándar y  $\mu$  es la media de la distribución. La variabilidad de los datos es clave en la simulación de Montecarlo, ya que permite explorar diferentes grados de incertidumbre o dispersión en los datos generados. Para calcular estos valores, se derivan las siguientes expresiones, basadas en la distribución de Weibull. La media  $\mu$  de la distribución está dada por,

$$\mu = \lambda \cdot \Gamma \left( 1 + \frac{1}{k} \right). \quad (10)$$

Por otro lado, la desviación estándar  $\sigma$ , que mide la dispersión de los datos alrededor de la media, está dada por,

$$\sigma = \sqrt{\lambda \left[ \Gamma \left( 1 + \frac{2}{k} \right) - \left( \Gamma \left( 1 + \frac{1}{k} \right) \right)^2 \right]}. \quad (11)$$

Estas fórmulas permiten calcular la variabilidad de los datos generados en función de los parámetros  $k$  y  $\lambda$ , lo cual es esencial para comprender cómo la forma y escala de la distribución Weibull afectan la dispersión de los datos.

En esta etapa, se lleva a cabo el entrenamiento de cuatro SVMs. Cada máquina es entrenada con los datos correspondientes a seis horas de la demanda horaria, ordenados de menor a mayor. Así, la primera SVM se entrena con los datos de menor demanda horaria y la última con los de mayor demanda. Cada hora incluye 100 escenarios de datos de entrenamiento y 30 de prueba, compuestos por la potencia activa, potencia reactiva y tensión eficaz sin control de las 32 barras  $PQ$ . El proceso de entrenamiento sigue los pasos detallados en la Figura 3 y los factores de escalamiento ( $\lambda$ ) y forma ( $k$ ) para cada coeficiente de variación son los siguientes:

1. Coeficiente de variación del 10 %: factor de escala de 1,043 y factor de forma de 12,15347.
2. Coeficiente de variación del 30 %: factor de escala de 1,10786 y factor de forma de 3,7137.
3. Coeficiente de variación del 60 %: factor de escala de 1,2151 y factor de forma de 1,717037.

**Tabla 4**

*Curva de demanda horaria del operador de red.*

Hora	Demanda (pu)
1	0,28
2	0,25
3	0,26
4	0,25
5	0,23
6	0,44
7	0,69
8	0,44
9	0,44
10	0,36
11	0,38
12	0,51
13	0,40
14	0,38
15	0,37
16	0,41
17	0,49
18	0,34
19	0,61
20	0,81
21	1,00
22	0,86
23	0,69
24	0,36

*Nota: Demanda horaria en una zona residencial estrato cuatro, tomado de (Rodríguez et al., 2021).*

Finalizado el entrenamiento, se ejecutan las pruebas descritas por Crisnacho Castro (2023), que comparan los resultados obtenidos mediante el algoritmo de optimización con aquellos del caso base sin control. Estas comparaciones se realizan en tres aspectos clave: la potencia aparente en la cabecera del sistema de distribución, el factor de potencia y la tensión en la barra 2.

A continuación, se genera una nueva serie de datos utilizando el método de Monte Carlo con una distribución de Weibull y los coeficientes de variación mencionados previamente, con el

objetivo de comparar los resultados del perfil de tensión a través de diagramas de cajas.

El presente trabajo de grado presenta los mismos escenarios de prueba, donde se comparan los resultados de optimización con las predicciones de las SVMs. Las tres primeras comparaciones se visualizan en las Figuras 5, 6 y 7. Los resultados de las simulaciones mediante el método de Monte Carlo se presentan en las Figuras 8, 9 y 10. Además, se muestra la precisión de las predicciones de las cuatro SVMs y el tiempo de ejecución necesario tanto para la optimización de las variables de control como para el entrenamiento de las máquinas de aprendizaje en las Tablas 10 y 11 respectivamente.

## 6. Resultados obtenidos

En este capítulo se muestra los resultados de la variación de los datos de entrenamiento, los resultados de los experimentos propuestos por el artículo y los resultados de los escenarios planteados en (Cristancho Castro, 2023).

