



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

**DEPARTAMENTO DE ELÉCTRICA Y
ELECTRÓNICA**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

**TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL
TÍTULO DE INGENIERO ELECTRÓNICO,
AUTOMATIZACIÓN Y CONTROL**

**TEMA: DISEÑO E IMPLEMENTACIÓN DE UN
CONTROLADOR DINÁMICO BASADO EN UN
CLASIFICADOR DE ESTADOS POR SVM PARA UN SISTEMA
BALASTRO-LÁMPARA HID-MH DE 250W.**

AUTOR: GUALAVISÍ LIMAICO, RICARDO SEBASTIÁN

DIRECTOR: Ing. AYALA TACO, JAIME PAÚL MSc.

**SANGOLQUÍ
2017**



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA
CARRERA DE INGENIERÍA EN AUTOMATIZACIÓN Y CONTROL

CERTIFICACIÓN

Certifico que el trabajo de titulación, ***“DISEÑO E IMPLEMENTACIÓN DE UN CONTROLADOR DINÁMICO BASADO EN UN CLASIFICADOR DE ESTADOS POR SVM PARA UN SISTEMA BALASTRO-LÁMPARA HID-MH DE 250W.”*** realizado por el señor ***GUALAVISÍ LIMAICO RICARDO SEBASTIÁN***, ha sido revisado en su totalidad y analizado por el software anti-plagio, el mismo cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, por lo tanto me permito acreditarlo y autorizar al Señor ***GUALAVISÍ LIMAICO RICARDO SEBASTIÁN*** para que lo sustente públicamente.

Enero de 2017

A blue ink handwritten signature, appearing to read 'Paúl Ayala', is written over a horizontal line.

Ing. Paúl Ayala
DIRECTOR



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA

CARRERA DE INGENIERÍA EN AUTOMATIZACIÓN Y CONTROL

AUTORÍA DE RESPONSABILIDAD

Yo, **GUALAVISÍ LIMAICO RICARDO SEBASTIÁN**, con cédula de identidad N° 172350532-5, declaro que este trabajo de titulación **“DISEÑO E IMPLEMENTACIÓN DE UN CONTROLADOR DINÁMICO BASADO EN UN CLASIFICADOR DE ESTADOS POR SVM PARA UN SISTEMA BALASTRO-LÁMPARA HID-MH DE 250W.”** ha sido desarrollado considerando los métodos de investigación existentes, así como también se ha respetado los derechos intelectuales de terceros considerándose en las citas bibliográficas.

Consecuentemente declaro que este trabajo es de mi autoría, en virtud de ello me declaro responsable del contenido, veracidad y alcance de la investigación mencionada.

Enero de 2017

Ricardo Sebastián Gualavisí
C.I. 172350532-5



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA

CARRERA DE INGENIERÍA EN AUTOMATIZACIÓN Y CONTROL

AUTORIZACIÓN

Yo, **GUALAVISÍ LIMAICO RICARDO SEBASTIÁN**, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar en la biblioteca Virtual de la institución el presente trabajo de titulación ***“DISEÑO E IMPLEMENTACIÓN DE UN CONTROLADOR DINÁMICO BASADO EN UN CLASIFICADOR DE ESTADOS POR SVM PARA UN SISTEMA BALASTRO-LÁMPARA HID-MH DE 250W.”***, cuyo contenido, ideas y criterios son de mi exclusiva autoría y responsabilidad.

Enero de 2017

Ricardo Sebastián Gualavisí
C.I. 172350532-5

DEDICATORIA

Este proyecto se lo dedico a mi familia, mis dos madres Laurita y Martha, a mis hermanos, Mario y Fátima, que han sido mi mayor motivación para poder salir adelante, ayudándome de forma incondicional en todas las formas que han podido.

Por todos ellos espero que este primer logro retribuya de alguna manera a su inmensa colaboración.

Ricardo Gualavisí L.

AGRADECIMIENTO

Me harían falta muchas páginas para nombrar una a una a todas las personas con las que estaré siempre agradecido, pues este logro es una realidad debido al arduo trabajo en conjunto de muchas de ellas, sin embargo quiero expresar mi gratitud en primer lugar a mi familia que ha sido, es y seguirá siendo el principal motivo para mejorar como profesional y más importante aún como persona.

A todos mis amigos que gracias a la vida son muchos y por largo son los mejores, sin ustedes llegar hasta aquí no sería lo mismo, gracias por su amistad incondicional y compartir los mejores momentos de mi vida; también quiero expresar mi gratitud a la Universidad de las Fuerzas Armadas - ESPE, a su espectacular cuerpo docente por haberme dado la oportunidad de aprender y mejorar día tras día, de forma especial doy las gracias a mis tutores Ingeniero Paúl Ayala y Vinicio Carrera por guiarme en esta etapa final de mi carrera.

Ricardo Gualavisí L.

RESUMEN

Las máquinas de vector soporte (SVM) son modelos de aprendizaje supervisados con algoritmos de aprendizaje asociados que analizan datos que se utilizan para su clasificación o análisis de regresión. En los últimos años, se han realizado importantes investigaciones para abordar los retos técnicos relacionados con el funcionamiento y el control de los sistemas electrónicos balastro-lámparas HID-MH. Este proyecto da una visión general del diseño y la implementación de un controlador dinámico que basa su operación en un clasificador multivariable (SVC). Este clasificador realiza la tarea de identificar las diferentes fases de ignición de cuatro lámparas HID de 250W. También se analiza el comportamiento de cuatro variables presentes en el proceso de encendido de las lámparas, estas variables son: tensión, intensidad de corriente, temperatura e iluminancia. El resultado de este análisis determina qué variables son óptimas para implementar el clasificador.

PALABRAS CLAVE:

- **MÁQUINAS DE VECTOR SOPORTE.**
- **CLASIFICADOR DE FASES MULTIVARIABLE.**
- **FASES DE ENCENDIDO.**

ABSTRACT

Support vector machines (SVM) are supervised learning models with associated learning algorithms that analyze data used for classification and regression analysis. Over the past few years, significant research has been done to address the technical challenges associated with the operation and control of the HID-MH ballast-lamp electronic systems. This project gives an overview of the design and implementation of a dynamic controller which bases its operation on a multivariable support vector classifier (SVC). This classifier performs the task of identifying the different ignition stages of four 250 W HID lamps. It is also analyzed the behavior of four variables that are present in the ignition process of the lamps, these variables are: voltage, current intensity, temperature and illuminance. The result of this analysis determines which variables are optimal for implementing the classifier.

KEYWORDS:

- **SUPPORT VECTOR MACHINES**
- **MULTIVARIABLE CLASSIFIER**
- **IGNITION STAGES.**

Índice general

Certificado	ii
Autoría de responsabilidad	iii
Autorización	iv
Dedicatoria	v
Agradecimientos	vi
Resumen	vii
Índice de figuras	xii
Índice de tablas	xv
1. Introducción	1
1.1. Antecedentes	1
1.2. Justificación e importancia	1
1.3. Objetivos	2
1.3.1. General	2
1.3.2. Específicos	2
1.4. Alcance	2
2. Estudio teórico	4
2.1. Lámparas de alta intensidad de descarga (HID-MH)	4
2.2. Lámparas de halogenuros metálicos	4
2.2.1. Componentes de las lámparas HID-MH	5
2.3. Fases de encendido de lámparas HID-MH.	6
2.3.1. Fase de ignición	6
2.3.2. Fase de calentamiento	6
2.3.3. Fase de estabilización	7

2.4.	Balastro	7
2.4.1.	Balastro electromagnético	7
2.4.2.	Balastro electrónico	8
2.5.	Máquinas de vector soporte (SVM)	9
2.5.1.	Aprendizaje supervisado	10
2.5.2.	Problemas de clasificación	10
2.5.2.1.	SVM's para clasificación binaria de datos cuasi se- parables linealmente	13
2.5.2.2.	SVM's para datos no separables linealmente	14
2.5.3.	Clasificación múltiple	15
2.5.3.1.	SVM's biclasificadores generalizados	16
2.5.3.2.	SVM's multi-clasificadores	17
2.5.4.	Regresión basada en SVM's	18
3.	Diseño e implementación del controlador	21
3.1.	Adquisición de datos	21
3.1.1.	Adquisición de tensión y corriente	23
3.1.2.	Adquisición de iluminancia	23
3.1.3.	Adquisición de temperatura de la bombilla	24
3.2.	Controlador dinámico	24
3.2.1.	SVC	25
3.2.1.1.	Implementación del SVC	25
3.2.2.	Compensador neuronal	29
3.2.3.	Acción de control del identificador Neuronal (ACIN)	29
4.	Pruebas y resultados	30
4.1.	Análisis de los datos	30
4.1.1.	Análisis en tiempo	30
4.1.2.	Análisis tensión-corriente	33
4.1.3.	Análisis tensión-iluminancia y corriente-iluminancia	35
4.1.4.	Análisis tensión-temperatura y corriente-temperatura	39
4.1.5.	Análisis iluminancia-temperatura	42
4.1.6.	Comparación de variables	44
4.2.	Resultados del SVC	45
4.2.1.	SVC con cuatro variables de entrada	49
4.2.2.	Máquina de estados	50
4.2.3.	Comparativa de clasificadores	51

5. Conclusiones y trabajos futuros	53
5.1. Conclusiones	53
5.2. Recomendaciones y trabajos futuros	54
Bibliografía	55
Referencias	55

Índice de figuras

1.	Componentes físicos de las lámparas HID-MH.	5
2.	Umbral de decisión de etapas de encendido de lámparas HID-MH. .	7
3.	Balastro electromagnético a) Bobinas internas b) Presentación externa c) Diagrama eléctrico	8
4.	Esquema del balastro electrónico.	9
5.	Esquema de configuración de una máquina de aprendizaje a partir de ejemplos.	10
6.	Hiperplanos de separación en un espacio bidimensional de un conjunto de ejemplos separables en dos clases: a) Un hiperplano de separación b) Infinitos planos posibles.	11
7.	Margen de un hiperplano de separación: a) Hiperplano de separación no óptimo b) Hiperplano de separación óptimo	12
8.	Distancia de cualquier muestra x_i	13
9.	Muestras no separables	13
10.	Espacio de entradas y espacio de características	15
11.	Clasificación one vs rest de cuatro clases	17
12.	Clasificación one vs one de cuatro clases	17
13.	Regresión lineal con banda de epsilon intensivo	18
14.	Regresión no lineal con banda de epsilon intensivo	19
15.	Banda epsilon detallada con muestras	19
16.	Esquema adquisición de datos.	22
17.	Dimensiones del área de incidencia de luz.	23
18.	Esquema controlador dinámico	25
19.	Esquema del entrenamiento del modelo	26
20.	Esquema de la implementación del predictor en hardware	26
21.	Esquema de la implementación del SVC en Simulink	28
22.	Datos lámpara 1 Sylvania. a) Datos de tensión b) Datos de corriente c) Datos de Iluminancia d) Datos de temperatura	31

23.	Datos lámpara 2 Sylvania. a) Datos de tensión b) Datos de corriente c) Datos de Iluminancia d) Datos de temperatura	31
24.	Datos lámpara 3 Sylvania. a) Datos de tensión b) Datos de corriente c) Datos de Iluminancia d) Datos de temperatura	32
25.	Datos lámpara 4 Osram. a) Datos de tensión b) Datos de corriente c) Datos de Iluminancia d) Datos de temperatura	32
26.	Fases de encendido lámpara 1 tensión en función de corriente	33
27.	Fases de encendido lámpara 2 tensión en función de corriente	34
28.	Fases de encendido lámpara 3 tensión en función de corriente	34
29.	Fases de encendido lámpara 4 tensión en función de corriente	35
30.	Relación de desempeño de las lámparas HID-MH. a) Lámpara 1 a) Lámpara 2 a) Lámpara 3 a) Lámpara 4	37
31.	Fases de encendido lámpara 1 en función de a) tensión en función de iluminancia b) corriente en función de iluminancia	38
32.	Fases de encendido lámpara 2 a) Tensión en función de iluminancia b) Corriente en función de iluminancia	38
33.	Fases de encendido lámpara 3 a) Tensión en función de iluminancia b) Corriente en función de iluminancia	39
34.	Fases de encendido lámpara 4 en función de tensión a) Tensión e iluminancia b) Corriente e iluminancia	39
35.	Fases de encendido lámpara 1 en función de a) Tensión y temperatura b) Corriente y temperatura	40
36.	Fases de encendido lámpara 2 en función de a) Tensión y temperatura b) Corriente y temperatura	40
37.	Fases de encendido lámpara 3 en función de a) Tensión y temperatura b) Corriente y temperatura	41
38.	Fases de encendido lámpara 4 en función de a) Tensión y temperatura b) Corriente y temperatura	41
39.	Fases de encendido lámpara 4 en función de a) tensión y temperatura b) corriente y temperatura	42
40.	Fases de encendido lámpara 4 en función de a) tensión y temperatura b) corriente y temperatura	43
41.	Fases de encendido lámpara 4 en función de a) tensión y temperatura b) corriente y temperatura	43
42.	Fases de encendido lámpara 4 en función de a) tensión y temperatura b) corriente y temperatura	44
43.	Regiones de clasificación sin SVR	45

44.	Modelo de regresión a) Datos fases de apagado e ignición b) Modelo SVR entrenado	46
45.	Interpolación datos de las fases de apagado e ignición	47
46.	Banco de datos final	48
47.	Regiones de clasificación final	49
48.	Lógica de la máquina de estados	51
49.	Esquema SVC-máquina de estados	51

Índice de tablas

1.	Parámetros para determinar los estados	27
2.	Características lámparas HID-MH según fabricante	30
3.	Valores máximos medidos de iluminancia y temperatura	33
4.	Valores máximos medidos de tensión y corriente	33
5.	Error relación flujo luminoso-potencia lámparas HID-MH	37
6.	Comparación de variables	45
7.	Precisión del SVC sin SVR de datos por fase	46
8.	Precisión del clasificador único con datos de cada lámpara	48
9.	Precisión del clasificador único con datos de cada lámpara	48
10.	Precisión del SVC con SVR de datos por fase	49
11.	Precisión del SVC con SVR de datos por fase para lámparas Sylvania	49
12.	Precisión del SVC de cuatro entradas por fase	50
13.	Precisión del SVC-SVR de dos variables con máquina de estados por fase	51
14.	Comparación de clasificadores para lámparas HID-MH	52

Capítulo 1

Introducción

1.1. Antecedentes

El grupo de lámparas de descarga de alta intensidad de haluros metálicos HID-MH por sus siglas en inglés, es con mucho, el grupo más importante de lámparas utilizadas en iluminación exterior e industrial, son muy apreciadas por su larga vida y alta eficacia. Los lámparas HID-MH son el método más rentable en iluminación de carreteras, áreas de estacionamiento, campos deportivos, señalización y edificios. Para asegurar que las lámparas HID-MH funcionen adecuadamente hay que mantener la corriente y tensión dentro de rangos determinados, para lo cual se debe implementar un balastro sea analógico o digital (Velasategui y Andino, 2015).

1.2. Justificación e importancia

Parte importante del presente proyecto se enfoca al mejoramiento cuantitativo de las tasas de precisión en la identificación de las fases de ignición de las lámparas HID-MH, altas tasas de precisión conllevan a que el controlador tenga las referencias adecuadas y así garantizar un adecuado proceso de encendido. Se conoce que las tasas de precisión obtenidas en los trabajos previamente desarrollados por (Velasategui y Andino, 2015) con un identificador neuronal y (Andino, 2015) con SVM's independientes, ambos superan la barrera del 86% de precisión, sin embargo, cada uno de ellos presenta importantes falencias que afectan al funcionamiento general del balastro, el diseño de (Velasategui y Andino, 2015) presenta una relativa baja tasa de precisión y el diseño de (Andino, 2015) aunque muestra tasas de precisión superiores a su análogo neuronal es proclive a que datos sean clasificados dentro de fases o estados "no definidos" que afectan a la correcta ejecución secuencial del proceso de encendido de las lámparas HID-MH. Debido a estos problemas es necesario que el clasificador a

diseñar presente una tasa de precisión alta y una estructura que permita minimizar los estados no definidos. Para este fin se decide analizar cuatro variables presentes en el funcionamiento de las lámparas HID-MH y de ellas determinar las adecuadas para que el clasificador se desempeñe de mejor manera.

1.3. Objetivos

1.3.1. General

Diseñar e implementar un controlador dinámico basado en un clasificador de estados SVM para el control de tensión y corriente de una lámpara HID-MH (mercurio de alta intensidad de descarga de halógenos metálicos) para una operación estable.

1.3.2. Específicos

- Adquirir datos de cuatro variables: tensión, corriente, temperatura e iluminancia, de las fases de encendido del sistema balastro-lámpara para su clasificación.
- Implementar un clasificador de los estados de encendido del sistema balastro-lámpara basado en SVM.
- Identificar el tipo de variable que permite una mejor clasificación de estados.
- Diseñar el controlador dinámico basado en el clasificador SVM de variables de mejor desempeño.

1.4. Alcance

La necesidad de mejorar el desempeño del clasificador de fases es primordial en el presente proyecto, por tal motivo se plantea el diseñar e implementar un controlador que tenga una acción de control dinámica basada en un SVC multivariable que identifique las fases de funcionamiento de una lámpara HID-MH con mejor precisión y rapidez, permitiendo así que el sistema adapte las condiciones de tensión y corriente adecuadas para una fase determinada. Se pretende además fortalecer la tasas de desempeño del nuevo clasificador al considerar los criterios de diseño por redes neuronales implementados en (Velastegui y Andino, 2015), y en (Andino, 2015) mediante SVM's independientes, esto con el objetivo de identificar las bondades y dificultades de cada uno de ellos.

Los estados de funcionamiento de la lámpara HID-MH se determinan mediante la clasificación de datos de tensión, corriente, temperatura e iluminancia de cuatro lámparas de diferentes fabricantes, para ello se considera el uso principalmente del hardware y software desarrollado en el proyecto de (Velasategui y Andino, 2015).

Capítulo 2

Estudio teórico

2.1. Lámparas de alta intensidad de descarga (HID-MH)

Son una fuente de luz electroluminiscente, es decir, la iluminación se produce por la acción de un campo eléctrico sobre un gas o material sólido (Howard, 2002). Las fases de encendido de estas lámparas necesitan de pulsos de alta tensión, mismos que cambian según el tipo de lámpara. Superada la fase inicial de encendido, el arco aumenta su conductividad debido al incremento iones y electrones libres producidos por el incremento de la temperatura y corriente eléctrica (Chicaiza y Barrionuevo, 2013).

Para cumplir con un adecuado proceso de encendido se utiliza un dispositivo limitador de corriente eléctrica conocido como balastro que puede ser electromagnético o electrónico. Las lámparas HID-MH se clasifican de acuerdo al tipo de metal contenido en el arco (O'Donell, Sandoval, y Paukste, 2002), estas son:

- Lámparas de vapor de mercurio
- Lámparas de halogenuros metálicos
- Lámparas de vapor de sodio

2.2. Lámparas de halogenuros metálicos

Estas lámparas contienen un tubo de descarga relleno de mercurio a alta presión y compuesto por una mezcla de gases de halogenuros metálicos tales como dysprosio (Dy), holmio (Ho) y tulio (Tm), los cuales permiten obtener rendimientos luminosos más elevados y mejores propiedades de reproducción cromática que las lámparas de mercurio, presentan además una alta eficiencia, excepcional rendimiento de color y

buen mantenimiento de lúmenes (Flores, 2007). El efecto que tiene esta mezcla de gases referente a la tensión de ignición, es que esta se eleva en un rango considerado de 1500 – 5000V, de manera similar la temperatura de funcionamiento aumenta lo que hace difícil el reencendido, de forma general se debe esperar de 15 a 20 minutos o elevar los pulsos de tensión a 35000 V (Velastegui y Andino, 2015).

