



PROYECTO DE GRADO

Presentado ante la ilustre UNIVERSIDAD DE LOS ANDES como requisito parcial para
obtener el Título de INGENIERO DE SISTEMAS

MÁQUINAS VECTORIALES DE SOPORTE EN REGRESIÓN APLICADA A SERIES TEMPORALES DE UN PROCESO INDUSTRIAL DE GALVANIZADO

Por

Br. Giselle Josceline Alvarez Forero

Tutor: Prof. Pablo Guillén

Marzo 2010

©2010 Universidad de Los Andes Mérida, Venezuela

Máquinas Vectoriales de Soporte en Regresión aplicada a Series Temporales de un Proceso Industrial de Galvanizado

Br. Giselle Josceline Alvarez Forero

Proyecto de Grado — Investigación de Operaciones, 71 páginas
Escuela de Ingeniería de Sistemas, Universidad de Los Andes, 2010

Resumen: La Minería de Datos puede definirse como el proceso de extraer información implícita en los datos sin previo conocimiento y potencialmente útil. En el ámbito industrial, una de las aplicaciones más interesantes es la búsqueda de conocimiento oculto que permita descubrir y asociar patrones de comportamiento de los datos y sus interrelaciones en el tiempo con la finalidad de desarrollar estrategias de mejoras en la toma de decisiones.

En este trabajo se presenta una técnica de la Minería de Datos llamada Máquinas Vectoriales de Soporte en Regresión (MVS-R), la cual es aplicada a series temporales de un proceso industrial de galvanizado continuo por inmersión de bobinas. Estas series de tiempo representan el comportamiento de las temperaturas de referencia (condición automatizada) y temperaturas medidas (sensores) que corresponden a lecturas de variables de control a la entrada y salida de un horno durante el proceso. A través de este enfoque de máquinas vectoriales de soporte en regresión se estiman los parámetros que interfieren en el proceso de galvanizado para determinar si las diferencias existentes entre las temperaturas medidas y de referencia están o se ven afectadas por dichos parámetros. La metodología MVS-R permite determinar el valor de una variable dependiente que está en función de otras variables independientes o explicativas, buscando la mejor función que determine esta variable. En general, se busca aprovechar al máximo la información obtenida de bases de datos compuestas por series temporales con el propósito de desarrollar estrategias de mejoras en la toma de decisiones a fin de optimizar la calidad del producto, aumentar la producción, prevenir fallos y reducir costos ocasionados por estos fallos durante el proceso de galvanizado.

Palabras clave: Máquinas Vectoriales de Soporte en Regresión, Minería de Datos, Proceso Industrial de Galvanizado.

A Dios Todopoderoso, a mi Madre, a mi Padre y a mis Hermanos.

Los Amo

www.bdigital.ula.ve

Índice

Índice de Tablas	viv
Índice de Figuras	vvi
Agradecimientos	vixii
Capítulo 1 Introducción	1
1.1 Introducción.....	2
1.2 Antecedentes.....	2
1.3 Planteamiento del problema.....	3
1.4 Objetivos.....	3
1.4.1 Objetivo General.....	3
1.4.2 Objetivos Específicos.....	3
1.5 Justificación.....	4
Capítulo 2 Marco Teórico	5
2.1 Galvanizado en caliente.....	5
2.2 Descripción del proceso industrial de galvanizado.....	6
2.2.1 Descripción de la línea de galvanizado.....	6
2.2.2 Modelo de control del horno.....	8
2.2.3 Modelo matemático.....	9
2.2.4 Modelización matemática del calentamiento de la banda.....	10
2.3 Calidad del Producto.....	11
2.4 Base de datos.....	12
2.5 Minería de datos.....	20
Capítulo 3 Metodología.....	22
3.1 Introducción a las MVS.....	21
3.2 Ventajas de las MVS.....	22
3.3 Definiciones básicas de las MVS.....	23
3.3.1 Dimensión VC.....	23
3.3.2 Maximización del margen.....	24
3.4 MVS para el caso lineal	25

3.5 MVS para el caso no lineal.....	27
3.5.1 MVS con margen máximo en el espacio de características.....	28
3.5.2 MVS con margen blando.....	30
3.6 Máquinas Vectoriales de Soporte en Regresión.....	31
3.7 Procedimiento para el ajuste de los parámetros del modelo.....	34
3.8 Salidas de la máquina.....	35
3.9 Análisis de Correlación y Selección de las muestras.....	36
3.10 Transformación de los datos al formato del software.....	36
3.11 Entrenamiento.....	36
3.12 Validación.....	37
3.13 Interpretación de los resultados.....	37
3.14 Especificación de los recursos a utilizar.....	37
Capítulo 4 Resultados.....	38
4.1 Estimación de la Temperatura Medida a partir de la Velocidad final, el Espesor y la Temperatura de Referencia.....	39
4.2 Estimación de la Temperatura Medida a partir de la Temperatura de Referencia, la Velocidad y el Espesor (Umbral tomando el valor mínimo y el máximo de la Base de Datos).....	44
Capítulo 5 Conclusiones.....	66
Bibliografía.....	68
Apéndice.....	70