### 6.1. Resultados de la variación de los datos de entrenamiento

**Tabla 5**

*Resultados para diferentes variaciones en la potencia base.*

Variación	Método	Reducción de Pérdidas (%)	Casos de sobretensión	Casos de subtensión	Máxima desviación de tensión (%)
± 40 %	Optimización	37,42	0	0	-4,97
	SVM	38,04	7	25	-5,36
20 %	Optimización	29,89	0	0	-4,99
	SVM	29,89	0	5	-5,03
20 % con datos adicionales	Optimización	29,75	0	0	-5,00
	SVM	29,75	0	2	-5,01

En la Tabla 5 se presentan los resultados de los cuatro parámetros evaluados, comparando la optimización con los modelos entrenados de SVM en los tres escenarios de variación descritos en la Sección 5.4. Es importante destacar que el tercer modelo de SVM se utiliza para continuar

**Tabla 6**

*Precisión de las SVM de las tres variantes de datos generados.*

Variación	Precisión
± 40 %	34,44 %
20 %	90 %
20 % con datos adicionales	98,61 %

con la experimentación detallada en la Sección 5.5. Adicionalmente, en la Tabla 6 se detalla la precisión obtenida por cada modelo de SVM frente a las diferentes variaciones en la generación de datos.

## 6.2. Resultados de los experimentos del artículo seleccionado

**Tabla 7**

*Resultados para diferentes condiciones de prueba.*

Condición	Método	Reducción de Pérdidas (%)	Casos de sobretensión	Casos de subtensión	Máxima desviación de tensión (%)
<b>Con 8 barras</b>	Optimización	29,75	0	0	-5,00
	SVM	29,75	0	8	-5,02
<b>Con ruido blanco gaussiano</b>	Optimización	29,68	0	0	-5,00
	SVM	29,68	0	3	-5,01
<b>Con capacitor fijo</b>	Optimización	29,05	0	0	-5,00
	SVM	29,00	0	0	-4,72

En la Tabla 7 se presentan los resultados de los cuatro parámetros de evaluación del sistema, donde se comparan el rendimiento del algoritmo de optimización y el del tercer modelo de SVM descrito en la Sección 5.4. Por otro lado, en la Tabla 8, se detalla la precisión de la predicción de la SVM seleccionada frente a las tres condiciones de prueba planteadas.

**Tabla 8**

*Precisión de la predicción de la SVM ante diferentes condiciones de prueba en el sistema de distribución.*


Condición	Precisión
Con 8 barras	97,22 %
Con ruido blanco gaussiano	98,05 %
Con capacitor fijo	35,27 %

### 6.3. Resultados de los escenarios planteados por Cristancho Castro (2023)

#### 6.3.1. Resultados del caso base

**Figura 5**

*Potencia aparente en cabecera.*

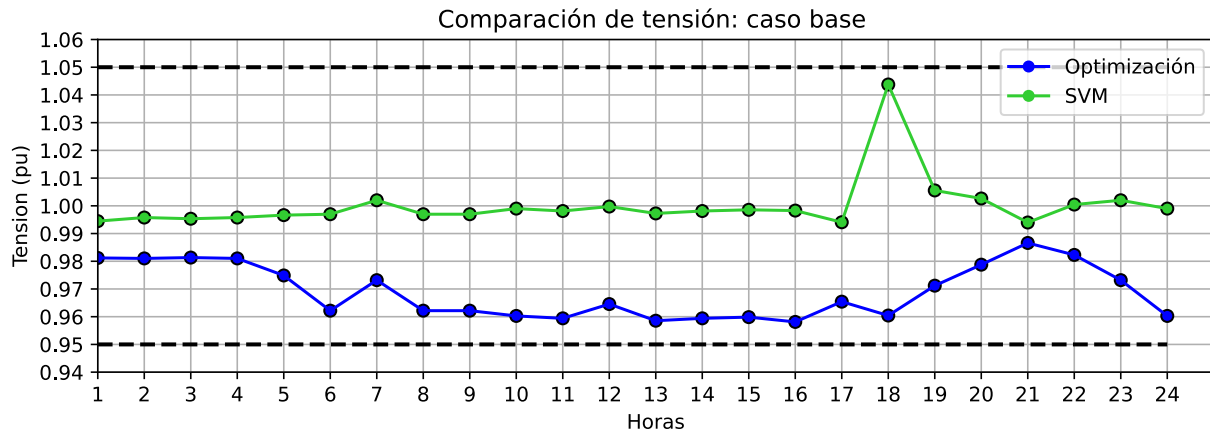


En la Figura 5 se muestran los resultados de la potencia aparente en la cabecera del sistema en el caso base, donde el algoritmo de optimización DCD no requiere la generación de datos. Por el contrario la SVM *sí* necesita de unos datos entrenamiento ( $\mathcal{D}$ ). Por esta razón, se utiliza el modelo SVM entrenado con un coeficiente de variación del 10 %, como se describe en la Sección 5.6., utilizando como descriptores de prueba los datos del caso base sin control.