2.2.1. Componentes de las lámparas HID-MH

Las lámparas HID-MH están conformadas básicamente por los siguientes elementos:

- Ampolla elipsoidal exterior
- Tubo de descarga
- Electrodo
- Casquillo

Como se muestra en la figura 1, la lámpara se constituye de una doble envoltura, conformada por la ampolla exterior y el tubo de descarga. La ampolla elipsoidal exterior tiene como función proteger de aire y temperaturas exteriores al tubo de descarga. El tubo de descarga contiene gases inertes y diferentes metales que actúan como elementos auxiliares en la fase inicial de encendido, los electrodos y el casquillo son los elementos en los que se tendrá una tensión adecuada para el correcto funcionamiento de la lámpara (O'Donnell y cols., 2002).

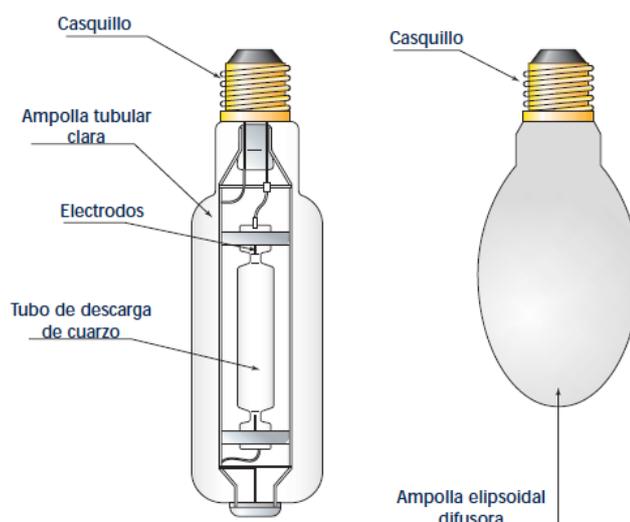


Figura 1: Componentes físicos de las lámparas HID-MH.

Fuente: (Flores, 2007)

2.3. Fases de encendido de lámparas HID-MH.

El funcionamiento de estas lámparas se basa en un arco de descarga o fenómeno electroluminiscente. Una descarga eléctrica entre dos electrodos, hacen que la condensación y mezcla de los gases empiece a emitir luz (Flores, 2007). Como consecuencia de la ionización del gas, se eleva la temperatura en el tubo de descarga, lo que da paso a la evaporación progresiva de los halogenuros metálicos. Después de varios minutos se produce la evaporación total de los elementos y se alcanza la estabilidad, en este punto la lámpara entregará los valores nominales de iluminación. El encendido de una lámpara HID-MH debe pasar por diferentes fases hasta alcanzar la estabilidad, estas fases son: ignición, calentamiento y estabilización (Gómez, 2004).

2.3.1. Fase de ignición

Esta fase se caracteriza por presentar una impedancia elevada en la lámpara y, además, requiere de una tensión elevada para romper el dieléctrico y hacer que la lámpara funcione. Al empezar la descarga, los electrones producen colisiones elásticas e inelásticas con los átomos del gas. Las colisiones elásticas son aquellas en las que los átomos que chocan desprenden un electrón y producen energía cinética que calientan su alrededor; pero por atracción del núcleo los electrones regresan a su órbita (Gómez, 2004). Las colisiones inelásticas son aquellas en las que los electrones se desprenden totalmente de su núcleo, generando un ion positivo y radiación electromagnética; esta etapa permite la circulación de la corriente eléctrica de descarga (Gómez, 2004).

Dentro de esta fase existe una etapa de transición de luminiscencia a arco, que se caracteriza por una tensión elevada entre los electrodos y la circulación de una pequeña corriente eléctrica en el arco de descarga, lo que ocasiona una aceleración en la ionización. La impedancia de la lámpara es alta y se puede ver una reducida emisión de luz (Gómez, 2004).

2.3.2. Fase de calentamiento

Dentro de la fase de calentamiento se distingue una etapa de transición al arco termoiónico en donde la aceleración de la ionización y el aumento de colisiones entre electrones y átomos provocan un gran incremento de la temperatura y reducción considerable de la impedancia, a lo que se conoce como fenómeno termoiónico. Esta etapa presenta una tensión reducida y elevada corriente. (Gómez, 2004).

2.3.3. Fase de estabilización

Debido al incremento de presión y temperatura en el interior del tubo de descarga se llega a establecer plenamente el arco termoiónico, que estabiliza la impedancia y que exige el valor nominal de potencia, para entregar así el valor nominal de iluminación (Gómez, 2004). Esta fase se caracteriza por presentar una impedancia estable y requerir una potencia fija. Las fases del encendido se describen en la figura 2.

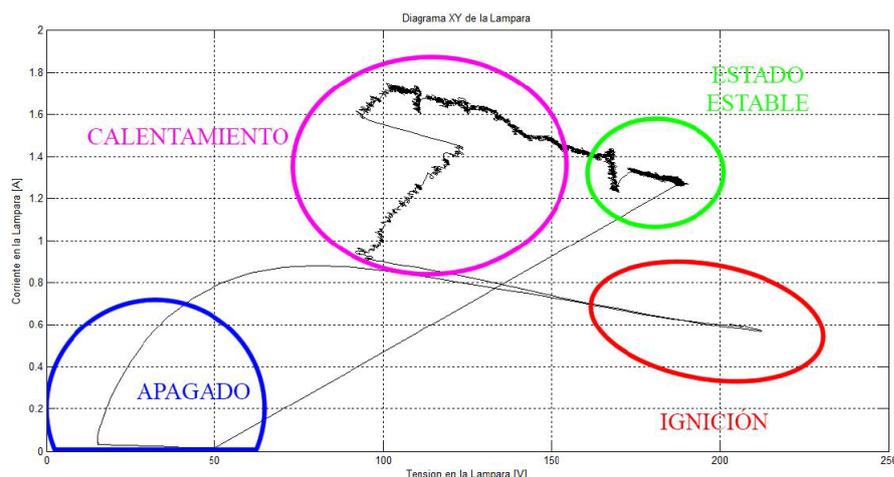


Figura 2: Umbrales de decisión de etapas de encendido de lámparas HID-MH.

Fuente: (Velastegui y Andino, 2015)

2.4. Balastro

Debido a que en cada una de las fases de encendido la impedancia cambia, las lámparas HID-MH no pueden ser conectadas directamente a la red eléctrica por tanto necesitan un dispositivo auxiliar para limitar la corriente eléctrica, este dispositivo es conocido como balastro (Olmedo, 2006). En la actualidad existen dos tipos de balastros: electromagnético y electrónico (G. García, 2008) y cumplen las funciones de:

- Limitar la corriente eléctrica en las etapas del encendido
- Estabilizar la corriente frente a variaciones en la alimentación

2.4.1. Balastro electromagnético

Como se observa en la figura 3 un balastro electromagnético de forma general consta de tres partes principales, un núcleo de láminas de acero rodeadas por dos bobinas de cobre que limita y estabiliza la corriente eléctrica, un arrancador que proporciona la tensión y finalmente un capacitor que mejora el factor de potencia. Estos

balastos presentan ventajas como: confiabilidad debido a su simple estructura y un bajo costo económico, sin embargo, presentan desventajas significativas como: gran tamaño y peso, factor de potencia no óptimo, bajo desempeño en eficiencia de potencia y sensibilidad a variaciones en tensión de línea (Regalado y Villacís, 2014).

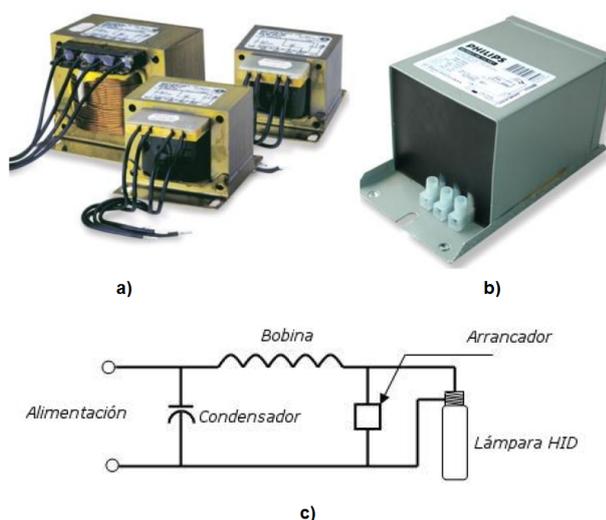


Figura 3: Balastro electromagnético a) Bobinas internas b) Presentación externa c) Diagrama eléctrico

Fuente: (C. García, 2011; Velastegui y Andino, 2015)

2.4.2. Balastro electrónico

El uso de estos balastos sin duda mejora la eficiencia de los sistemas de iluminación sobre todo en el campo del ahorro de energía. El uso de electrónica de potencia ocasiona un aumento en la distorsión armónica y un menor factor de potencia que debe ser corregido (Velastegui y Andino, 2015). Un mayor rendimiento de la lámpara se logra al trabajar con frecuencias altas (mayor a $20kHz$) ya que a mayor frecuencia incrementa el flujo luminoso, es así que al utilizar una frecuencia de $25kHz$ se consigue un aumento del 10% de flujo luminoso con respecto a los $60Hz$ (balastos electromagnéticos), sin embargo, a mayor frecuencia las pérdidas de conmutación se incrementan (G. García, 2008).

En la figura 4 se esquematiza un balastro electrónico que cuenta con un filtro interferencia electromagnética EMI por sus siglas en inglés, a la entrada que limita las interferencias electromagnéticas y la distorsión armónica; después se rectifica la señal para obtener una tensión continua. Al tener claro que en el encendido, la impedancia cambia en cada fase de encendido, es necesario el uso de un convertidor DC-DC para

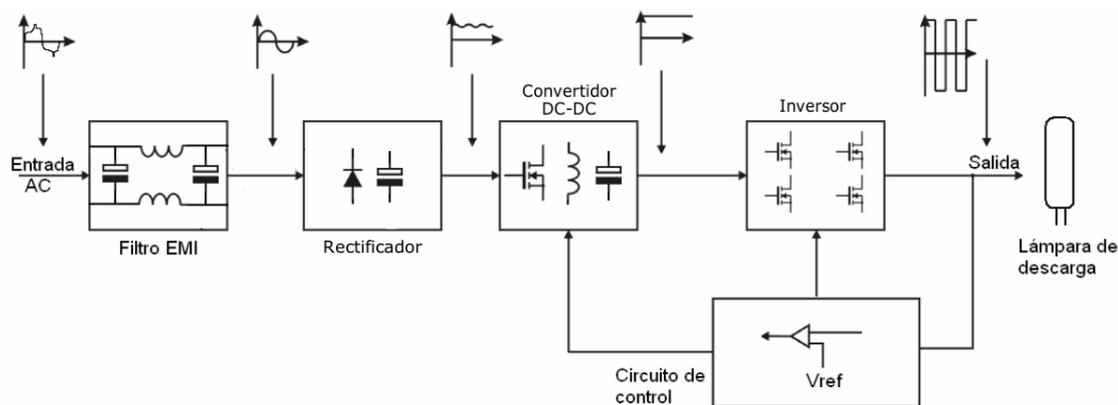


Figura 4: Esquema del balastro electrónico.

Fuente: (Velastegui y Andino, 2015)

adecuar la tensión y corriente. El inversor se encarga de elevar la frecuencia a valores adecuados. Para un óptimo funcionamiento de la lámpara, se adiciona una etapa de control que gestiona el convertidor y/o inversor.

2.5. Máquinas de vector soporte (SVM)

En los últimos años existen desarrollos muy significativos en el entendimiento teórico de máquinas de vector soporte (SVM's), de igual manera existen estrategias algorítmicas para implementarlas y solucionar problemas prácticos. La construcción de máquinas capaces de aprender en función de experiencias ha sido durante mucho tiempo el objeto de un debate filosófico como técnico. El aspecto técnico del debate ha recibido un enorme impulso con la llegada de computadoras electrónicas, mismas que han demostrado que las máquinas pueden mostrar un significativo nivel de habilidad de aprendizaje. La disponibilidad de sistemas de aprendizaje fiables tiene una importancia estratégica, debido a la existencia de muchas tareas que no pueden ser resueltas por técnicas de programación clásicas y por tanto no tienen ningún modelo matemático (Cristianini y Shawe-Taylor, 2000).

Las máquinas de vectores soporte se originan en los trabajos sobre la teoría del aprendizaje estadístico y fueron introducidas en los años 90 por Vapnik y sus colaboradores (Boser, Vapnik, y Guyon, 1992). Inicialmente las SVM's fueron direccionadas a resolver problemas de clasificación binaria, en la actualidad se usan para resolver otros problemas como: regresión, agrupamiento, multclasificación entre los más importantes. Los campos en los que han sido utilizadas con mayor éxito son visión artificial, reconocimiento de caracteres, categorización de texto, análisis de series temporales (Carmona, 2013).

2.5.1. Aprendizaje supervisado

Al considerar la perspectiva de un aprendizaje supervisado, es decir, el conocimiento de las salidas de un grupo o conjunto de entradas, es posible supervisar o cuantificar la bondad de los resultados del modelo en base a precisión en la clasificación. La base en la que se fundamenta el aprendizaje supervisado es aprender a partir de datos y para ello busca la existencia de alguna dependencia funcional entre un conjunto de vectores de entrada y vectores de salida (Gonzales, 2004). El modelo se representa por la figura 5, en la cual se recoge de manera clara el esquema que se pretende desarrollar.

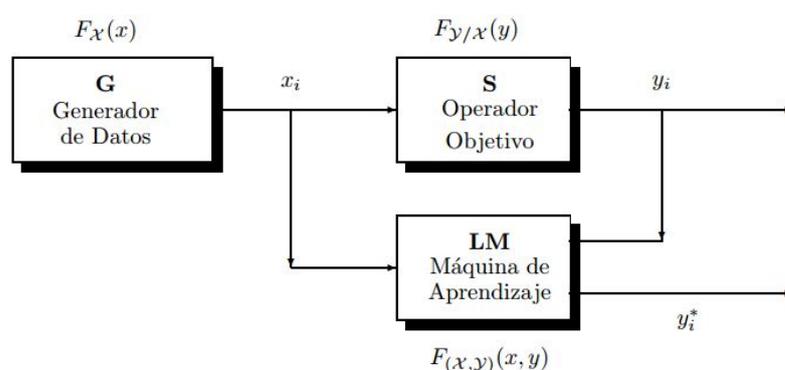


Figura 5: Esquema de configuración de una máquina de aprendizaje a partir de ejemplos.

Fuente: (Gonzales, 2004)

Donde el bloque G es un generador de datos que proporciona los vectores de entrada $x_i \in X$, independientes. Cada vector x_i es la entrada del operador del bloque S , que transforma x_i en un valor de salida y_i . Así la máquina de aprendizaje LM recoge el conjunto de entrenamiento conforme a,

$$Z = \{(x_1, y_1), \dots, (x_n, y_n)\} \quad (2.1)$$

A partir del conjunto de entrenamiento Z , la máquina de aprendizaje construye una aproximación al operador desconocido S (Gonzales, 2004).

2.5.2. Problemas de clasificación

Dado un conjunto separable $S = \{(x_1, y_1), \dots, (x_n, y_n)\}$, donde $x_i \in \mathbb{R}$ e $y \in \{+1, -1\}$, se puede definir un hiperplano de separación ilustrado en la figura 6a como una función lineal que es capaz de separar dicho conjunto con error mínimo (Carmona, 2013) :

$$D(x) = (w_1 x_1 + \dots + w_d x_d) + b = \langle w, x \rangle + b \quad (2.2)$$

Donde w y b , son coeficientes reales. El hiperplano de separación cumplirá las siguientes restricciones para todo x_i :

$$\langle w, x_i \rangle + b \geq 0 \quad \text{si } y_i = +1 \quad (2.3)$$

$$\langle w, x_i \rangle + b \leq 0 \quad \text{si } y_i = -1, i = 1, \dots, n \quad (2.4)$$

o de forma más compacta:

$$y_i D(x_i) \geq 0, i = 1, \dots, n \quad (2.5)$$

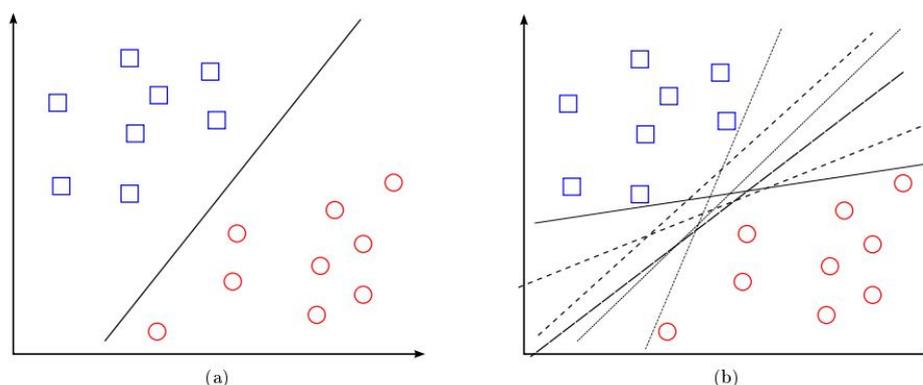


Figura 6: Hiperplanos de separación en un espacio bidimensional de un conjunto de ejemplos separables en dos clases: a) Un hiperplano de separación b) Infinitos planos posibles.

Fuente: (Carmona, 2013)

Como se indica en la figura 6b, el hiperplano que separa las muestras puede no ser único, es decir, existen un infinito número de hiper-planos posibles, surge entonces la necesidad de establecer un criterio adicional que permita definir un hiperplano de separación óptimo. Para ello, en primer lugar, se define el concepto de “margen” de un hiperplano de separación, denotado por τ , como la mínima distancia entre dicho hiperplano y la muestra más cercana de cualquiera de las dos clases como se observa en la figura 7a, por tanto, un hiperplano de separación es óptimo si su margen es de tamaño máximo como se observa en la figura 7b. Una propiedad de la definición de hiperplano óptimo es que debe equidistar de la muestra más cercana (Carmona, 2013).

Mediante geometría se sabe que la distancia entre un hiperplano de separación $D(x)$, y un ejemplo x' está dada por

$$\frac{|D(x')|}{\|w\|} \quad (2.6)$$

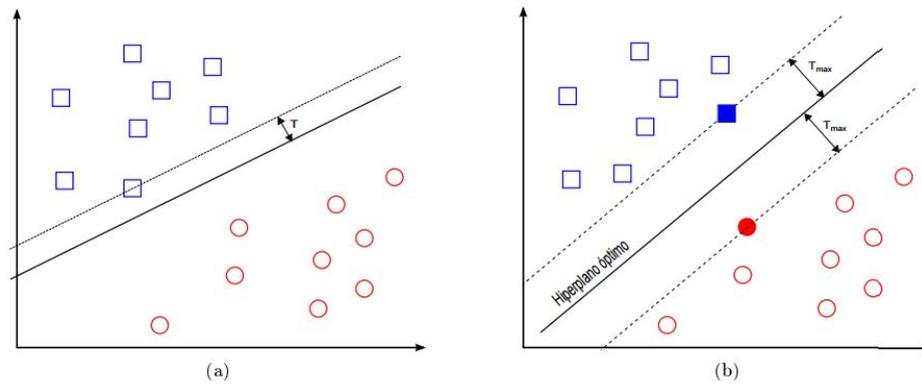


Figura 7: Margen de un hiperplano de separación: a) Hiperplano de separación no óptimo b) Hiperplano de separación óptimo .