Índice de Tablas

2.1 Estructura física de la Base de Datos.....	13
3.1 Tipos de Kernel utilizados para el ajuste.....	34
3.2 Salidas de la Máquina.....	35
4.1 Kernel tipo Lineal para la TMPP2M utilizando MVS-R.....	39
4.2 Kernel tipo Polinomial para la TMPP2M utilizando MVS-R.....	39
4.3 Kernel tipo RBF para la TMPP2M utilizando MVS-R.....	40
4.4 Mínimo MSE (TMPP2M).....	40
4.5 Ajuste del parámetro C utilizando MVS-R (TMPP2M).....	41
4.6 Mínimo MSE (TMPP2M).....	41
4.7 Ajuste del parámetro ϵ utilizando MVS-R (TMPP2M).....	42
4.8 Mínimo MSE (TMPP2M).....	42
4.9 Kernel tipo Lineal para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Ea_vb).....	46
4.10 Kernel tipo Polinomial para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Ea_vb).....	46
4.11 Kernel tipo RBF para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Ea_vb).....	46
4.12 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Ea_vb)).....	47
4.13 Ajuste del parámetro C utilizando Umbrales con el valor mínimo y el máximo (Ea_vb).....	47
4.14 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Ea_vb)).....	48
4.15 Ajuste del parámetro ϵ (utilizando Umbrales con el valor mínimo y el máximo (Ea_vb)).....	48
4.16 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Ea_vb)).....	49

4.17 Kernel tipo Lineal para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Ea_va).....	51
4.18 Kernel tipo Polinomial para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Ea_va).....	51
4.19 Kernel tipo RBF para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Ea_va).....	51
4.20 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Ea_va)).....	52
4.21 Ajuste del parámetro C utilizando Umbrales con el valor mínimo y el máximo (Ea_va)).....	52
4.22 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Ea_va)).....	53
4.23 Ajuste del parámetro ϵ (utilizando Umbrales con el valor mínimo y el máximo (Ea_va)).....	53
4.24 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Ea_va)).....	54
4.25 Kernel tipo Lineal para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Eb_va).....	56
4.26 Kernel tipo Polinomial para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Eb_va).....	56
4.27 Kernel tipo RBF para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Eb_va).....	56
4.28 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Eb_va)).....	57
4.29 Ajuste del parámetro C utilizando Umbrales con el valor mínimo y el máximo (Eb_va)).....	57
4.30 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Eb_va)).....	58
4.31 Ajuste del parámetro ϵ (utilizando Umbrales con el valor mínimo y el máximo (Eb_va)).....	58
4.32 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Eb_va)).....	59
4.33 Kernel tipo Lineal para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Eb_vb).....	61

4.34 Kernel tipo Polinomial para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Eb_vb).....	61
4.35 Kernel tipo RBF para la TMPP2M utilizando Umbrales con el valor mínimo y el máximo (Eb_vb).....	61
4.36 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Eb_vb)).....	62
4.37 Ajuste del parámetro C utilizando Umbrales con el valor mínimo y el máximo (Eb_vb).....	62
4.38 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Eb_vb)).....	63
4.39 Ajuste del parámetro ϵ (utilizando Umbrales con el valor mínimo y el máximo (Eb_vb)).....	63
4.40 Mínimo MSE (utilizando Umbrales con el valor mínimo y el máximo (Eb_vb)).....	64

www.bdigital.ula.ve

Índice de Figuras

2.1 Proceso de Galvanizado	7
2.2 Registro de la temperatura TMPP2C en la zona de salida del horno.....	14
2.3 Registro de la temperatura TMPP2M en la zona de salida del horno.....	15
2.4 Series temporales de la temperatura de referencia (TMPP2C) y temperatura medida (TMPP2M) a la salida del horno (N=1.979 muestras).....	16
2.5 Registro del Espesor en la zona de salida del horno.....	17
2.6 Registro de la Velocidad en la zona de salida del horno.....	18
2.7 Matriz de Dispersión de las variables con Correlaciones lineales.....	19
3.1 Hiperplano de margen máximo.....	25
3.2 Casolinealmente separable.....	26
3.3 Caso no linealmente separable.....	28
3.4 Transformación del espacio de entrada mediante el uso de un Kernel.....	29
3.5 La función de pérdida ϵ -insensitiva de Vapnik y las variables de holgura.....	33
4.1 Errores para el ajuste del Kernel (TMPP2M).....	40
4.2 Errores para el ajuste de C (TMPP2M).....	41
4.3 Errores para el ajuste de ϵ (TMPP2M).....	42
4.4 Óptimo ajuste utilizando MVS-R (TMPP2M).....	43
4.5 Umbrales para el Espesor tomando en cuenta el valor máximo y el mínimo.....	45
4.6 Umbrales para la Velocidad tomando en cuenta el valor máximo y el mínimo.....	45
4.7 Errores para el ajuste del Kernel utilizando Umbrales con el valor máximo y el mínimo (Ea_vb).....	47
4.8 Errores para el ajuste de C utilizando Umbrales con el valor máximo y el mínimo (Ea_vb).....	48