En la Figura 6 se presentan los resultados de la tensión en p.u. del caso base, obtenidos mediante el algoritmo de optimización DCD, junto con la predicción proporcionada por la SVM


**Figura 6**

*Comparación entre la optimización y las predicciones de la SVM en el perfil de tensión en la barra 2.*



**Figura 7**

*Factor de potencia en la barra de alimentación.*



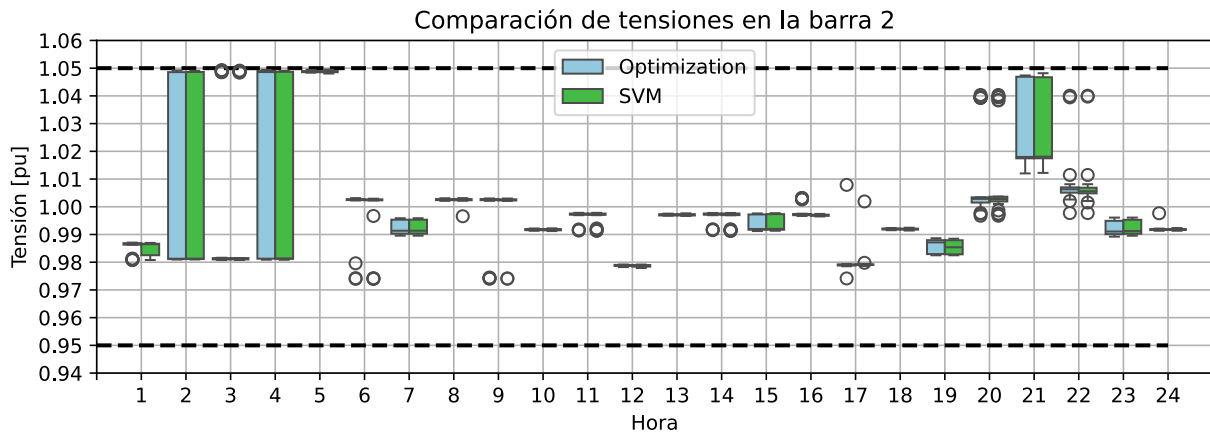
utilizando los datos del caso base sin control.

La Figura 7 muestra los resultados del factor de potencia en la cabecera del sistema, obtenidos mediante el algoritmo de optimización DCD y la predicción de la SVM utilizando los datos del caso base sin control.

6.3.2. Resultados de las simulaciones por el método de Montecarlo


**Figura 8**

*Coefficiente de variación del 10 %.*



**Figura 9**

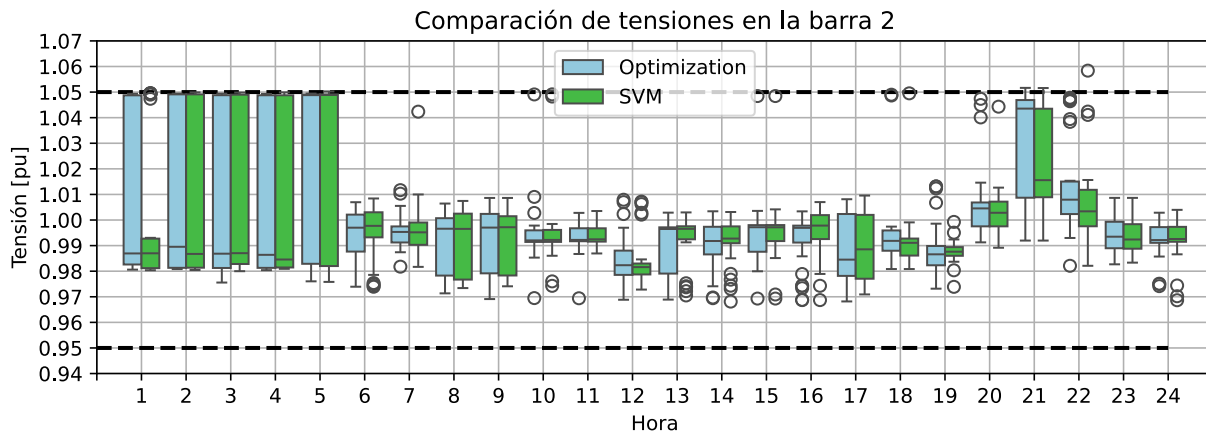
*Coefficiente de variación del 30 %.*



En las Figuras 8, 9 y 10 presentan, a través de diagramas de caja, los resultados de la tensión en p.u. en la barra dos del sistema de distribución para los coeficientes de variación del 10 %, 30 % y 60 %, respectivamente.