Fuente: (Carmona, 2013)

donde w es el vector que, junto con b , define el hiperplano $D(x)$ y que además es perpendicular al hiperplano considerado. Al hacer uso de (2.5) y de (2.6) todas las muestras o datos de entrenamiento cumplirán que:

$$\frac{D(x_i)}{\|w\|} \geq \tau, i = 1, \dots, n \quad (2.7)$$

De la expresión anterior, se puede deducir que encontrar el hiperplano óptimo es equivalente a encontrar el valor de w que maximiza el margen. Para limitar el número de soluciones a una sola, se modifica (2.7) y se expresa como:

$$y_i D(x_i) \geq \tau \|w\|, i = 1, \dots, n \quad (2.8)$$

La escala del producto de τ y la norma de w se fija de forma arbitraria en la unidad es decir:

$$\tau \|w\| = 1 \quad (2.9)$$

se concluye que el aumentar el margen es equivalente a disminuir la norma de w , por lo que se expresa lo mencionado como:

$$\tau = \frac{1}{\|w\|} \quad (2.10)$$

Las muestras que se sitúan a ambos lados del hiperplano óptimo y que definen al margen reciben el nombre de vectores soporte, que matemáticamente están expresados como una igualdad en (2.11). Estas muestras (vectores soporte) son las más cercanas al hiperplano de separación óptimo, y por tanto, las más difíciles de clasificar (ver figura 8), debido a ello deben ser las únicas a considerar a la hora de construir dicho

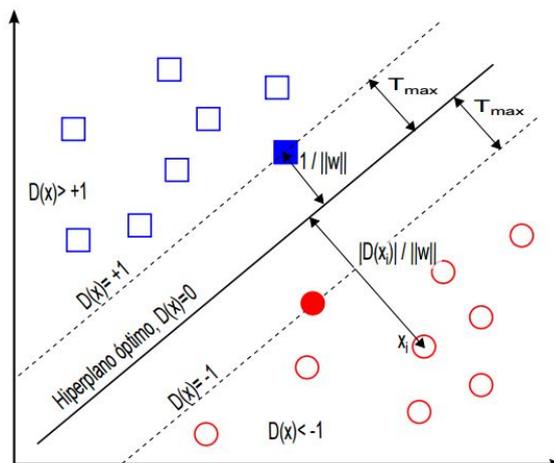


Figura 8: Distancia de cualquier muestra x_i .
Fuente: (Carmona, 2013)

hiperplano (Carmona, 2013).

$$y_i(\langle w, x_i \rangle + b) \geq 1 \quad i = 1, \dots, n \quad (2.11)$$

2.5.2.1. SVM's para clasificación binaria de datos cuasi separables linealmente

En la práctica no es común trabajar con conjuntos o muestras de datos separables, se observa en la figura 9, que muestras de una clase están dentro de la región correspondiente a las muestras de la otra clase, por lo que no podrán ser separados por medio de hiperplanos (Gonzales, 2004).

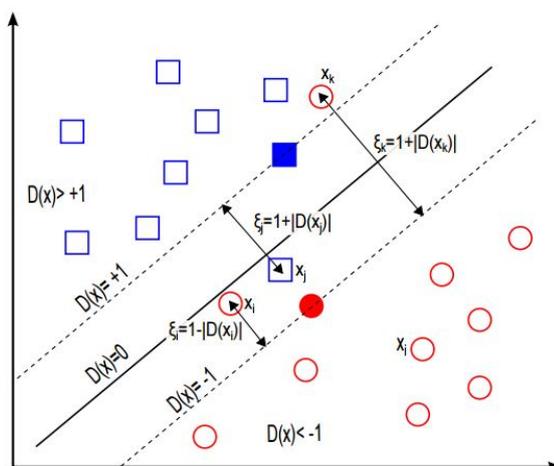


Figura 9: Muestras no separables
Fuente: (Carmona, 2013)

Desde el punto de vista matemático un ejemplo es no separable si no cumple con

(2.11), por lo que, para el presente propósito (separar sólo información relevante) se debe definir un conjunto de variables reales positivas llamadas “variables de holgura” ξ (Gonzales, 2004), mismas que permiten cuantificar el número de ejemplos no separables que se está dispuesto a admitir, es decir, relajar las restricciones, se define como:

$$y_i(\langle w, x_i \rangle + b) \geq 1 - \xi_i \quad \xi \geq 0, \quad i = 1, \dots, n \quad (2.12)$$

Por tanto, la función a ser optimizada debe incluir de alguna manera los errores de clasificación que comete el hiperplano, es decir:

$$f(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (2.13)$$

donde:

C es la constante que regula el grado de sobre ajuste y la proporción del número de ejemplos no separables. Valores de C grandes permitirían valores de ξ_i muy pequeños que disminuyen la cantidad de errores, por el contrario valores de C pequeños permite valores de ξ_i muy grandes que provocan una mayor receptividad de errores (Martinez, 2007).

w hace referencia al inverso del margen (Martinez, 2007).

En consecuencia, el nuevo problema de optimización consistirá en encontrar el hiperplano definido por w y b , que minimiza (2.13) sujeto a condiciones de (2.11). Al seguir el procedimiento matemático de (Carmona, 2013) detallado entre las páginas 10 a 25, finalmente se obtiene:

$$D(x) = \sum_{i=1}^n \alpha_i y_i \langle x_i, x \rangle + b \quad (2.14)$$

2.5.2.2. SVM's para datos no separables linealmente

En esta sección se aborda el problema de generalizar los desarrollos anteriores para el caso de clases de funciones no necesariamente lineales. Para este fin, se considera el procedimiento de (Aizerman, Braverman, y Rozonoér, 1964) en donde se define la función Φ , de entradas χ , en un espacio característico \mathcal{H} .

$$\Phi : \chi \subset \mathbb{R} \rightarrow \mathcal{H} \quad (2.15)$$

Ahora, en lugar de considerar $\{x_1, \dots, x_n\}$ como en 2.14, se consideran a los vectores transformados $\{\Phi(x_1), \dots, \Phi(x_n)\}$ que al ser plantearlos como un problema de optimización se obtiene la solución a través del producto escalar definido en

$\mathcal{H} \langle \Phi(x_i), \Phi(x) \rangle$ (Gonzales, 2004), así se considera una función:

$$k : \mathcal{H} \times \mathcal{H} \rightarrow \mathbb{R} \quad (2.16)$$

Por tanto, al hacer el reemplazo de $\langle x_i, x \rangle$ por $k(x_i, x)$ (función kernel) se habrá conseguido una máquina de vectores soporte definida en un nuevo espacio, que consumirá los mismos recursos computacionales que una técnica lineal (Martinez, 2007). Del breve análisis realizado se llega a la función solución que es:

$$D(x) = \sum_{i=1}^n \alpha_i k(x_i, x) + b \quad (2.17)$$

Donde (2.17) es la ecuación que permite evaluar si una muestra pertenece o no a una determinada clase. Las funciones núcleo o kernel más utilizados son (Carmona, 2013):

- Kernel lineal $K(x_i, x_j) = x_i^T x_j$
- Kernel polinómico $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
- Kernel Gaussiano o RBF $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$

Con esta nueva solución en un nuevo espacio de características las muestras podrán ser separables linealmente como se indica en la figura 10

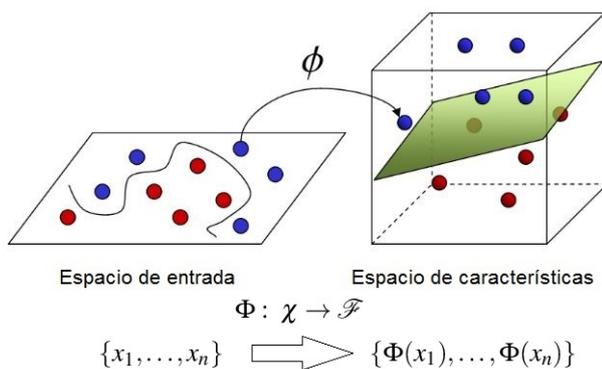


Figura 10: Espacio de entradas y espacio de características
Fuente: (Carmona, 2013)

2.5.3. Clasificación múltiple

Los SVC originalmente se diseñaron para problemas de clasificación binaria, debido a los buenos resultados presentados, han sido extendidas para resolver problemas

de clasificación con múltiples clases (mayor parte de los problemas reales). Al partir de la estructura dicotómica de los SVC, se han propuesto diferentes aproximaciones como la aproximación directa de (Weston y Watkins, 1998) en la que se propone una modificación de la función de optimización que tiene en cuenta todas las clases y se describe en (2.18).

$$f(w, \xi) = \min \frac{1}{2} \sum_{m=1}^n \|w\|^2 + C \sum_{i=1}^n \sum_{m \neq y_i} \xi_i^m \quad (2.18)$$

Donde es posible definir un vector de etiquetas $\{\theta_1, \dots, \theta_l\}$, con $n > 2$ y sin una relación de orden definida entre ellas (Martinez, 2007). Lo más habitual entre las técnicas para la aproximación a SVM multiclase se basan en la descomposición de los problemas multiclase en problemas de clasificación binaria (Zubiaga, 2008).

2.5.3.1. SVM's biclasificadores generalizados

Es una metodología que permite construir un modelo global a partir de un conjunto de funciones clasificadoras dicotómicas, que dan solución al problema de multiclasi-ficación al transformar las l particiones del conjunto de entrenamiento en un conjunto de L biparticiones, en las que se construye una función clasificadora para cada clase. Se obtienen f_1, \dots, f_L clasificadores dicotómicos, que mediante un esquema de recons-trucción se podrá proporcionar la salida final (Martinez, 2007). Dentro del esquema de descomposición, las máquinas más utilizadas son:

- Máquina one vs rest: El problema multiclase con k clases es descompuesto en otros problemas binarios, en los que cada clase se enfrenta al resto. Por lo que se construyen k clasificadores que definen hiperplanos que separan la clase i de los $k - 1$ restantes como ocurre en la figura 11.
- Máquina one vs one: se descompone el problema de k clases en $k(k - 1)/2$ problemas; donde se enfrentan todas las clases una a una, y donde se obtiene un hiperplano como muestra la figura 12 para cada uno de estos problemas (enfren-tamientos) binarios. A continuación se somete a cada par de la vector de prueba a todos estos clasificadores y se añade un voto a la clase ganadora para cada caso, la clase ganadora resulta del mayor número de votos obtenidos (Zubiaga, 2008).
- Máquina all vs all: existe una variante en base a las máquinas anteriores en la que se definen $(2^{n-1} - 1)$ clasificadores, correspondiente a todos los posibles enfrentamientos entre clases. Por ejemplo, para un problema de cuatro clases se

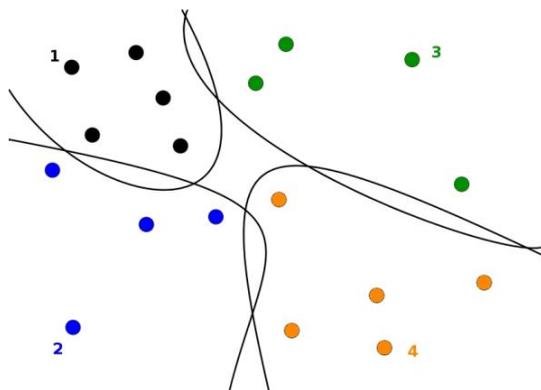


Figura 11: Clasificación one vs rest de cuatro clases
Fuente: (Zubiaga, 2008)

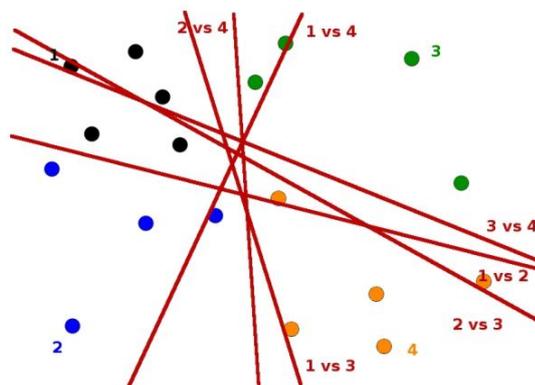


Figura 12: Clasificación one vs one de cuatro clases
Fuente: (Zubiaga, 2008)

generarían $1 vs (2, 3, 4)$, $(1, 2) vs (3, 4)$, $(1, 2, 3) vs 4$, $(1, 3) vs (2, 4)$, $(1, 4) vs (2, 3)$, $(1, 2, 4) vs 3$ y $(1, 3, 4) vs 2$. Cada vector de entrada se somete a cada uno de los clasificadores generados, para definir la clase que se asigna a cada vector de entrada, se prueban cuatro métodos de votación, los cuales se centran en las predicciones de todos los clasificadores y se eligen a aquellas clases que tengan mayor “puntuación”. La puntuación puede variar en función de estos criterios de votación mismos que son detallados en el trabajo de (Zubiaga, 2008).

2.5.3.2. SVM’s multi-clasificadores

Es una metodología que permite resolver un problema multiclase, en el que se construye un modelo global de forma directa; se consideran todas las clases a la vez. Esta metodología presenta el inconveniente de que la salida es obtenida mediante un modelo que es una caja negra, que no admite ninguna reconstrucción posterior

(Martinez, 2007).

2.5.4. Regresión basada en SVM's

Las máquinas de vector soporte pueden ser aplicadas no sólo para problemas de clasificación sino también para casos de regresión. La regresión está basada en la definición de una función de pérdida que ignora errores, los cuales están situados a cierta distancia del valor verdadero. Esta función es conocida como función de pérdida de epsilon intensivo. La figura 13 muestra un ejemplo de una función de regresión lineal con una banda de “epsilon intensivo” (banda de generalización). La función mide el costo del error para las muestras de entrenamiento; este valor es cero si las muestras están dentro de la banda delimitada por epsilon (Girma, 2009).

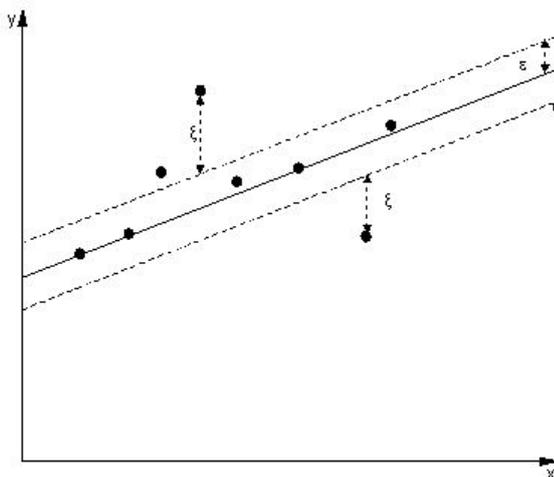


Figura 13: Regresión lineal con banda de epsilon intensivo
Fuente: (Girma, 2009)

La figura 14 muestra una situación similar pero en un caso de regresión no lineal.

Al utilizar la función de pérdida intensiva de epsilon, se garantiza la existencia del mínimo global y al mismo tiempo la optimización de un límite de generalización confiable como se observa en la figura 15.

En una SVR, la entrada x se asigna a un espacio de características m -dimensional que usa mapeo fijo (no lineal), y entonces un modelo lineal es construido en este espacio de características. Haciendo uso de notación matemática, el modelo lineal (en el espacio de características) está dado por (2.17).

La calidad de la estimación se mide por la función de pérdida $L(y, D(x))$. SVR usa un nuevo tipo de función de pérdida llamada función de pérdida sinsensible de ϵ propuesta por (Cortes y V, 1995):

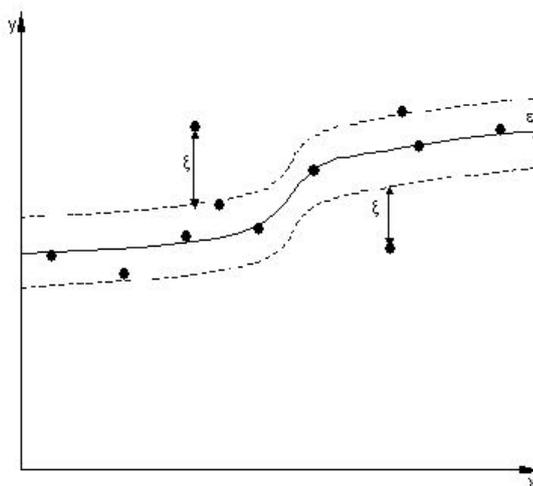


Figura 14: Regresión no lineal con banda de epsilon intensivo
Fuente: (Girma, 2009)

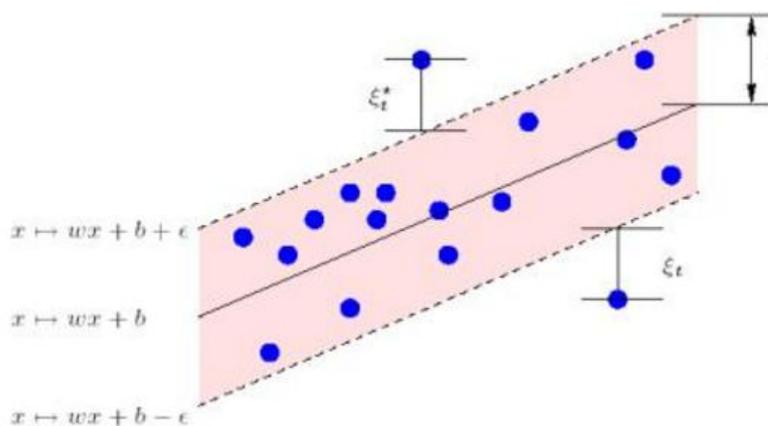


Figura 15: Banda epsilon detallada con muestras
Fuente: (Girma, 2009)

$$L(y, D(x)) = \begin{cases} 0 & \text{si } |y - D(x)| \leq \epsilon \\ |y - D(x)| - \epsilon & \text{otro} \end{cases} \quad (2.19)$$

La SVR realiza una regresión lineal en la dimensión de características más alta y garantiza también la existencia del mínimo global mediante la función de pérdida de ϵ . Sin embargo, la complejidad del modelo es aún alta por lo que se consideran los criterios expuestos por (Cortes y V, 1995) y de ello reducir la complejidad del modelo que da como resultado a (2.20):

$$\min \frac{1}{2} \|w\|^2 + C \sum_{m=1}^n (\xi_i + \xi_i^*) \quad (2.20)$$

Donde ξ_i y ξ_i^* son variables de holgura no negativas. Este problema de optimiza-

ción puede transformarse en el problema dual y su solución está dada por (2.21).

$$f(x) = \sum_{m=1}^n (\alpha_i + \alpha_i^*) K(x_i, x) \quad (2.21)$$

donde debe satisfacer $0 \leq \alpha_i^* \leq C$, $0 \leq \alpha_i \leq C$ y $K(x_i, x)$ es la función kernel.

El parámetro C determina la compensación entre la complejidad del modelo y el grado en que las desviaciones son mayores que las toleradas en la formulación de optimización, por ejemplo, si C es demasiado grande, entonces el objetivo es minimizar el riesgo empírico solamente, sin considerar la complejidad del modelo en la formulación de optimización, por el contrario a valores de C muy bajos la complejidad del modelo será menor pero se maximiza el riesgo empírico (se minimiza la capacidad de generalización).

Se sabe que el rendimiento de generalización SVM (precisión de estimación) depende de un buen ajuste de C y la correcta elección del kernel (Girma, 2009), por lo consiguiente estos parámetros deben ser calculados de forma adecuada.

Capítulo 3

Diseño e implementación del controlador

Se diseña el clasificador de estados SVC tomando en consideración: características de la planta, requerimientos del balastro y los criterios de control expuestos en (Velastegui y Andino, 2015). Se describe además el análisis de datos de temperatura e iluminancia de cuatro lámparas HID-MH de diferentes fabricantes y la respectiva metodología para implementar el SVC en hardware.

3.1. Adquisición de datos

La adquisición de las cuatro variables propuestas (tensión, corriente, temperatura e iluminancia) es simultánea y en condiciones que permitan minimizar las interferencias externas como: luz natural y temperatura ambiente cambiante. Para minimizar estas interferencias externas se utiliza el banco de pruebas desarrollado en el proyecto de (Gallo y Santamaría, 2012), que presenta una estructura dedicada al análisis de estas variables en ambientes controlados. El banco de pruebas sigue el diagrama esquemático de la figura 16.

Este esquema consta de diferentes sub etapas que se describen a continuación:

- Una etapa de alimentación, que incluye las fuentes AC y DC (fuente de poder Kepco configurada en una tensión de 170 VDC y una corriente de 3 Amperios) necesarias para alimentar la circuitería.
- Una etapa de ignición que provee los pulsos de tensión necesarios para dar inicio al proceso de ignición de las lámparas HID-MH.
- Una etapa de control, que dispara los semiconductores de potencia del inversor DC/AC (configuración como puente H).

- Una etapa de potencia, constituida por el convertor AC/DC que alimenta el bus de DC del puente H; y el puente H en sí como inversor DC/AC que alimenta a la lámpara.
- Una etapa de sensamiento que permite recabar información de tensión y corriente. Mediante el uso de dos puntas diferenciales se adquieren los valores de tensión en la lámpara y en la resistencia de sensamiento atenuados para proteger a la tarjeta de adquisición. Esta etapa consta además de un sensor de temperatura (S1) y uno de iluminancia (S2).
- Una etapa de instrumentación, constituida por el generador de señales Agilent 33120A que provee señal con las siguientes características: onda cuadrada a 10 kHz con amplitud de 2.5 Vpp y con un offset de 1.5 VDC.

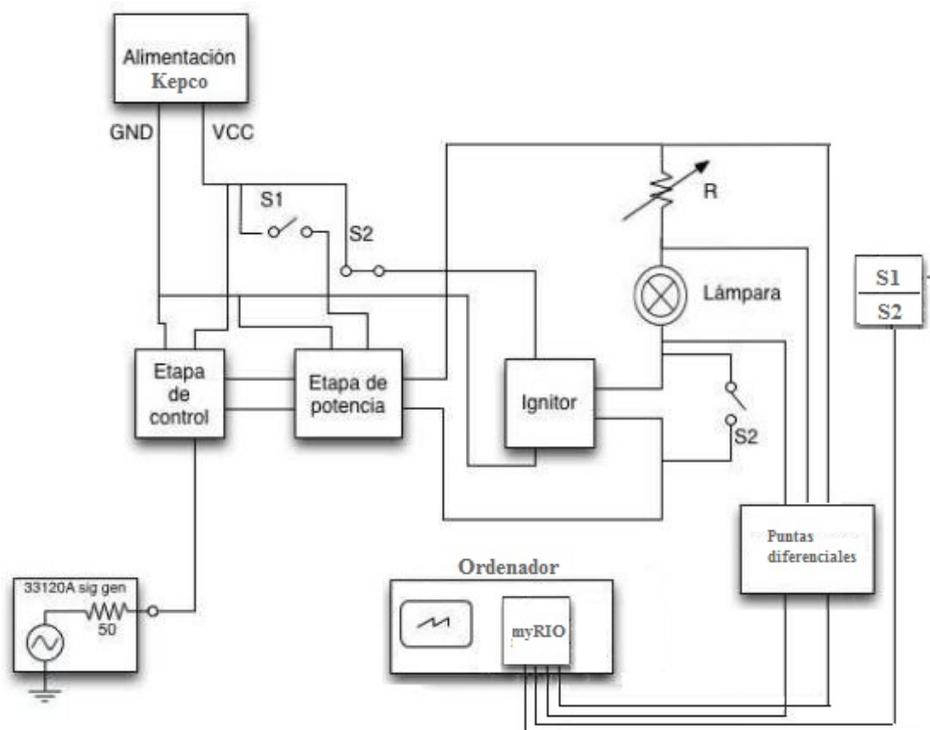


Figura 16: Esquema adquisición de datos.

Fuente: (Gallo y Santamaría, 2012)

De forma experimental puede afirmar que en un promedio de cinco sesiones cada una de las lámparas alcanzan los valores nominales de potencia (250W) y junto a ello los valores estables de iluminancia.

3.1.1. Adquisición de tensión y corriente

Se conocen las características de los puertos analógicos de entrada de la tarjeta de adquisición NI myRio que son $\pm 10\text{v}$ con resolución de 12 bits, la tensión se adquiere mediante una punta diferencial con atenuación de 100 veces el valor de entrada con ello el valor máximo de adquisición será de 3.5 V (caso extremo). De forma similar para la adquisición de la corriente se mide la tensión en la resistencia de sensamiento con una atenuación de 100 veces el valor de entrada y se divide para resistencia cuyo valor es de 5 Ohms.

3.1.2. Adquisición de iluminancia

Para seleccionar los sensores de iluminancia y temperatura se toma en cuenta las características provistas por los fabricantes descritas en la tabla 2. Según (Ransen, 2015) para la determinar la iluminancia que posteriormente se adquiere hay que tener en cuenta el área de incidencia de la luz en el banco de pruebas que se obtiene de las dimensiones del banco de prueba $53\text{cm} \times 53\text{cm} \times 68\text{cm}$. Debido a la limitación de espacio del banco de pruebas el sensor de iluminancia se ubicará a 28cm del eje del arco de descarga de las lámparas HID-MH. El esquema de la figura 17 muestra la localización del sensor de iluminancia dentro del banco de pruebas.

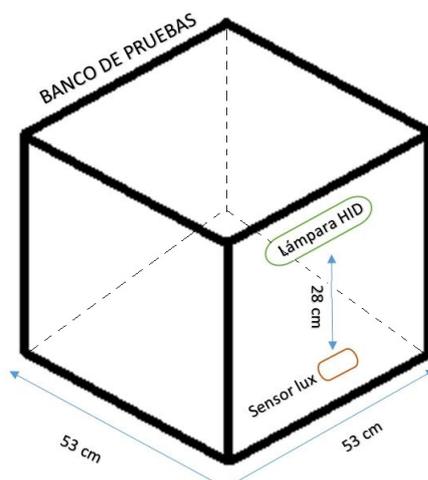


Figura 17: Dimensiones del área de incidencia de luz.

Para seleccionar el sensor de iluminancia adecuado hay que basarse en las ecuaciones enunciadas por (Ransen, 2015) :

$$E = \frac{F [lm]}{S [m^2]} \quad (3.1)$$

donde F es flujo luminoso máximo emitido por una de las lámparas HID-MH y corresponde a 19000 lm (lámpara Osram) y S es la superficie de incidencia de la luz.

$$E = \frac{19000}{0,53 \times 0,53} = 67639,73 \text{ lux} \quad (3.2)$$

Al considerar un margen de error del 5 % se obtiene 71020,98 lux que será el valor que el sensor debe ser capaz de medir, y para ello se opta por el sensor de iluminación Digital BH1750FVI para medición de luz ambiental de 16 bits en configuración ajustable de ventana óptica el cual permite mediciones de hasta 100000 lux (Rohm, 2009).

3.1.3. Adquisición de temperatura de la bombilla

Para seleccionar el sensor adecuado de temperatura se toma el máximo valor de temperatura emitido por alguna de las lámparas HID-MH, que según los datos de la tabla 2 y es 500°C, no obstante se debe considerar además que las temperaturas que se miden en la superficie de la ampolla elipsoidal pueden ser mucho más bajas en el tubo de descarga, las cuales según especifican los fabricantes (Osram, 2009; Sylvania, 2014) pueden llegar hasta temperaturas de 2500°C, este cambio de temperatura se debe al vacío entre el tubo de descarga y la ampolla elipsoidal que además tiene una alta transmitancia (coeficiente entre la energía que atraviesa y la energía radiante incidente) (Nellis y Klein, 2009). Para la selección del sensor se toma como referencia la mayor de las temperaturas de resistencia térmica del material de la ampolla elipsoidal especificada por los fabricantes; se considera además un margen de tolerancia del 5 % que da 525°C, que es el valor que el sensor debe medir como mínimo. Se opta por tanto por un termistor NTC DKF103, que tiene un rango de medición desde -5° hasta 615°C que estará adherido a la ampolla elipsoidal de las lámparas HID-MH.

3.2. Controlador dinámico

El controlador consiste en dos etapas, la primera es el SVC que tiene a su vez dos funciones: la primera se encarga de determinar la fase en que se encuentra la lámpara HID-MH y la segunda se encarga de colocar los valores referentes de corriente para control del convertidor DC-DC. Debido al alcance de este proyecto se toma en consideración los mismos criterios de diseño del controlador dinámico propuestos en el proyecto de (Velastegui y Andino, 2015), en el que además de usar un clasificador de estados, implementa un controlador por modos deslizantes (CMD) para mantener una corriente adecuada en la bobina del convertidor y un compensador neuronal (CN)

que realiza correcciones sobre la corriente de referencia del CMD ante perturbaciones externas. El esquema del controlador dinámico se presenta en la figura 18.

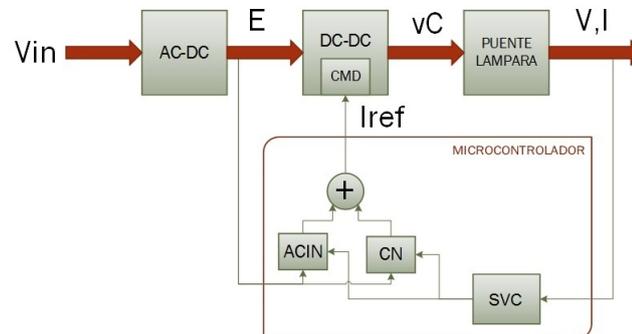


Figura 18: Esquema controlador dinámico

Fuente: (Velastegui y Andino, 2015)

3.2.1. SVC

El clasificador de estados debe ser capaz de identificar las tres fases de encendido principales: ignición, calentamiento, estable; adicionalmente se adiciona dos fases una de apagado, que según (Velastegui y Andino, 2015) reduce la corriente en la inductancia a un valor de 0 A y una fase indefinida la cual indica si el sistema balastro lámpara sale de su funcionamiento normal. Por tanto, el clasificador es multiclase de nivel 5 y además tendrá 4 entradas (máximo número de entradas) que corresponden a los datos de: tensión, corriente, temperatura e iluminancia. Un punto importante del alcance de este proyecto que es la de implementar el SVC con los datos de entrada que presenten los mejores resultados. Para determinar que variables son las mejores para el entrenamiento final del SVC se toman en consideración dos criterios: la precisión del clasificador y la ergonomía en la implementación.

3.2.1.1. Implementación del SVC

Para la implementación del SVC es necesario tener claro que se debe seguir dos etapas:

- El entrenamiento donde se determinan las características del clasificador, tales como: el tipo de kernel, número de clases y número de entradas, en esta etapa además se conoce la precisión del clasificador; resultado de este entrenamiento se obtienen los parámetros que obedecen a (2.17) que es el modelo. Esta etapa para la implementación del SVC puede ser esquematizada según se observa en la figura 19.

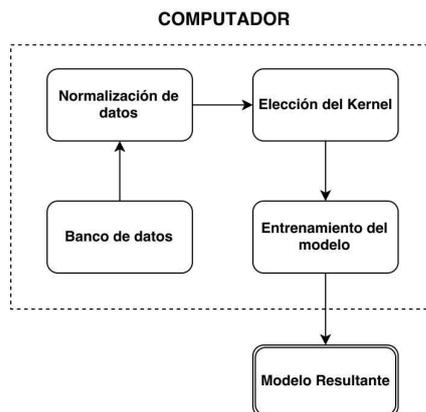


Figura 19: Esquema del entrenamiento del modelo

- El diseño y posterior implementación del predictor que cumple con la función de clasificación (se implementa en el hardware también). El predictor hace uso del modelo obtenido en el entrenamiento. Esta etapa para la implementación del SVC puede ser esquematizada según se observa en la figura 20.

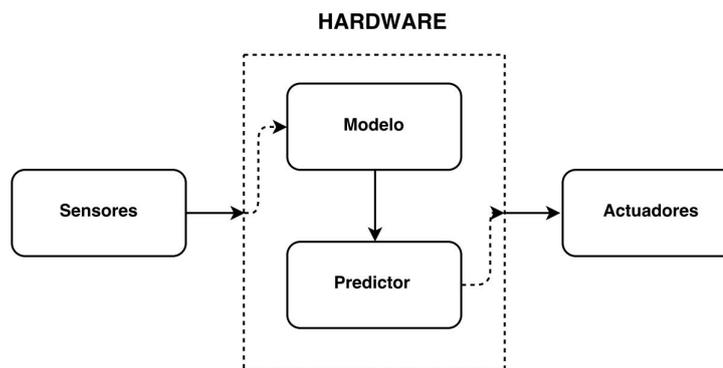


Figura 20: Esquema de la implementación del predictor en hardware

Dentro de la etapa del entrenamiento existen sub etapas que se describen a continuación:

- Banco de datos

Se obtuvieron cuatro bancos de datos uno por cada lámpara HID-MH, en cada uno de ellos están almacenados las mediciones de las cuatro variables en estudio: tensión, corriente, temperatura e iluminancia, además de las etiquetas que identifican a cada clase según las especificaciones para cada fase, 10 para la fase de apagado, 20 para la fase de ignición, 30 para la fase de calentamiento, 40 para la fase estable y 0 para la fase no definida. Dichas etiquetas se justifican en base a los resultados obtenidos en (Velastegui y Andino, 2015) y al comportamiento de la tensión y la corriente en cada fase según (Gómez, 2004) y se resumen en la tabla 1.

Tabla 1
Parámetros para determinar los estados

Fase	Vref	Iref
Apagado	0 - 200 V	0 - 0.8 A
Ignición	150 - 300 V	0.8 - 1 A
Calentamiento	120- 150 V	1 - 2A
Estable	150 - 250 V	2 - 1 A
No definido	otros	otros

Fuente: (Velastegui y Andino, 2015)

- Normalización de datos

Debido a la diferencia de rango entre las variables a ser analizadas es necesario que tanto las entradas como las salidas se concentren en un rango de longitud $(-1, 1)$ y estén dispersos dentro de este rango para un mejor tratamiento de datos. La normalización a utilizarse es la estadística Z-core y sigue la siguiente ecuación (Garrido, 2013):

$$x'_i = \frac{(x_i - \mu)}{\sigma} \quad (3.3)$$

donde:

x'_i es la entrada normalizada de índice i

x_i es la entrada de índice i

μ es la media de las entradas

σ es la desviación típica de las entradas

- Elección del kernel y entrenamiento del modelo

La selección del mejor kernel para una aplicación es todavía tema de investigación (Ali y Smith, 2006), pero se toma en consideración los resultados obtenidos en un análisis de kernels en el trabajo de (Maldonado y Weber, 2012) en el que el kernel de función de base radial (RBF por sus siglas en inglés) obtiene mejores resultados en clasificación.

Para entrenar el modelo se toman en consideración los criterios expuestos por (Kohavi, 1995) referentes a validación cruzada y bootstrap en aplicaciones de inteligencia artificial, en el que claramente recomienda el uso de “10 a 20-fold cross validation” (validación cruzada por pliegues) ó “hold out cross validation “ (validación cruzada por retención) con un distribución del 70% para datos de entrenamiento y/de 30% para datos de prueba. Para el presente proyecto se usa “hold out cross validation” para determinar los conjuntos de entrenamiento y de prueba del modelo, esto debido al menor tiempo de computo (Kohavi, 1995).

Adicionalmente, se proponen dos algoritmos que usan “SVMs biclasificadores generalizados” debido a las ventajas en la implementación en hardware del predictor; el

primer algoritmo (Máquina one vs rest) hace uso de una propuesta de (Kittipat, 2015) que usa la librería Libsvm de (Chih-Chung y Chih-Jen, 2011), y que siguen, además los criterios de (Lawrence, W, y Bottou, 2004; Bakir, Bottou, y Weston, 2004) referente a técnicas de “crosstraining” con las modificaciones propias para este proyecto. La segunda es una propuesta (Máquina one vs rest) de algoritmo que utiliza las funciones nativas de (Christianini y Shawe-Taylor, 2000.). Los dos algoritmos son escritos, compilados y probados en el editor de Matlab.

■ Modelo

El resultado del entrenamiento con los parámetros mencionados es un modelo en el que están comprimidos los atributos que servirán para determinar a que clase pertenece cada muestra. Los vectores soporte S_V , los pesos α_i , los bias b y el kernel son los atributos que obedecen a (2.17) y por tanto deben ser exportados al predictor (hardware).

Para exportar el modelo al hardware se ha decidido hacer uso del esquema de la figura 20. La capacidad del microcontrolador debe permitir las diferentes operaciones matriciales en la identificación y el control del balastro electrónico. Por esta razón se escoge la tarjeta STM32F4-Discovery que presenta puertos de entradas analógicas con resolución de 12 bits, comunicación serial y la capacidad de diseñar algoritmos mediante programación gráfica de Simulink (trabaja sólo si se instala la librería Waijung Blockset) (augmented, 2011). La programación del SVC multiclase se observa en el diagrama esquemático de simulink de la figura 21 en la que adicionalmente se introduce una máquina de estados como una etapa adicional que tiene como finalidad mejorar la precisión del clasificador, además garantiza una secuencia correcta en la evolución de las fases del proceso de encendido de la lámpara HID-MH.

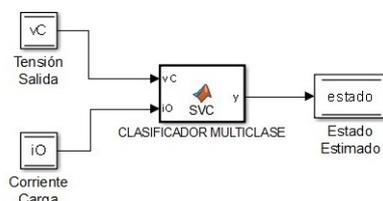


Figura 21: Esquema de la implementación del SVC en Simulink

Dentro de la etapa del predictor (ver figura 20) existen sub etapas que se describen a continuación:

- La sub etapa de lectura del modelo, donde se almacenan matrices que contienen cada uno de los vectores soporte S_V , los pesos α_i , los bias b y el kernel. Es

importante que estas matrices estén debidamente ordenadas pues cada vector soporte tiene su respectivo peso y bías.

- La sub etapa predictor de la figura utiliza conjuntamente a la ecuación (2.17) y a un arreglo de comparadores que determinan a que clase pertenece las muestras provenientes del exterior.

3.2.2. Compensador neuronal

La función principal del compensador neuronal es evitar perturbaciones externas que afecten al sistema, de forma específica las que se producen por cambios en la tensión de entrada. El compensador neuronal al detectar una variación en la tensión de entrada, calcula una variación referencia de corriente de la bobina según para mantener estable la tensión de salida. Esta variación se suma a la acción de control que proviene del SVC.

3.2.3. Acción de control del identificador Neuronal (ACIN)

La acción de control realiza la compensación en la señal de control para que la bobina reciba la corriente adecuada para el funcionamiento del convertidor además de suavizar el cambio de fases.

Capítulo 4

Pruebas y resultados

4.1. Análisis de los datos

Para determinar que variables son las mejores para el entrenamiento final del clasificador se hace un análisis independiente para cada una de las cuatro variables de las cuatro lámparas. Las características de las lámparas resumen de acuerdo a las necesidades de este proyecto en la tabla 2 y provienen de las hojas técnicas de los fabricantes.