**Figura 10**

*Coefficiente de variación del 60 %.*

**Tabla 9**

*Resultados con diferentes coeficientes de variación.*

Coefficiente de variación	Método	Reducción de Pérdidas (%)	Casos de sobretensión	Casos de subtensión	Máxima desviación de tensión (%)
Weibull 10 %	Optimización	41,9	1	0	-5,00
	SVM	41,48	2	16	-5,11
Weibull 30 %	Optimización	39,96	0	0	-5,00
	SVM	39,95	6	26	-5,14
Weibull 60 %	Optimización	69,41	6	4	5,16
	SVM	69,86	37	229	-6,32

Las Tablas 9, 10 y 11 presentan resultados clave de la experimentación. La Tabla 9 muestra los cuatro parámetros evaluados ante diferentes coeficientes de variación en la generación de datos, comparando los resultados obtenidos a través del algoritmo de optimización con las predicciones de los modelos entrenados de SVM. La Tabla 10 detalla la precisión de las predicciones de los cuatro SVM en función de los coeficientes de variación utilizados. Finalmente, la Tabla 11 muestra el tiempo de ejecución requerido para encontrar las variables óptimas mediante el algoritmo de optimización DCD y para el entrenamiento de la máquina de aprendizaje.

**Tabla 10**

*Precisión de las cuatro SVM entrenadas.*

<b>Coefficiente de variación</b>	<b>SVM 1</b>	<b>SVM 2</b>	<b>SVM 3</b>	<b>SVM 4</b>
Weibull 10 %	82,22 %	76,11 %	70,55 %	83,22 %
Weibull 30 %	62,77 %	51,11 %	34,44 %	62,77 %
Weibull 60 %	35 %	26,66 %	19,44 %	41,66 %

**Tabla 11**

*Tiempos de ejecución con diferentes coeficientes de variación.*

	Weibull 10 %	Weibull 30 %	Weibull 60 %
Optimización	00:45:10	01:40:02	01:26:34
SVM	00:02:26	00:03:18	00:03:42

## 7. Conclusiones

La revisión de la literatura ha proporcionado una comprensión detallada sobre el uso de máquinas de aprendizaje en el control tensión-reactiva en sistemas de distribución. Este análisis ha permitido obtener una visión general de las metodologías empleadas, destacando el potencial de estas técnicas para determinar las variables de control óptimas para el control tensión-reactiva. En particular, las máquinas de soporte vectorial (SVM) fueron seleccionadas y modeladas siguiendo las directrices del artículo seleccionado, mientras que el algoritmo de optimización por descenso de coordenadas discretas (DCD), descrito por Cristancho Castro (2023), ha demostrado ser efectivo en mantener los niveles de tensión dentro de los límites permitidos, mejorar el factor de potencia y reducir las pérdidas de potencia.

Los resultados de las simulaciones muestran que el algoritmo DCD no presenta infracciones por sobretensión o subtensión en la mayoría de los escenarios, logrando, además, una reducción superior al 25 % en las pérdidas de potencia en comparación con casos sin control, según las pruebas basadas en el artículo seleccionado. Sin embargo, un inconveniente significativo es su tiempo de

ejecución, que *puede tardar*\* más de una hora en encontrar las variables de control, especialmente cuando aumenta la cantidad de datos de simulación.

En este contexto, el uso de las SVM tiene como objetivo mantener o mejorar la eficiencia que brinda el algoritmo de optimización, pero con tiempos de ejecución considerablemente más reducidos. Sin embargo, se observó que la precisión de la SVM se ve afectada por la aleatoriedad de los datos; en condiciones iniciales los casos de mayor variación, la precisión disminuyó hasta un 34,4 %, lo que resultó en 32 infracciones en los límites de tensión (Tabla 5). Por otro lado, al reducir la variabilidad de los datos y aumentar su cantidad, la precisión de la SVM mejoró hasta un 98,6 %, reduciendo el número de infracciones a 2. Esto indica que tanto la variabilidad como la cantidad de datos utilizados en el entrenamiento son factores cruciales en este proceso.