Tabla 2
Características lámparas HID-MH según fabricante

Lámpara	Marca	Flujo luminoso	Potencia	Máxima temperatura en la bombilla
1	Sylvania	18500 lm	250 W	400 °C
2	Sylvania	18500 lm	250 W	400 °C
3	Sylvania	18500 lm	250 W	400 °C
4	Osram	19000 lm	250 W	500 °C

Fuente: (Sylvania, 2014; Osram, 2015)

4.1.1. Análisis en tiempo

Se sabe que las lámparas 1, 2 y 3 pertenecen al mismo fabricante, por lo que se espera que los datos adquiridos demuestren una evolución similar entre las lámparas, esto facilitaría la detección de datos erróneos y por lo tanto lámparas en mal estado. En las figuras 22, 23 y 24 se observan variaciones notorias en la evolución de tensión, corriente e iluminancia específicamente en el primer tercio del periodo de adquisición, lo que indicaría posibles transiciones entre fases, sin embargo, es necesario mejorar la técnica de visualización para una apreciación mas clara.

De igual manera se evidencian principalmente cambios notorios de tensión, corriente e iluminancia en la lámpara 4 de Osram (ver la figura 25a, 25b y 25c). Al

realizar un breve análisis gráfico se determina que existe una evolución no muy diferente a sus análogos de Sylvania, lo que conllevaría modelar un clasificador de fases único para todas las lámparas HID-MH analizadas en este proyecto, sin embargo es necesario un análisis numérico con el fin de confirmar dicha posibilidad.

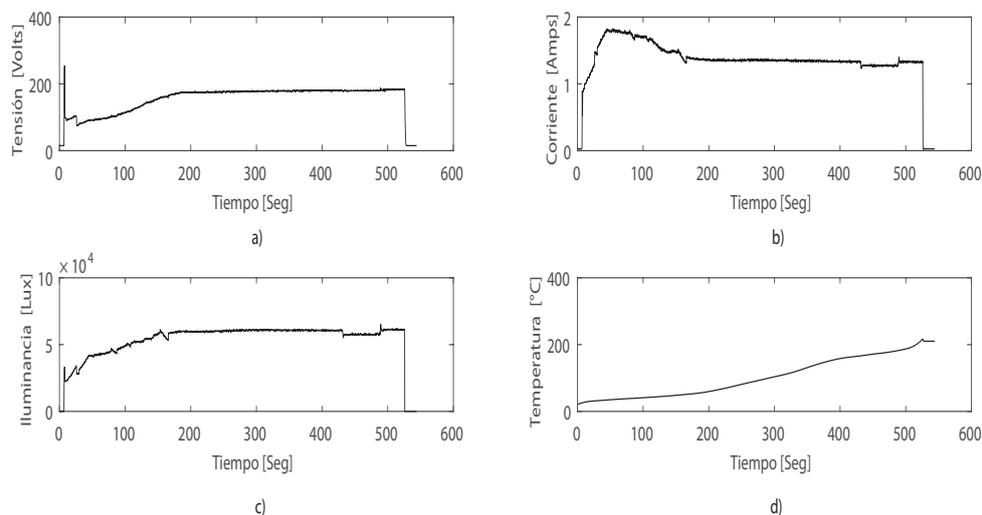


Figura 22: Datos lámpara 1 Sylvania. a) Datos de tensión b) Datos de corriente c) Datos de Iluminancia d) Datos de temperatura

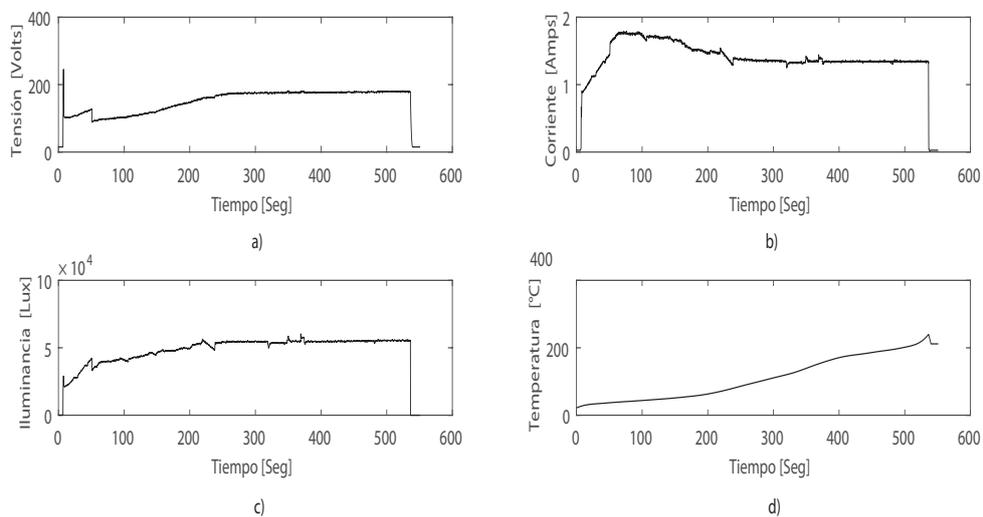


Figura 23: Datos lámpara 2 Sylvania. a) Datos de tensión b) Datos de corriente c) Datos de Iluminancia d) Datos de temperatura

En las figuras 22d, 23d, 24d y 25d de forma clara se observa que la temperatura presenta una tendencia con pocas variaciones en casi toda la adquisición, además de no alcanzar un estado estable como las demás variables. La temperatura al ser una variable que se adquiere de forma “indirecta” (en la ampolla exterior) imposibilita que

sea susceptible a cambios a lo largo del proceso de ignición de las lámparas HID-MH. La iluminancia por otro lado aunque se adquiere de forma “indirecta” también, presenta cambios mucho más marcados durante la evolución del proceso de encendido de las lámparas, por otro lado, es necesario realizar un análisis más detallado para determinar si esta variable es capaz de reaccionar a cambios de fase.

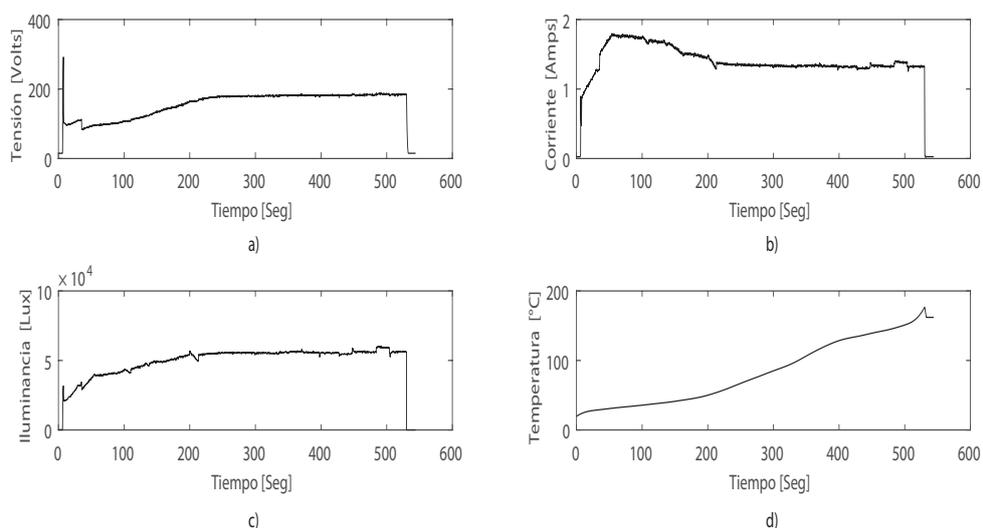


Figura 24: Datos lámpara 3 Sylvania. a) Datos de tensión b) Datos de corriente c) Datos de Iluminancia d) Datos de temperatura

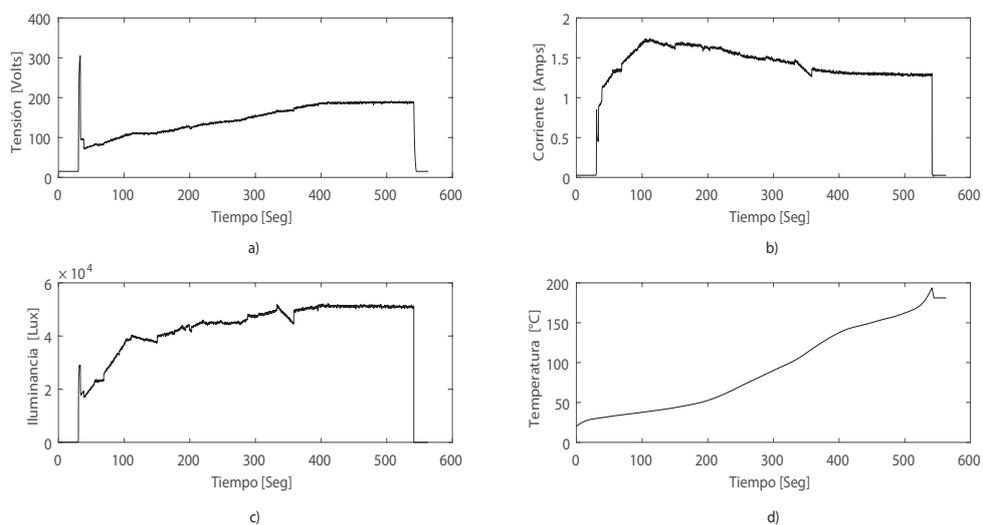


Figura 25: Datos lámpara 4 Osram. a) Datos de tensión b) Datos de corriente c) Datos de Iluminancia d) Datos de temperatura

En referencia a la tablas 3 y 4 (obtenidas y analizadas en Matlab) se presume que el modelamiento de un clasificador global para las cuatro lámparas es viable en primera instancia ya que los rangos entre las variables no son tan amplios, pero para garantizar

dicha viabilidad se debe normalizar todos los datos de todas las lámparas. Dado que no existe una metodología exacta para determinar que rango y distribución tendrá una zona de clasificación, la única forma de hacerlo es de forma experimental.

Tabla 3

Valores máximos medidos de iluminancia y temperatura

Lámpara	Marca	Iluminancia Max/Min	Temperatura Max/Min
1	Sylvania	65727/ 0 lux	216.9797 / 20.9002 °C]
2	Sylvania	69689/ 0 lux	239.9984 / 21.6750 °C]
3	Sylvania	63115/ 0 lux	176.7326 / 19.6823 °C]
4	Osram	62692/ 0 lux	193.8967 / 20.2283 °C]

Tabla 4

Valores máximos medidos de tensión y corriente

Lámpara	Marca	Tensión Max/Min	Corriente Max/Min
1	Sylvania	254.7587/ 15.1300 V	1.8283 / 0.0148 A
2	Sylvania	246.0530/ 15.1300 V	1.7943 / 0.0150 A
3	Sylvania	292.4487/ 15.1300 V	1.8035 / 0.0151 A
4	Osram	305.6745/ 15.1300 V	1.7411 / 0.0151 A

Con el fin de realizar un estudio mas detallado de las variables se plantean los siguientes análisis: tensión-corriente, tensión-iluminancia, corriente-iluminancia, tensión-temperatura, corriente-temperatura y finalmente iluminancia-temperatura.

4.1.2. Análisis tensión-corriente

Se comparan los resultados de la subsección “Análisis en tiempo” con los resultados obtenidos en las figuras 26, 27, 28 y 29.

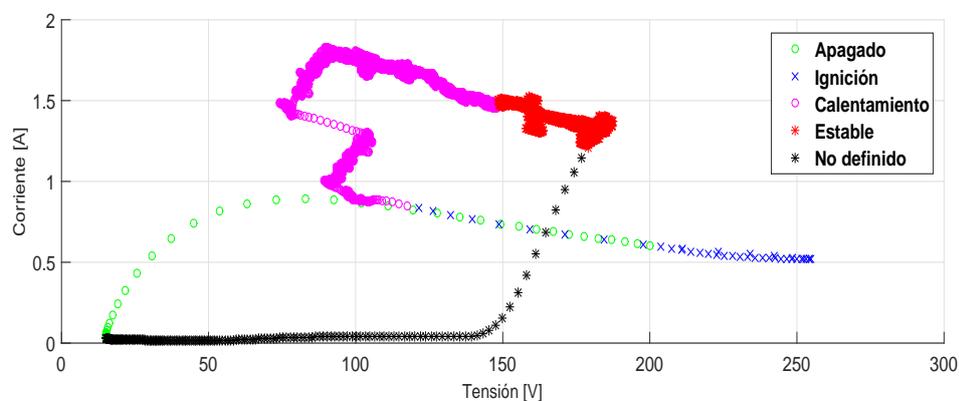


Figura 26: Fases de encendido lámpara 1 tensión en función de corriente

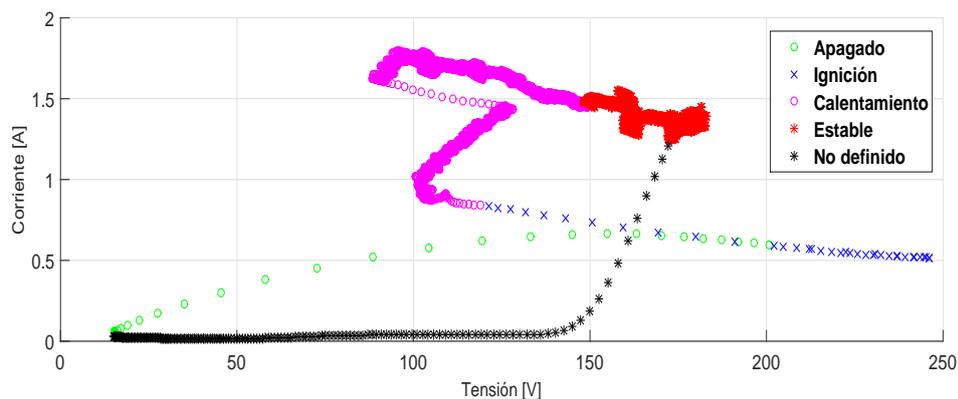


Figura 27: Fases de encendido lámpara 2 tensión en función de corriente

Se distingue claramente la evolución de cada fase de cada una de las lámparas HID-MH, esto se debe a que la adquisición de tensión y corriente requirió de un proceso que interactuaba directamente con la carga sin interferencias externas.

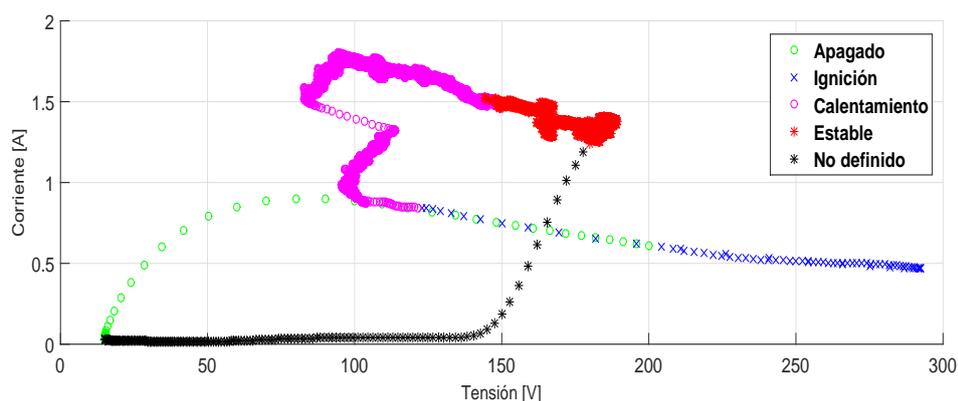


Figura 28: Fases de encendido lámpara 3 tensión en función de corriente

Se observa en las figuras 26, 27, 28 y 29 que las fases de apagado, ignición y no definida presentan una cantidad de datos mucho menor en comparación a las demás fases, (esto se debe a la velocidad de evolución en el proceso de encendido de las lámparas HID-MH), lo que provocará que en la etapa de entrenamiento del clasificador se generen más vectores soporte para las fases de calentamiento y estable, dando una mayor prioridad a la zona de clasificación de estas dos fases. Lo que dificultará clasificar los datos que pertenezcan a las fases de apagado e ignición, la fase no definida puede ser obviada en este caso debido a que esta fase se genera cuando la lámpara es desenergizada.

Por lo tanto, antes del entrenamiento del clasificador debe realizarse una adecuación o tratamiento de datos para compensar la falta de los mismos. Se presentan dos procedimientos que serán validados de forma experimental (observando el comporta-

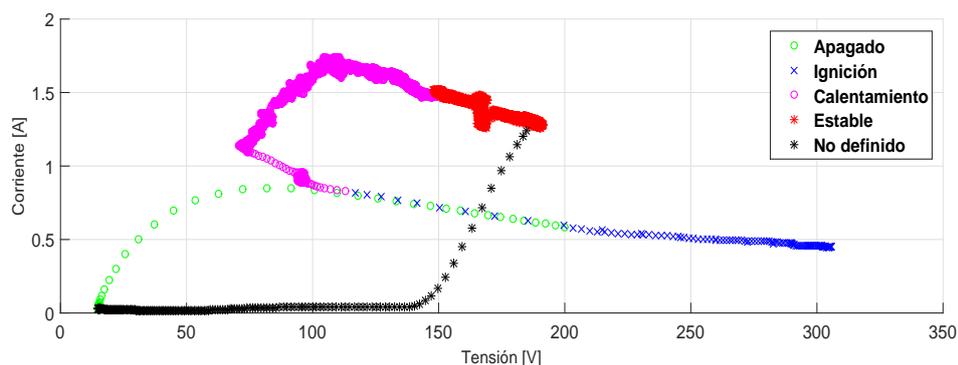


Figura 29: Fases de encendido lámpara 4 tensión en función de corriente

miento de las zonas de clasificación de cada una de las fases):

- Disminuir el número de muestras de entrenamiento para las fases de calentamiento y estable.
- Disminuir el número de muestras de entrenamiento para las fases de calentamiento y estable y obtener más datos mediante una SVR para las fases de apagado y de ignición, estos procedimientos se basan en el criterio de (Ben-Hur y Horn, 2001) en la que el número de vectores soporte aumenta en forma proporcional al número de muestras de entrenamiento. Estos procedimientos no se los realiza para la fase no definida pues los datos de esta fase ocurren cuando la lámpara deja de funcionar.

La metodología de reducción del número de muestras para las fases de calentamiento y la fase estable se los hace de forma experimental, empezando con intervalos de reducción del 10%, hasta que la zona de clasificación de cada fase no se vea afectada en su totalidad.

4.1.3. Análisis tensión-iluminancia y corriente-iluminancia

Debido a que los fabricantes (Sylvania, 2014; Osram, 2015) garantizan una tendencia lineal en la relación flujo luminoso-potencia para cada uno de sus productos (R. fabricante en tabla 5), es necesario demostrar tal relación con el fin de validar la adquisición de datos en cada una de las lámparas. Para ello se planean dos criterios:

- La media de la relación flujo luminoso-potencia debe encontrar dentro de un rango de error aceptable (menor al 10%).
- Comprobar que el coeficiente de correlación lineal medido para cada una de las relaciones flujo luminoso-potencia sea cercano a 1.

Para satisfacer los dos criterios planteados se necesita obtener en primera instancia el flujo luminoso medido y la potencia medida en cada instante de encendida cada una de las cuatro lámparas HID-MH. Para obtener el flujo luminoso a partir de los datos de iluminancia, se tiene en consideración las especificaciones del banco de pruebas y la distancia desde el sensor a la lámpara (ver figura 17), con ello y mediante (3.1) se obtienen los resultados del flujo luminoso medido. La potencia medida se determina según enuncia la ecuación (4.1)

$$P = V \times I \quad (4.1)$$

donde

V es la tensión medida en la lámpara.

I es la corriente medida en la lámpara.

Con los valores de flujo luminoso medido y potencia medida mediante la función *corrcoef* de Matlab se calculan los coeficientes de correlación lineal correspondientes a cada lámpara y expuestos en la tabla 5 en la columna “F. correlación”. Para calcular la relación flujo luminoso-potencia se hace uso de la ecuación (4.2).

$$R = \frac{F}{P} \quad (4.2)$$

donde:

F es el flujo luminoso medido en cada lámpara.

P es la potencia medida en cada lámpara.

Al hacer uso de la ecuación (4.2) se obtiene la relación flujo luminoso-potencia en cada instante de tiempo. Para tener una apreciación macro de la relación flujo luminoso - potencia se realiza el cálculo enunciado por (4.3).

$$R_{media} = \frac{\sum_{i=1}^n F_i/P_i}{n} \quad (4.3)$$

donde:

F es el flujo luminoso medido en cada lámpara.

P es la potencia medida en cada lámpara.

n es el número de muestras total en cada adquisición.

Al observar los resultados expuestos en la tabla 5, se tiene un respaldo para validar el primer criterio planteado, debido a que la relación flujo luminoso-potencia presenta un error individual (columna Error que relaciona R.Fabricante y R.medida) y promedio menor al estipulado inicialmente ($\leq 10\%$). Para comprobar el segundo criterio planteado referente a la linealidad de la relación flujo luminoso-potencia, se debe verificar que

cada una de los factores de correlación sea lo más cercano a 1, hecho que se comprueba en los datos mostrados en la tabla 5 y en la figura 30, mismos que indican valores muy próximos a la unidad (valor ideal). Cumplidos los dos criterios de validación se establece que los datos de la adquisición van de acuerdo a los parámetros expuestos por los fabricantes y son válidos para cualquier acción en adelante.

Tabla 5

Error relación flujo luminoso-potencia lámparas HID-MH

Lámpara	Marca	R fabricante	R medida	Error	F. Correlación
1	Sylvania	76 lm/W	71.24 lm/W	6.26 %	0.9972
2	Sylvania	76 lm/W	73.62 lm/W	3.13 %	0.9976
3	Sylvania	76 lm/W	70.93 lm/W	6.67 %	0.9978
4	Osram	74 lm/W	70.16 lm/W	5.18 %	0.9982
5	Media	75.5 lm/W	71.48 lm/W	5.31 %	0.9977

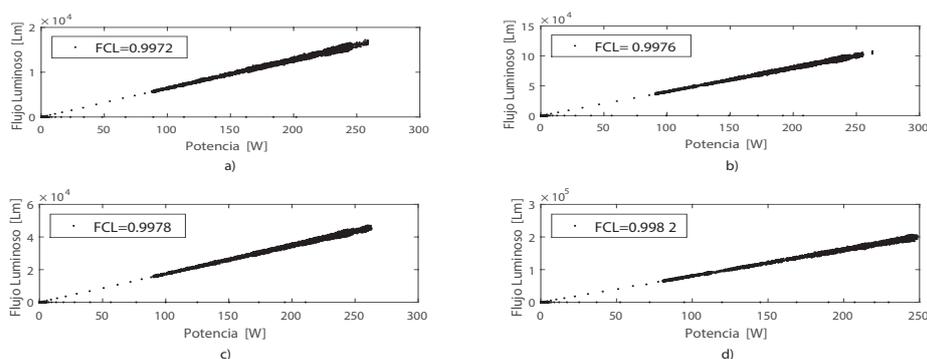


Figura 30: Relación de desempeño de las lámparas HID-MH. a) Lámpara 1 a) Lámpara 2 a) Lámpara 3 a) Lámpara 4

Como sucedió en el análisis tensión-corriente, es claro diferenciar las cinco fases. Se muestra tanto en a) y b) de las figuras 31, 32, 33 y 34 (Osram) que la iluminancia reacciona a los cambios entre fases de forma clara, esto podría ser predecible debido a que la iluminancia tiene una relación constante con el flujo luminoso y por tanto también tiene una relación lineal con la potencia.

Se observa, además en a) y b) de las figuras 31, 32, 33 y 34 el mismo comportamiento en las fases de apagado y de ignición, en donde existe poca cantidad de datos, lo que provocará que en la etapa de entrenamiento del clasificador se generen más vectores soporte para las fases de calentamiento y estable, dando una mayor prioridad a la zona de clasificación de estas dos fases. Lo que dificultará clasificar los datos que pertenezcan a las fases de apagado e ignición. Por lo que se tiene que realizar un acondicionamiento de datos previo al modelado del clasificador, dicho acondicionamiento tendría la misma metodología a la expuesta en el análisis tensión-corriente.

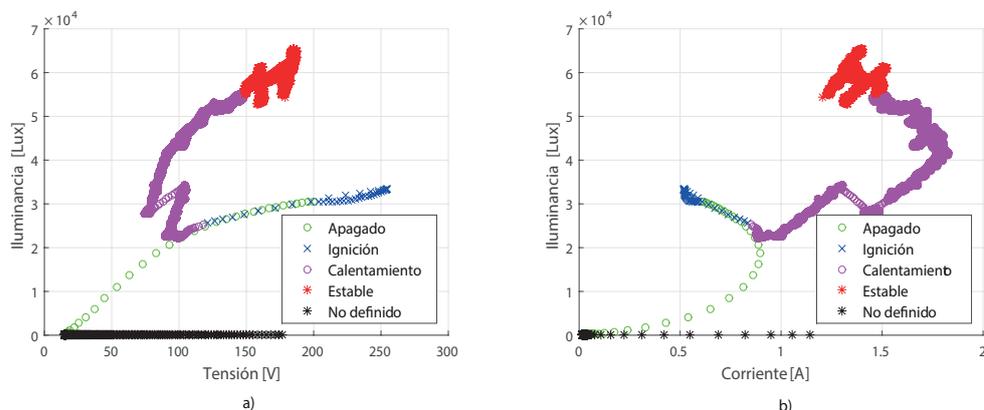


Figura 31: Fases de encendido lámpara 1 en función de a) tensión en función de iluminancia b) corriente en función de iluminancia

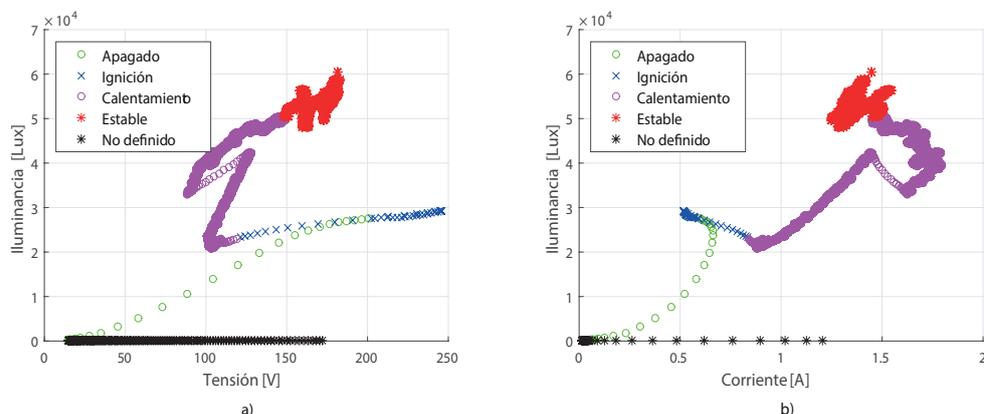


Figura 32: Fases de encendido lámpara 2 a) Tensión en función de iluminancia b) Corriente en función de iluminancia

Observando los datos de la fase *no definida* en ambas relaciones tensión iluminancia y corriente-iluminancia equivalentes a 0, es válido cuestionarse si afectará de alguna forma a las demás regiones de clasificación; la respuesta a ello es que no, debido a que esta fase no definida sucede solamente cuando una lámpara es apagada, por lo que considerar esta fase para entrenar un modelo de SVC sería innecesario, incluso podría convertirse en una zona que interfiera con las demás de mayor prioridad.

Hay que considerar además que los datos de iluminancia fueron adquiridos bajo condiciones ideales (aislado de fuentes de luz externa) por lo que la implementación un SVC entrenado con datos de iluminancia, sería poco práctico desde el punto de vista de la implementación debido a que requiere de la instalación de sensores en el área de incidencia del flujo luminoso, y que captarán señales externas (luz solar, luz artificial, reflejos etc) difíciles de discriminar en el presente proyecto.

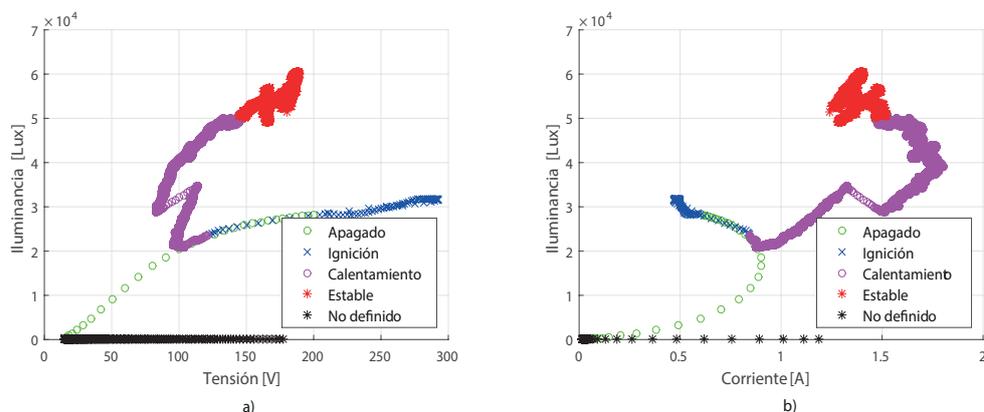


Figura 33: Fases de encendido lámpara 3 a) Tensión en función de iluminancia b) Corriente en función de iluminancia

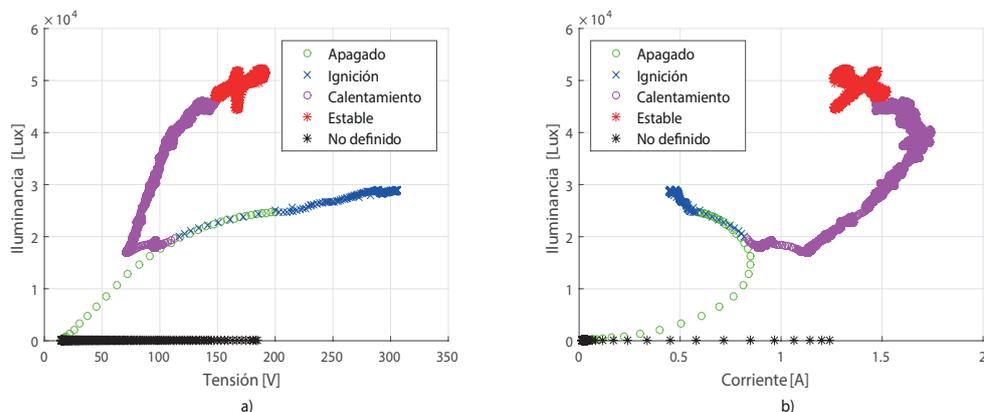


Figura 34: Fases de encendido lámpara 4 en función de tensión a) Tensión e iluminancia b) Corriente e iluminancia

Por tanto, el uso de iluminancia para implementar un SVC sería posible solamente para motivos académicos dentro de ambientes controlados.

4.1.4. Análisis tensión-temperatura y corriente-temperatura

Es complicado validar los datos para esta variable debido a que el único dato disponible según los fabricantes es la temperatura umbral de resistencia de la ampolla elipsoidal exterior (ver tabla 3), sin embargo las mediciones adquiridas pueden dar un panorama aproximando de la evolución de la temperatura en la ampolla exterior durante las fases de encendido de las lámparas HID-MH. Para la adquisición se estimó una temperatura ambiente dentro del banco de pruebas de aproximadamente 20°C.

Para la lámpara 1, se observa en la figura 35a la casi nula diferenciación entre las fases de ignición, apagado y calentamiento, esto sucede debido a que los valores de

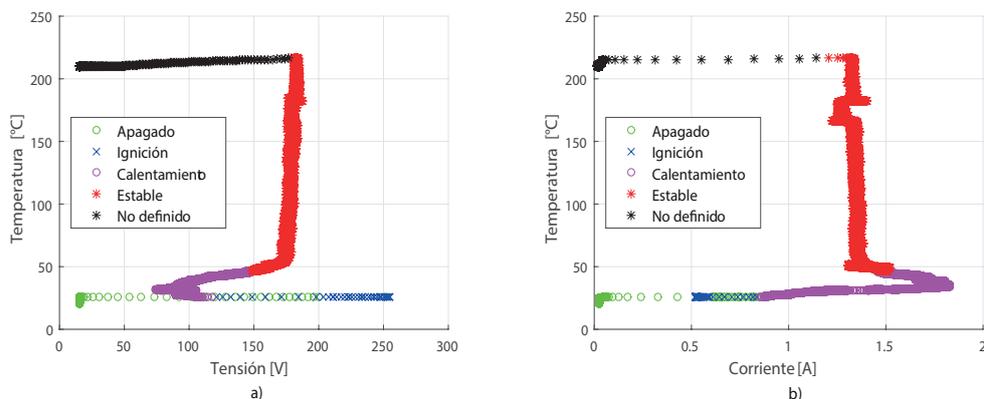


Figura 35: Fases de encendido lámpara 1 en función de a) Tensión y temperatura b) Corriente y temperatura

temperatura no cambian de forma significativa entre los cambios de estas fases. Donde si existe un cambio notorio es cuando la lámpara alcanza la fase estable.

El mismo comportamiento se observa en la figura 35b aunque la diferenciación es un poco más notable entre las fases de apagado, ignición y calentamiento. Por otro lado se obtuvo una temperatura máxima en la ampolla exterior de $216,97^{\circ}\text{C}$ que representa el 54,24% de la temperatura máxima (ver valores máximos en la tabla 2), lo que significa que la lámpara está muy lejos de funcionar en el umbral de ruptura de la ampolla exterior. Lo que en primera instancia se observa en la lámpara 1 es que a contraposición de las otras variables la temperatura no es susceptible a cambios demasiado rápidos entre fases.

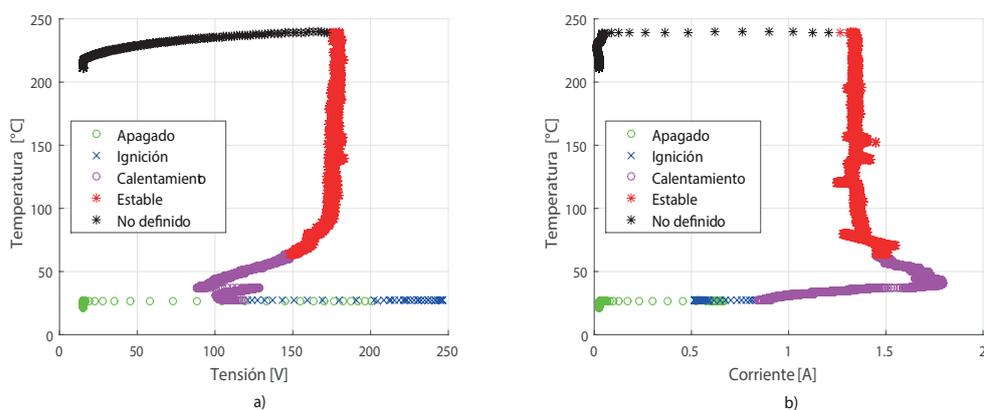


Figura 36: Fases de encendido lámpara 2 en función de a) Tensión y temperatura b) Corriente y temperatura

Un comportamiento similar es evidente para las lámparas 2 y 3 (ambas de Sylvania), si se observan las figuras 36a, 36b, 37a y 37b, no existe una diferenciación como

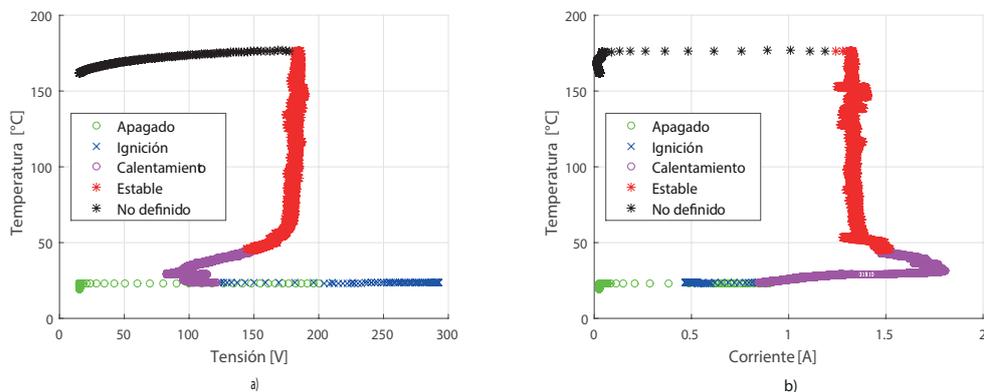


Figura 37: Fases de encendido lámpara 3 en función de a) Tensión y temperatura b) Corriente y temperatura

tal de las fases de apagado ignición y estable, lo que ocasionará una sobreposición entre las zonas de clasificación y dificultando la clasificación. Se comprueba además que las temperaturas máximas medidas (216,97 y 239,99°C respectivamente) trabajan bajo del 52,8% de la temperatura umbral especificada por los fabricantes. Los resultados de la adquisición de datos de la lámpara 4 (Osram) se presentan en las figuras 38a y 38b, las que presentan una evolución del proceso muy parecido a sus análogas de Sylvania. Lo único que se puede diferenciar es que la temperatura alcanza un nivel mucho más bajo en comparación de las otras 176,73°C.

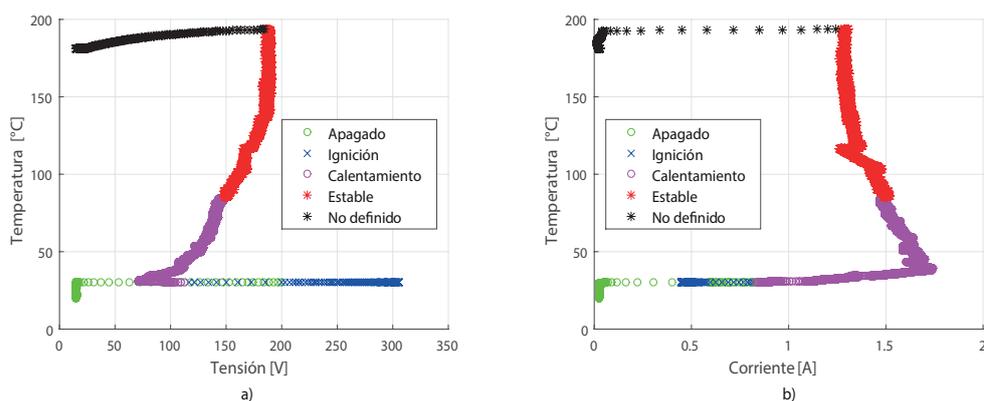


Figura 38: Fases de encendido lámpara 4 en función de a) Tensión y temperatura b) Corriente y temperatura

De forma independiente si la temperatura es puesta en función de la tensión o de la corriente presenta una respuesta de reacción muy baja, lo que ocasiona cuatro importantes efectos:

- No permite diferenciar entre las fases principalmente de apagado, ignición y

calentamiento, lo que provocaría sobreposición entre regiones de clasificación lo que disminuye la precisión.

- La temperatura es una variable lenta por lo cual no se puede detectar cambios repentinos en el funcionamiento de la lámpara HID-MH.
- La temperatura a nivel general tarda más que las otras variables (tensión, corriente e iluminancia) en llegar a un valor estable cuando existe un cambio de entre fases, además de que existe una gran cantidad de datos sobrepuestos, lo que produciría que las zonas de clasificación interfieran entre ellas.
- Es poco práctica la implementación puesto que fuera de un ambiente controlado existen demasiadas variaciones de temperatura durante el día.