En los escenarios de prueba basados en el artículo seleccionado (Tablas 7 y 8), se observa que, cuando se dispone de una cantidad reducida de equipos de medida, la precisión puede alcanzar el 97,2 % con 8 infracciones de tensión (6 infracciones adicionales en comparación con el caso inicial). Este resultado es viable si se realiza el entrenamiento de la SVM con una mayor cantidad de datos. En presencia de una señal de ruido de 40 dB, el impacto en los resultados es mínimo, presentando 3 casos de infracción en la tensión (1 infracción adicional en comparación con el caso inicial). En el evento de incorporar un capacitor fijo al sistema, se observa una disminución significativa en la precisión de la máquina, que baja al 35,3 %. Sin embargo, al implementar el control basado en las predicciones, los resultados mejoran incluso en comparación con el algoritmo de optimización. Una hipótesis para este fenómeno es que los bancos de capacitores forman parte de las variables de control. Al introducir una nueva variable, los resultados obtenidos a través de la simulación con OpenDSS (utilizando la librería de Python) afectan el perfil de tensión. Esto, a su vez, influye en la precisión de la SVM y ajusta el perfil de tensión dentro de los límites permitidos.

Finalmente, el análisis de distintos coeficientes de variación muestra una tendencia clara: a medida que aumenta el coeficiente, la precisión de las predicciones disminuye (ver Tabla 9), lo que incrementa las infracciones de tensión (ver Tabla 10). Esto resalta la necesidad de llevar a cabo

---

\* Los tiempos son de referencia y están directamente relacionados con el hardware utilizado.

un estudio adicional para determinar la variabilidad presente en el sistema de distribución y así implementar medidas que maximicen la precisión de las SVM.

El análisis revela una diferencia notable en los tiempos de ejecución entre el algoritmo de optimización y el entrenamiento de la SVM (como se muestra en la Tabla 11). Mientras que el proceso de optimización requiere un tiempo considerablemente mayor, la SVM puede completar sus predicciones en menos de 15 segundos. Es importante destacar que, aunque el algoritmo de optimización demanda más tiempo, este paso es necesario solo una vez para determinar las clases de entrenamiento. Una vez que la máquina ha sido entrenada, su capacidad para generar resultados rápidamente se vuelve evidente. Esta eficiencia en el tiempo de respuesta es particularmente valiosa en situaciones que requieren decisiones inmediatas o en contextos de emergencia.

**Referencias Bibliográficas**

- Baran, M., & Wu, F. (1989). Network Reconfiguration in Distribution Systems for Loss Reduction and Load Balancing. *IEEE Transactions on Power Delivery*, 4(2), 1401-1407. <https://doi.org/10.1109/61.25627>
- Biserica, M., Besanger, Y., Caire, R., Chilard, O., & Deschamps, P. (2012). Neural Networks to Improve Distribution State Estimation—Volt Var Control Performances. *IEEE Transactions on Smart Grid*, 3(3), 1137-1144. <https://doi.org/10.1109/TSG.2012.2193673>
- Cristancho Castro, C. A. (2023, noviembre). Estrategia de control tensión-reactiva en sistemas de distribución a partir de bancos de condensadores y cambia tomas en transformadores [Universidad Industrial de Santander].
- Fan, T.-H., Lee, X. Y., & Wang, Y. (2022, marzo). PowerGym: A Reinforcement Learning Environment for Volt-Var Control in Power Distribution Systems. <https://doi.org/10.48550/arXiv.2109.03970>
- Foundation, P. S. (2024). Full Grammar specification [Accedido: 14-Sep-2024]. <https://docs.python.org/3/reference/grammar.html>
- Gao, Y., Wang, W., & Yu, N. (2021). Consensus Multi-Agent Reinforcement Learning for Volt-Var Control in Power Distribution Networks. *IEEE Transactions on Smart Grid*, 12(4), 3594-3604. <https://doi.org/10.1109/TSG.2021.3058996>
- Gao, Y., & Yu, N. (2022). Model-augmented safe reinforcement learning for Volt-Var control in power distribution networks. *Applied Energy*, 313, 118762. <https://doi.org/https://doi.org/10.1016/j.apenergy.2022.118762>
- Jabr, R. A., & Džafić, I. (2016). Sensitivity-Based Discrete Coordinate-Descent for Volt/Var Control in Distribution Networks. *IEEE Transactions on Power Systems*, 31(6), 4670-4678. <https://doi.org/10.1109/TPWRS.2015.2512103>
- Khodr, H., Olsina, F., Jesus, P. D. O.-D., & Yusta, J. (2008). Maximum savings approach for location and sizing of capacitors in distribution systems. *Electric Power Systems Research*, 78(7), 1192-1203. <https://doi.org/https://doi.org/10.1016/j.epsr.2007.10.002>