4.1.5. Análisis iluminancia-temperatura

Como se observó en el análisis tensión-iluminancia y corriente-iluminancia, la velocidad de esta variable responde de forma adecuada a cambios entre fases, por otro lado la temperatura demostró todo lo contrario. Es de esperar que la temperatura influya de igual manera como con la tensión y la corriente, ello se evidencia de forma clara en las figuras 39, 40, 41 y 42, en donde existe poca diferencia entre las fases de apagado, ignición y calentamiento, incluso se observa que en la fase estable existen variaciones.

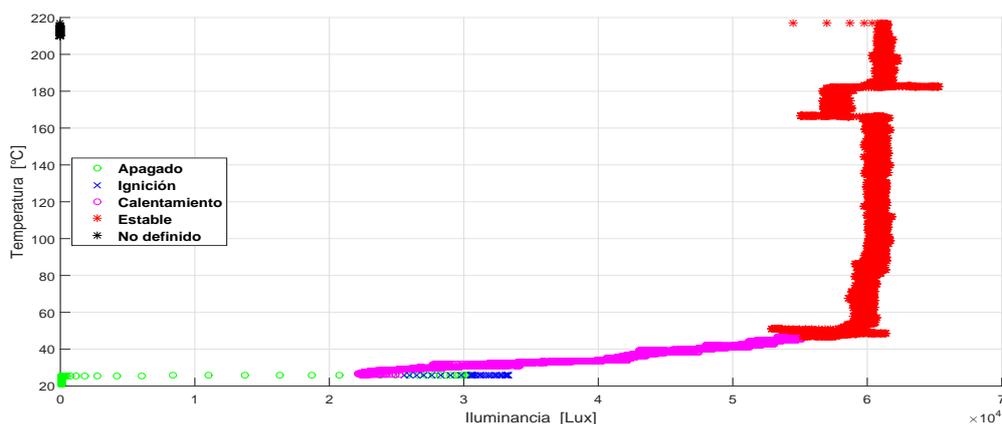


Figura 39: Fases de encendido lámpara 4 en función de a) tensión y temperatura b) corriente y temperatura

En todos los resultados obtenidos la fase no definida presenta un conjunto muy reducido de datos, esto se debe a que la iluminancia toma un valor nulo al instante de que la lámpara se apaga, esto no representa una influencia importante dado que como

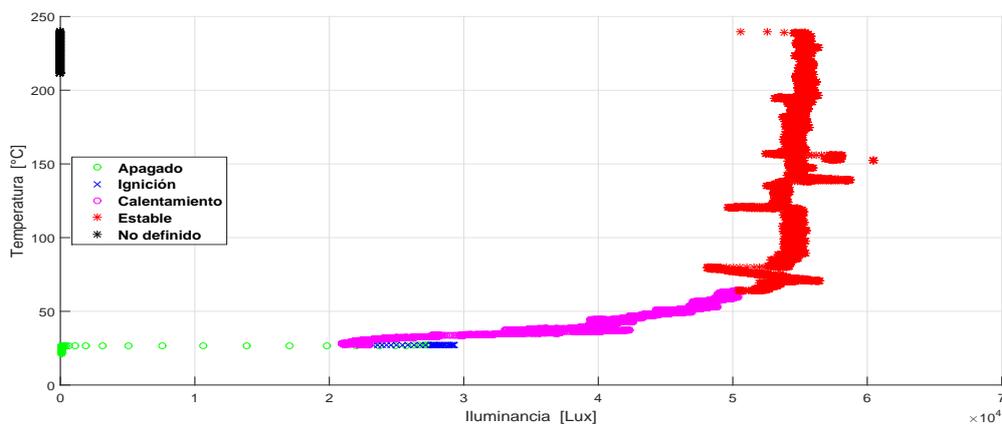


Figura 40: Fases de encendido lámpara 4 en función de a) tensión y temperatura b) corriente y temperatura

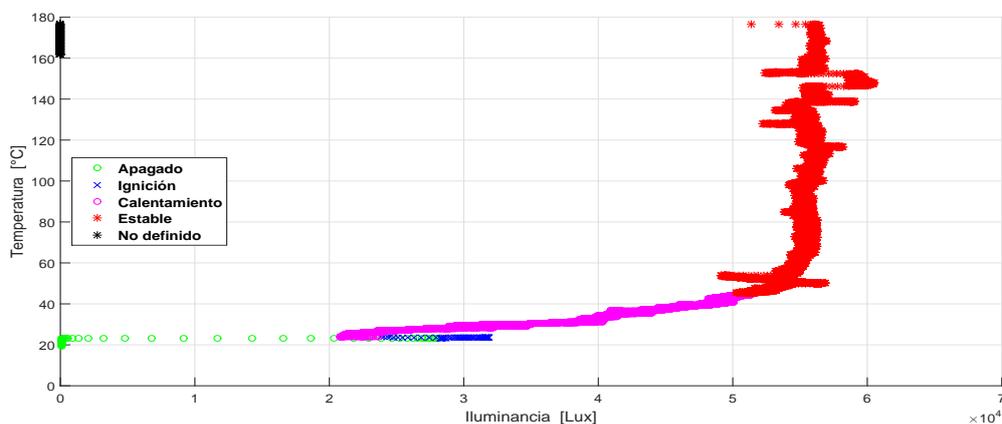


Figura 41: Fases de encendido lámpara 4 en función de a) tensión y temperatura b) corriente y temperatura

se dijo anteriormente la fase no definida es la de menor prioridad en relación a las otras.

De todos los análisis expuestos en este proyecto el de iluminancia-temperatura es el más difícil de implementar, además de necesitar sensores colocados de forma específica, el sistema estaría expuesto a datos que serían muy diferentes con los que se entrena al sistema de forma inicial, puesto que en un ambiente no ideal existen muchos factores (temperatura ambiente cambiante, interferencia de otras fuentes de luz entre las más importantes) que harán difícil determinar una fase o viceversa, debido a la naturaleza de la iluminancia tan solo bastaría un reflejo para marcar un valor totalmente fuera de rango de los valores de entrenamiento del clasificador.

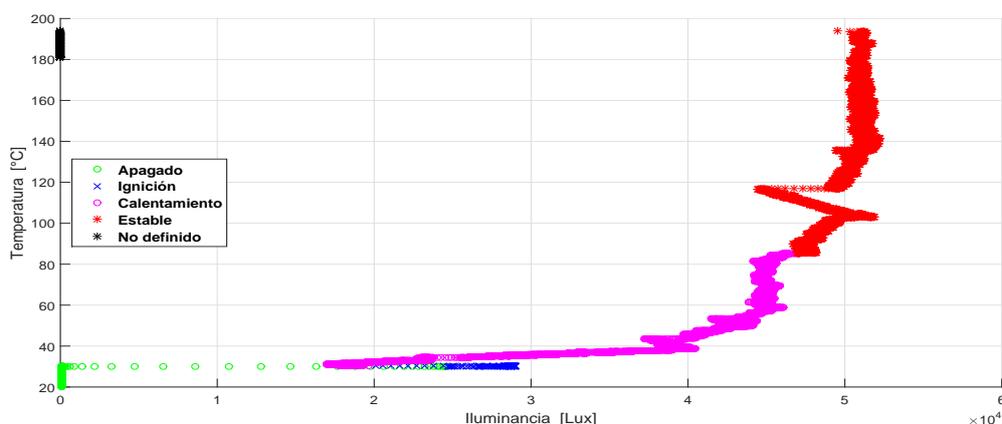


Figura 42: Fases de encendido lámpara 4 en función de a) tensión y temperatura b) corriente y temperatura

4.1.6. Comparación de variables

Una vez se han expuesto los resultados de la adquisición de las variables se hace un análisis de cuáles son las adecuadas para ser implementadas en un SVC. Se analizan tres criterios: el primero, la susceptibilidad a cambios rápidos, sobreposición de datos y finalmente la ergonomía de implementación.

- Que la variable sea susceptible a cambios rápidos es la capacidad que tiene una variable de cambiar en función de las fases de encendido lo que conllevará que el SVC pueda detectar estos cambios y tomar las decisiones del caso.
- En los análisis tensión-corriente, tensión-iluminancia, corriente-iluminancia se evidenció (forma gráfica) que los datos mantienen una sobre posición sobre todo en las fases de apagado y de ignición, sin embargo, claramente existe una diferenciación entre fases, no así como se observa en los análisis tensión-temperatura, corriente-temperatura e iluminancia-temperatura en donde las fases de apagado, ignición e incluso calentamiento muestran una sobre posición mucho mayor a los otros análisis.
- La ergonomía de implementación, que trata la facilidad de instalar un sistema en la vida real, pues como se trató anteriormente hay variables que presentan buenos resultados pero solo bajo condiciones especiales. Las variables que pueden ser implementadas de forma más ergonómica y que pueden presentar menos interferencias al medio externo son la corriente y la tensión.

En base a la tabla 6 el SVC será multi-variable de nivel 5 y tendrá 2 variables que son tensión y corriente, sin embargo, para fines investigativos se implementó un SVC

Tabla 6
Comparación de variables

Lámpara	Relación	Cambios rápidos	Sobreposición de datos	Ergonomía
1	Tensión/Corriente	Si	No	Si
2	Tensión/Iluminancia	Si	No	No
3	Corriente/Iluminancia	Si	No	No
4	Tensión/Temperatura	No	Si	No
5	Corriente/Temperatura	No	Si	No

multi-variable de nivel 5 con las 4 variables de entrada, para hacer una comparación de precisión entre el SVC de dos entradas y el clasificador neuronal implementado en el proyecto de (Velastegui y Andino, 2015).

4.2. Resultados del SVC

Como se planteó con anterioridad el primer modelo fue obtenido en base al 70% de muestras de entrenamiento y evaluado con el 30% de las muestras de prueba. Mediante la obtención de las clasificaciones positivas por cada clase y mediante las funciones *predict* y *gscatter* de Matlab se obtienen las zonas de clasificación de la figura 43. La tasa de acierto con estas zonas de clasificación se exponen por fase en las tabla 7.

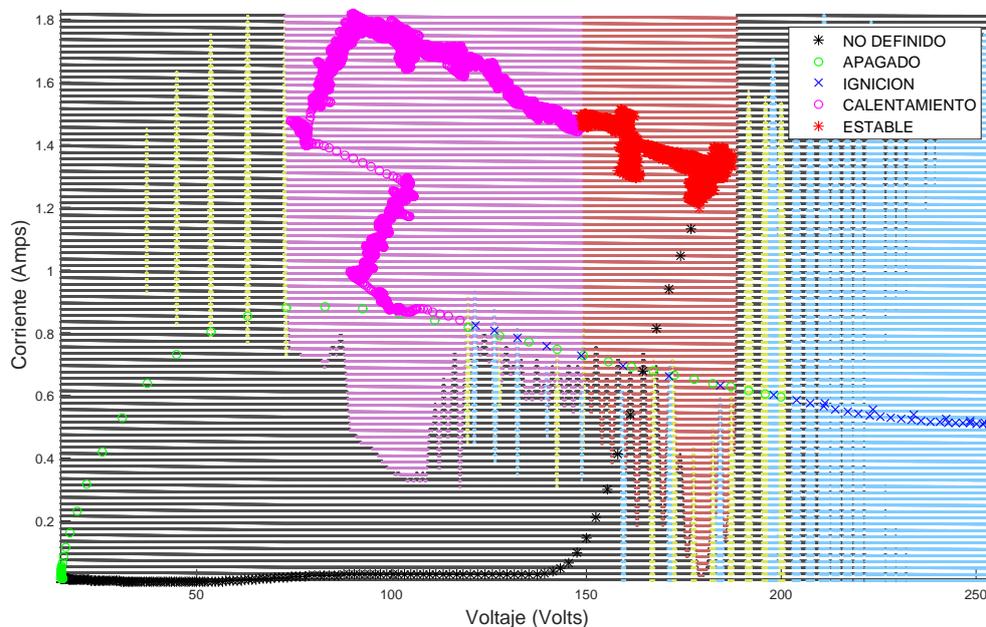


Figura 43: Regiones de clasificación sin SVR

Las fases de apagado y de ignición presentan una región de clasificación de poca influencia con relación a las otras, esto se debe a la falta de datos. Esto se ve reflejado en

la tasa de precisión que es relativamente baja (ver tabla 7).

Tabla 7

Precisión del SVC sin SVR de datos por fase

Lámpara	Marca	Apagado	Ignición	Calentamiento	Estable	No definido	Media
1	Sylvania	88.756 %	90.006 %	99.072 %	98.540 %	90.661 %	93,407 %
2	Sylvania	89.419 %	89.995 %	99.259 %	98.965 %	86.797 %	92,887 %
3	Sylvania	88.885 %	91.622 %	99.012 %	99.773 %	90.483 %	93,955 %
4	Osram	92.108 %	89.089 %	99.405 %	99.553 %	79.415 %	91,914 %
Media		89.792 %	90.178 %	99.187 %	99.207 %	86.839 %	93.040 %

En el análisis tensión-corriente se plantearon dos posibles soluciones a este problema, de las cuales de forma experimental se comprobó que la disminución en un 50 % de las muestras de las fases de calentamiento y estable, y la implementación de una regresión mediante vectores soporte (SVR) presentaron los mejores resultados porque se logró regiones de clasificación independientes con tasas de precisión más altas. La metodología que llevó a estos resultados se detalla a continuación.

Para entrenar el modelo de la SVR no se consideran la totalidad de los datos pertenecientes a la fase de apagado e ignición, debido a que la cercanía que existe con los datos de la fase de calentamiento de sobrepondrán generando un modelo erróneo, por lo que en primera instancia se genera el modelo con los datos expuestos en la figura 44a correspondiente al 96 % de datos fases de apagado e ignición. Entrenado el modelo de regresión (ver figura 44b) se le adjunta el restante de los datos de la fase de ignición (ver figura 45b).

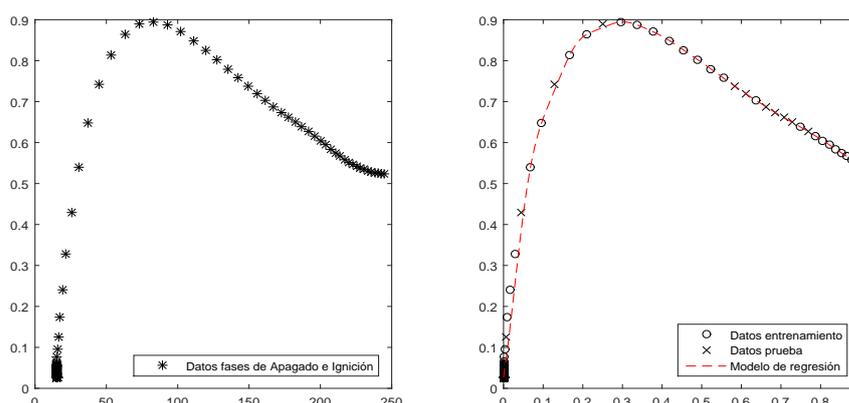


Figura 44: Modelo de regresión a) Datos fases de apagado e ignición b) Modelo SVR entrenado

A las muestras que se generen a partir del modelo de la regresión se adjunta el 4 % de los datos faltantes con el fin de tener un banco de datos general que será usado en

el entrenamiento del clasificador final. El resultado final de la regresión y de la unión de los datos restantes de las fase de ignición se observa en la figura 45.

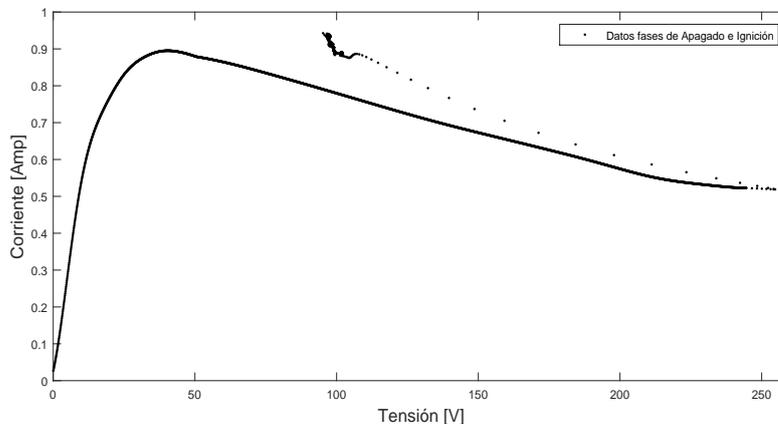


Figura 45: Interpolación datos de las fases de apagado e ignición

Como se evidenció con anterioridad la zona de clasificación puede tener extensión grande o pequeña en función del número vectores soporte (ver figura 43), lo que implica que los datos que se obtengan a partir de la SVR deben cumplir dos características:

- Asignar un número adecuado de muestras para las fases de apagado e ignición con el fin de que cada una de las zonas de clasificación generadas no interfieran con las demás fases.
- Que las muestras obtenidas a partir del modelo de regresión sigan el mismo patrón de generación que los datos de entrenamiento y prueba, es decir, el modelo debe sobre ajustarse (overfitting) a las muestras de entrenamiento, de no ser así los datos presentarán un margen de generalización demasiado amplio con lo que extiende la zona de clasificación.

Con el fin de generar un número adecuado de muestras para las fases de apagado e ignición se parte de la cantidad de muestras promedio que presenta cada banco de datos (uno por cada lámpara). Cada banco de datos tiene en promedio 40000 muestras (valor obtenido mediante matlab), y cada fase contribuye de forma porcentual en los valores que se indican en la tabla 8.

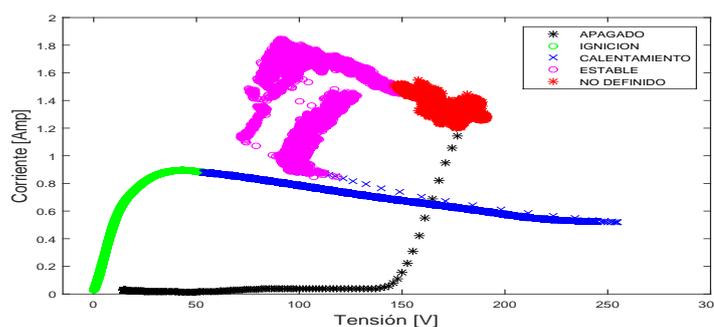
En base a los datos relacionados a las fases de apagado e ignición se decide entrenar un clasificador total (generalizado para las cuatro lámparas) aumentando 100 muestras (generadas por por el modelo de regresión) para las fases de apagado e ignición y una disminución gradual del 10% en los datos de las fases de calentamiento y estable; hasta que de forma experimental se tengan zonas de clasificación que no

Tabla 8

Precisión del clasificador único con datos de cada lámpara

Lámpara	Fase	Número aproximado de datos por fase	Proporción
1	Apagado	800	2 %
2	Ignición	1000	2.5 %
3	Calentamiento	16600	41.5 %
4	Estable	20400	51 %
5	No definido	1200	3 %
	Total		100 %

interfieran unas con otras. Al seguir la metodología anterior se determina que los mejores resultados obtenidos fue cuando se generaron 1000 muestras extras para la fase de apagado y 1200 muestras extras para la fase de ignición, y una reducción del 50 % de los datos de las fases de calentamiento y estable. Los resultados se exponen en la figura 46.

**Figura 46:** Banco de datos final

Los resultados que se muestran en la figura 47 indican unas regiones de clasificación definidas en comparación con las obtenidas en la figura 43.

Se evidencian las tasas de precisión que se indican en la tabla 9 y por fase en la tabla 10. Existen cambios notorios positivos para los resultados donde se aplicó la SVR

Tabla 9

Precisión del clasificador único con datos de cada lámpara

Lámpara	Marca	Precisión sin SVR	Precisión con SVR
1	Sylvania	93,407 %	98,008 %
2	Sylvania	92,887 %	98,296 %
3	Sylvania	93,955 %	97,942 %
4	Osram	91,914 %	93,407 %
Media		93.040 %	96.913 %

Al analizar los valores de la tabla 10, se observa que la precisión del SVC tiende a ser menos con datos de la lámpara Osram, esto sin duda afecta a la precisión total del clasificador.