- Liu, Q., Guo, Y., Deng, L., Tang, W., Sun, H., & Huang, W. (2021). Robust Offline Deep Reinforcement Learning for Volt-Var Control in Active Distribution Networks. *2021 IEEE 5th Conference on Energy Internet and Energy System Integration (EI2)*, 442-448. <https://doi.org/10.1109/EI252483.2021.9712941>
- Manbachi, M., Farhangi, H., Palizban, A., & Arzanpour, S. (2014). Predictive algorithm for Volt/VAR optimization of distribution networks using Neural Networks. *2014 IEEE 27th Canadian Conference on Electrical and Computer Engineering (CCECE)*, 1-7. <https://doi.org/10.1109/CCECE.2014.6901014>
- Meira, P. (2023). Dss Extensions [(Recuperado el 14 de septiembre de 2024)]. [https://dss-extensions.org/dss\\_properties.html](https://dss-extensions.org/dss_properties.html)
- Oluchi Anyanwu, G., Nwakanma, C. I., Lee, J.-M., & Kim, D.-S. (2023). Optimization of RBF-SVM Kernel Using Grid Search Algorithm for DDoS Attack Detection in SDN-Based VANET. *IEEE Internet of Things Journal*, 10(10), 8477-8490. <https://doi.org/10.1109/JIOT.2022.3199712>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
- Pourjafari, E., & Reformat, M. (2019). A Support Vector Regression Based Model Predictive Control for Volt-Var Optimization of Distribution Systems. *IEEE Access*, 7, 93352-93363. <https://doi.org/10.1109/ACCESS.2019.2928173>
- Rodríguez, Á. A., Sánchez, F. A. P., Roa, A. M. O., & Jiménez, G. L. C. (2021, octubre). *NTG-02 MARCO GENERAL NORMA URBANA* [Grupo Homologación y Normalización CET]. ESSA. Consultado el 4 de septiembre de 2024, desde <https://www.essa.com.co/site/Portals/proveedores/ntg-02%20marco%20general%20norma%20urbana.pdf?ver=2023-12-14-174803-547#:~:text=La%20presente%20norma%20se%20fundamenta%20en%20algunos%20casos%20en%20la>

- Salles, D., Pinto, A. C., & Freitas, W. (2016). Integrated volt/Var control in modern distribution power systems based on support vector machines. *International Transactions on Electrical Energy Systems*, 26(10), 2216-2229. <https://doi.org/10.1002/etep.2200>
- Swarup, K., & Subash, P. (2005). Neural Network Approach to Voltage and Reactive Power Control in Power Systems. *Proceedings of 2005 International Conference on Intelligent Sensing and Information Processing, 2005.*, 228-233. <https://doi.org/10.1109/ICISIP.2005.1529453>
- Syarif, I., Prugel-Bennett, A., & Wills, G. (2016). SVM Parameter Optimization using Grid Search and Genetic Algorithm to Improve Classification Performance. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, 14, 1502. <https://doi.org/10.12928/telkomnika.v14i4.3956>
- Wang, W., Yu, N., Shi, J., & Gao, Y. (2019). Volt-VAR Control in Power Distribution Systems with Deep Reinforcement Learning. *2019 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm)*, 1-7. <https://doi.org/10.1109/SmartGridComm.2019.8909741>
- Zhang, M., Xu, Q., Magnússon, S., Pilawa-Podgurski, R. C. N., & Guo, G. (2022). Multi-Agent Deep Reinforcement Learning for Decentralized Voltage-Var Control in Distribution Power System. *2022 IEEE Energy Conversion Congress and Exposition (ECCE)*, 1-5. <https://doi.org/10.1109/ECCE50734.2022.9947399>
- Zhang, S., Zhang, M., Hu, R., Lubkeman, D., Liu, Y., & Lu, N. (2022). Reinforcement Learning for Volt- Var Control: A Novel Two-stage Progressive Training Strategy. *2022 IEEE Power & Energy Society General Meeting (PESGM)*, 1-5. <https://doi.org/10.1109/PESGM48719.2022.9916659>
- Zhang, Y., Wang, X., Wang, J., & Zhang, Y. (2021). Deep Reinforcement Learning Based Volt-VAR Optimization in Smart Distribution Systems. *IEEE Transactions on Smart Grid*, 12(1), 361-371. <https://doi.org/10.1109/TSG.2020.3010130>