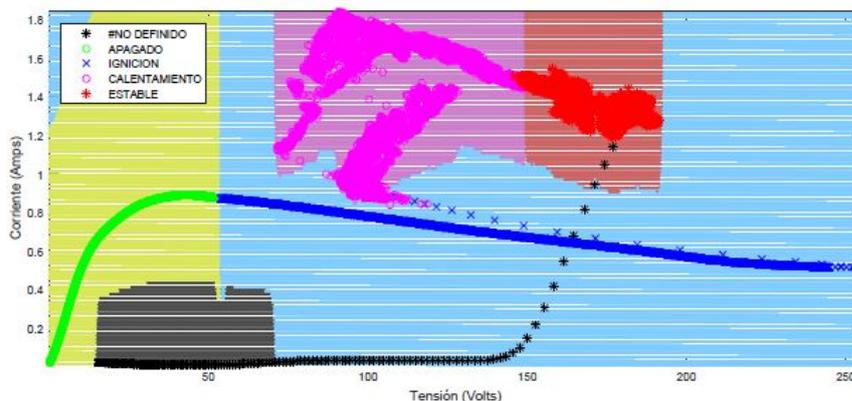


Figura 47: Regiones de clasificación final

Tabla 10

Precisión del SVC con SVR de datos por fase

Marca	Apagado	Ignición	Calentamiento	Estable	No definido	Media
Sylvania	99.198 %	98.025 %	99.480 %	99.773 %	93.563 %	98,008 %
Sylvania	98.367 %	98.238 %	99.699 %	99.808 %	95.368 %	98,296 %
Sylvania	98.280 %	99.056 %	99.452 %	99.611 %	93.211 %	97,942 %
Osram	91.744 %	91.836 %	98.964 %	97.450 %	87.041 %	93,407 %
Media	96.897 %	96.788 %	99.398 %	99.160 %	92.295 %	96.913 %

Para tener un análisis más objetivo se entrena un clasificador sólo con datos de las lámparas Sylvania donde se obtienen los resultados de la tabla 11.

Tabla 11

Precisión del SVC con SVR de datos por fase para lámparas Sylvania

Marca	Apagado	Ignición	Calentamiento	Estable	No definido	Media
Sylvania	98.323 %	99.609 %	99.844 %	99.280 %	97.692 %	98,949 %
Sylvania	98.115 %	98.708 %	99.470 %	99.219 %	97.098 %	98,522 %
Sylvania	97.736 %	98.662 %	99.123 %	99.539 %	96.114 %	98,234 %
Media	98.058 %	98.993 %	99.479 %	99.346 %	96.968 %	98.568 %

Se observa que clasificador con datos de lámparas Sylvania mejora la precisión de 96,913 % (ver tabla 10) a 98,568 % (ver tabla 11), donde se demuestra que los datos de la lámpara Osram si afectan al rendimiento general del clasificador global. Sin embargo, el clasificador final tendrá incluido a los datos de la lámpara Osram.

4.2.1. SVC con cuatro variables de entrada

El modelo de regresión realizado en este proyecto es aplicable solamente para un sistema de dos variables de entrada, por lo tanto, el modelo de regresión no se aplica

para realizar ninguna corrección de los datos previo al entrenamiento del clasificador multiclase de cuatro entradas. Para realizar el entrenamiento de este clasificador se hace uso del algoritmo hace uso de una propuesta de (Kittipat, 2015) que usa la librería Libsvm de (Chih-Chung y Chih-Jen, 2011), se siguen además los criterios de (Lawrence y cols., 2004; Bakir y cols., 2004) referente a técnicas de “crosstraining”.

Tabla 12

Precisión del SVC de cuatro entradas por fase

Marca	Apagado	Ignición	Calentamiento	Estable	No definido	Media
Sylvania	96.405 %	95.896 %	97.361 %	97.533 %	97.452 %	96,929 %
Sylvania	95.652 %	95.721 %	97.486 %	97.594 %	97.785 %	96,847 %
Sylvania	96.145 %	95.026 %	97.133 %	97.450 %	96.565 %	96,463 %
Osram	93.363 %	94.541 %	97.014 %	97.141 %	95.862 %	95,584 %
Media	95.391 %	95.296 %	97.248 %	97.429 %	96.916 %	96.456 %

Como se observa en los datos de la tabla 12 la precisión en general es de 96,456 % que es mucho menor que la del SVC de dos variables, se observa además que la lámpara Osram muestra mejoras notorias en la fase no definida aunque se mantiene por debajo de la tasa de acierto de las demás lámparas.

4.2.2. Máquina de estados

Para garantizar que el funcionamiento del sistema balastro-lámpara no se vea afectado por transiciones erróneas se considera el uso de una máquina secuencial de estados. La máquina de estados cumple la función principal de garantizar que las fases de encendido ocurran de forma secuencial, puede además funcionar como un complemento al SVC por que determina cuando una muestra de entre 4 (valor limitado por memoria del hardware) no pertenece al grupo y da como salida el estado de las otras 3 muestras, hasta que 3 de las 4 muestras pertenezcan a un mismo estado la salida no se actualizará . Si las 4 muestras presentan un estado diferente la máquina secuencial mantiene el último estado válido hasta que se cumpla la condición para actualizarlo. El esquema de la figura 48 resume el funcionamiento de la máquina de estados.

La figura 49 muestra dos bloques principales, el bloque A es la implementación del clasificador multiclase analizado en la sección SVC del capítulo 3, mismo que se compila y almacena de forma directa en el microcontrolador de la STM32 por medio de la librería Waijung Blockset para programación gráfica desde Simulink, el cual tiene dos entradas correspondientes a las tensión y a la corriente, se han asignado además las siguientes etiquetasl de salida: fase de apagado 10, ignición 20, calentamiento 30, estable 40 y no definido 0.

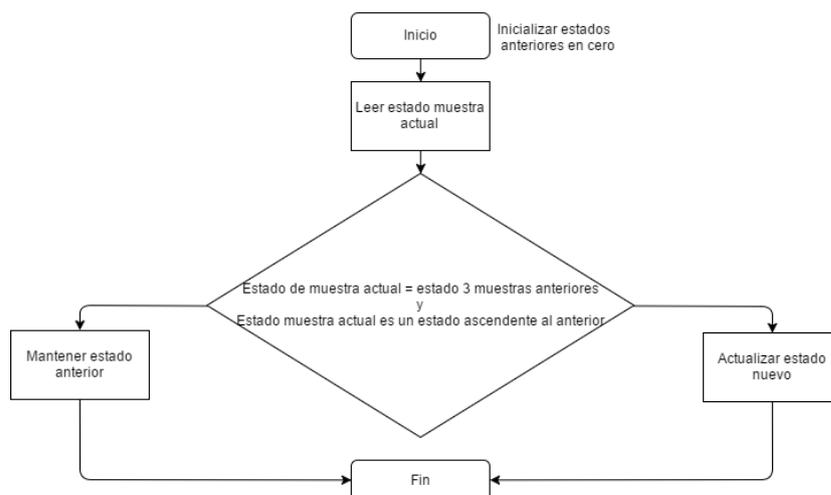


Figura 48: Lógica de la máquina de estados

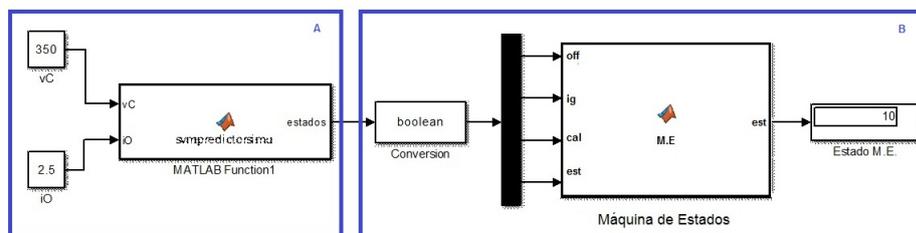


Figura 49: Esquema SVC-máquina de estados

Con la implementación de la máquina de estados hay un aumento de la precisión del clasificador del 96,913 % (ver tabla 10), a 97,639 % (ver tabla 13) además de que el sistema Balastro-lámpara no se vea afectado por transiciones erróneas en el proceso de encendido. Los datos obtenidos con la implementación de una máquina de estados se detallan en la tabla 13.

Tabla 13

Precisión del SVC-SVR de dos variables con máquina de estados por fase

Marca	Apagado	Ignición	Calentamiento	Estable	No definido	Media
Sylvania	99.408 %	98.652 %	99.808 %	99.806 %	93.611 %	98,257 %
Sylvania	98.631 %	98.382 %	99.833 %	99.863 %	95.394 %	98,420 %
Sylvania	98.544 %	99.302 %	99.599 %	99.653 %	93.490 %	98,117 %
Osram	95.149 %	95.444 %	98.620 %	98.194 %	91.413 %	95,764 %
Media	97.933 %	97.945 %	99.465 %	99.379 %	93.477 %	97,639 %

4.2.3. Comparativa de clasificadores

Los datos expuestos en la tabla 14 referentes a la precisión del identificador Neuronal son tomados de (Velastegui y Andino, 2015) y los valores del clasificador por

SVMs independientes con máquina de estados de (Andino, 2015).

Tabla 14

Comparación de clasificadores para lámparas HID-MH

Identificador de estados	Apagado	Ignición	Calenta	Estable	No definido	Media
Neuronal	85.04 %	85.83 %	84.92 %	88.39 %	-	86.04 %
SVMs ind. y M.E.	99.54 %	95.01 %	98.66 %	98.79 %	-	98.00 %
SVC 2 entradas SVR	96.897 %	96.788 %	99.398 %	99.160 %	92.295 %	96.913 %
SVC 2 entradas SVR y M.E	97.933 %	97.945 %	99.465 %	99.379 %	93.477 %	97.639 %
SVC cuatro entradas	95.391 %	95.296 %	97.248 %	97.429 %	96.916 %	96.456 %

Se puede observar que cualquier método de clasificación mediante SVM es mejor que el clasificador neuronal expuesto por (Velasco y Andino, 2015), sin embargo, analizando métodos de clasificación mediante SVMs se observa que ambos métodos presentan tasas de acierto sobre el 93 %, debido a la diferencia estructural, al número de clases, y al número de lámparas empleadas estos sistemas no se puede comparar de forma directa. Se resumen a continuación las ventajas de utilizar SVM para determinar las fases de encendido de una lámpara HID-MH:

- Ajuste de las zonas de clasificación

Se lo puede realizar cambiando el número de muestras del SVR para las fases de Apagado e Ignición, con el fin de poder dar más prioridad al resto de fases de ser el caso, otra opción es el cambio de kernel que debido a la estructura multiclase permitiría un entrenamiento más eficiente en términos del tiempo de entrenamiento.

- Máquina de estados para mejorar la precisión

La precisión de un SVC multiclase tiene una dependencia menor de una máquina de estados para alcanzar rangos de precisión sobre 92 %.

- Transiciones erróneas

Un clasificador multiclase tiene una probabilidad casi nula de que dos o más estados sean identificados al mismo tiempo, puesto que las zonas de clasificación están claramente definidas.

Capítulo 5

Conclusiones y trabajos futuros

5.1. Conclusiones

- Se diseñó e implementó el clasificador mediante Máquinas de Vector Soporte lo que permite que el sistema balastro lámpara tenga una acción de control dinámica, pues permite adaptar las condiciones de tensión y corriente en función del estado actual de funcionamiento.
- La adquisición de datos permitió determinar que variables son las mejores a ser implementadas en un SVC, estas variables son tensión y corriente, pues permiten determinar cambios de forma rápida y notoria, con lo que se puede tomar las acciones del caso, si bien es cierto la iluminancia presenta cambios rápidos y notorios es poco práctica su implementación, pues requiere la instalación de un sensor dedicado, mismo que puede ser propenso a lecturas erróneas debido a factores externos como luz solar entre otras.
- La temperatura es la variable que menos responde a cambios rápidos haciendo que el sistema sea propenso a reaccionar de forma más lenta lo que no es recomendable si se llega a dar un pico de tensión o corriente.
- Se diseñó un clasificador de fases mediante las cuatro variables, mismo que presenta valores importantes en comparación al identificador neuronal, la precisión es mayor, pero la implementación de este clasificador supone dificultades técnicas como instalación de sensores dedicados en lugares poco convenientes, además de la dificultad de trabajo en un rango cuantitativo de las variables de temperatura e iluminancia, dado que el sistema estaría expuesto a factores externos como temperatura ambiente cambiante, que provocaría cambios de estado se basen en condiciones externas y no propias del proceso de encendido de una lámpara HID-MH, iluminancia proveniente de distintas fuentes como el sol, reflejo

en el suelo, otras lámparas, que además de provocar una clasificación errónea de fase sería brusca debido a la naturaleza de la iluminancia; el SVC de este tipo solamente es factible dentro de ambientes controlados.

- Se realizó la comparación entre los diferentes SVC, y mediante los resultados se comprueba que el que mejores resultados presentó fue un SVC en conjunto con una máquina de estados que trabaja con datos de tensión y corriente, el cual permite ajustar las regiones de clasificación mediante el número de muestras obtenidas del SVR que pueden hacer del sistema más tolerable a cambios de tensión o corriente sin que se produzca cambios de fase, al realizar la comparativa con el clasificador neuronal se observa que este presenta menor precisión.
- La precisión del SVC en general tiende a disminuir cuando se hace el entrenamiento de un modelo único para lámparas HID-MH de diferentes fabricantes, esto puede ser debido a las diferencias físicas y logísticas en la manufactura de estas lámparas.
- Una de las ventajas de utilizar técnicas de clasificación y de regresión mediante SVM, es que permite implementar sistemas que realizan operaciones complejas mediante ecuaciones sencillas de bajo costo computacional.

5.2. Recomendaciones y trabajos futuros

- Diseñar un algoritmo en otras plataformas y lenguajes de programación que permitan un entrenamiento más rápido del SVC, pues los modelos diseñados en Matlab tomaron un tiempo considerable.
- Se recomienda la creación de un SVC dedicado para lámparas de un solo fabricante, puesto que al intentar englobar los datos de dos fabricantes la precisión del clasificador en general tiende a reducir.
- Como trabajo futuro se plantea un estudio para reducir el tamaño en memoria del modelo del clasificador con el fin de que el hardware no sature la misma.
- Un trabajo a futuro es mejorar el diseño de la máquina de estados para mejorar la precisión al momento de determinar una fase.
- Se recomienda como trabajo futuro realizar pruebas con los diferentes kernel especialmente uno polinómico de grados superiores a 3.

Referencias

- Aizerman, M., Braverman, E., y Rozonoér, L. (1964). *Theoretical foundations of the potential function method in pattern recognition learning*. Descargado de
- Ali, S., y Smith, K. (2006). A met a-learning approach to automatic kernel selection for support vector machines. , 70(1-3):173-186.
- Andino, J. (2015). *Diseño de un clasificador de estados para un sistema balastro-lámpara hid utilizando svm*.
- augmented, L. S. (2011). Discovery kit with stm32f407vg mcu [Manual de software informático].
- Bakir, H., Bottou, L., y Weston, J. (2004). Breaking svm complexity with cross-training.
- Ben-Hur, A., y Horn, D. (2001). Support vector clustering.
- Boser, B., Vapnik, V., y Guyon, I. (1992). A training algorithm for optimal margin classifiers.
- Carmona, E. (2013). Tutorial sobre máquinas de vector soporte (svm).
- Chicaiza, W., y Barrionuevo, C. (2013). *Control adaptativo de una lámpara hid-mh de 250w*. ESPE.
- Chih-Chung, C., y Chih-Jen, L. (2011). Libsvm : a library for support vector machines. , 2, 27:1–27:27. Descargado de Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- Christianini, N., y Shawe-Taylor, J. (2000.). A practical guide to support vector classification. [Manual de software informático]. Cambridge, UK: Cambridge University Press,.
- Cortes, C., y V, V. (1995). *Machine learning*.
- Cristianini, y Shawe-Taylor, J. (2000). *An introduction to support vector machines and other kernel-based learning methods*. Cambridge University Press.
- Flores, R. (2007). *Modelado dinámico de lámparas de alta intensidad de descarga* (Tesis de Master no publicada).
- Gallo, C., y Santamaría, N. (2012). *Diseño e implementación de un banco de pruebas para lámparas de descarga de alta intensidad (hid) de halogenuros metálicos operando a altas frecuencias*.
- García, C. (2011). Manual de procedimientos correctivos y preventivos de luminarias tipo exterior para bombillas hid de sodio y halogenuros metálicos utilizadas en alumbrado público [Manual de software informático].
- García, G. (2008). *Compatibilidad electromagnética de balastos electrónicos* (Tesis de Master no publicada).

- Garrido, M. (2013). *Reconocimiento de señales de tráfico para un sistema de ayuda a la conducción*. (Tesis de Master no publicada).
- Girma, H. (2009). A tutorial on support vector machine.
- Gómez, J. (2004). *Estrategias de control en lámparas de alta presión para la eliminación de resonancia acústica*. (Tesis Doctoral no publicada).
- Gonzales, L. (2004). Modelos de clasificación basados en máquinas de vector soporte. (Universidad de Sevilla)
- Howard, L. (2002). High intensity discharge servicing guide. [Manual de software informático].
- Kittipat, K. (2015). *Integrated brain imaging university of washington medical center*.
- Kohavi, R. (1995). A study of crossvalidation and bootstrap for accuracy estimation and model selection.
- Lawrence, S., W, Y., y Bottou, L. (2004). *Neural information processing systems* (Vol. 17; S. Lawrence, Y. W, y L. Bottou, Eds.).
- Maldonado, S., y Weber, R. (2012). Modelos de selección de atributos para support vector machines.
- Martinez, C. (2007). *Detector multiusuario para ds-cdma basado en svm - universidad de sevilla*.
- Nellis, G., y Klein, S. (2009). Heat transfer, cambridge university press. *New York*.
- O'Donnell, B., Sandoval, J., y Paukste, F. (2002). *Manual de iluminación eficiente* (E. de la Universidad Tecnológica Nacional, Ed.).
- Olmedo, E. (2006). *Diseño y construcción de un balastro electrónico alimentado con cd, para encender una lámpara de hid de 50w con ignitor interno*. Universidad Tecnológica de la Mixteca.
- Osram. (2009). Metal halide llamp - oinstructions for the use and application [Manual de software informático]. Descargado de <http://ilumicentro.com/osram.pdf>
- Osram. (2015). Metal halide llamp - oinstructions for the use and application [Manual de software informático].
- Ransen, O. (2015). Candelas lumens and lux is a very brief introduction to the basic ideas and math of illumination engineering.
- Regalado, B., y Villacís, N. (2014). *Diseño e implementación de un control fuzzy para un balastro electrónico de una lámpa hid - mh*. ESPE.
- Rohm. (2009). *Digital 16bit serial output type ambient light sensor ic* (Inf. Téc.). Rohm Semiconductor. Descargado de <https://e-radionica.com/productdata/BH1750FVI.pdf>

Sylvania. (2014). 250 w metalarc metal halide discharge lamps.

Velastegui, A., y Andino, J. (2015). *Implementación de un controlador neuronal para un balastro electrónico compatible con lámparas hid - mh de 250w*. ESPE.

Weston, J., y Watkins, C. (1998). *Multi-class support vector machines*.

Zubiaga, A. (2008). *Aproximaciones a svm semisupervisado multiclase para clasificación de páginas web* (Tesis de Master no publicada).