4.9 Errores para el ajuste de ε utilizando Umbrales con el valor máximo y el mínimo (Ea_vb).....	49
4.10 Óptimo ajuste utilizando MVS-R (Umbrales con el valor máximo y el mínimo (Ea_vb)).....	50
4.11 Errores para el ajuste del Kernel utilizando Umbrales con el valor máximo y el mínimo (Ea_va).....	52
4.12 Errores para el ajuste de C utilizando Umbrales con el valor máximo y el mínimo (Ea_va).....	53
4.13 Errores para el ajuste de ε utilizando Umbrales con el valor máximo y el mínimo (Ea_va).....	54
4.14 Óptimo ajuste utilizando MVS-R (Umbrales con el valor máximo y el mínimo (Ea_va)).....	55
4.15 Errores para el ajuste del Kernel utilizando Umbrales con el valor máximo y el mínimo (Ea_va).....	57
4.16 Errores para el ajuste de C utilizando Umbrales con el valor máximo y el mínimo (Eb_va).....	58
4.17 Errores para el ajuste de ε utilizando Umbrales con el valor máximo y el mínimo (Eb_va).....	59
4.18 Óptimo ajuste utilizando MVS-R (Umbrales con el valor máximo y el mínimo (Eb_va)).....	60
4.19 TMPP2M vs TMPP2C utilizando Umbrales con el valor máximo y el mínimo para Eb_va.....	60
4.20 Errores para el ajuste del Kernel utilizando Umbrales con el valor máximo y el mínimo (Eb_vb).....	62
4.21 Errores para el ajuste de C utilizando Umbrales con el valor máximo y el mínimo (Eb_vb).....	63
4.22 Errores para el ajuste de ε utilizando Umbrales con el valor máximo y el mínimo (Eb_vb).....	64

4.23 Óptimo ajuste utilizando MVS-R (Umbrales con el valor máximo y el mínimo (Eb_vb)).....65

www.bdigital.ula.ve

Agradecimientos

Agradezco a mi Tutor, Profesor Pablo Guillén quien fue mi guía durante la realización de esta investigación, por sus grandes aportes y su impecable responsabilidad.

Agradezco a mis Padres y Hermanos por su apoyo incondicional, por creer y confiar en mí a pesar de todas las adversidades, por no permitir que me derrumbara en los peores momentos, esto es para Uds. Los Amo.

Agradezco a Andy Uzcategui por su compañía, su apoyo y su ayuda en todo momento durante este largo camino, siempre me has dado fuerzas y animo, representas las columnas de mi vida, más que mi compañero sentimental eres mi amigo. Te Amo.

Agradezco a Emilio Zambrano por sus buenos consejos, su guía y su colaboración durante esta etapa de mi carrera, eres el mejor significado de la palabra Amistad, Gracias.

Capítulo 1

Introducción

En el presente capítulo se exponen los aspectos fundamentales que respaldan la realización del trabajo: sus antecedentes, la definición del problema, los objetivos, justificación y metodología a utilizar.

1.1 Introducción

En procesos industriales es común encontrar series temporales que reflejan la dinámica real de los parámetros medidos en el tiempo que son capturados por dispositivos a través de señales emitidas por sensores. Esto implica que es necesario disponer de una base de datos con históricos del proceso que sea coherente, exhaustiva y de buena calidad, cuyo volumen de información puede ser interpretado mediante técnicas de la Minería de Datos, la cual es una disciplina que está influyendo cada vez más en nuestros días dentro del ámbito del análisis de datos.

Específicamente, en el proceso industrial de galvanizado intervienen diferentes parámetros y se quiere observar en el caso en el que las señales de temperatura medida y de consigna (a partir de aquí será llamada temperatura de referencia) presenten alguna diferencia durante el proceso continuo de inmersión, si parámetros del proceso como la velocidad en el tren de laminado y el espesor de la bobina se ven influenciados por estos cambios o viceversa. Para ello se utilizará la metodología de Máquinas Vectoriales de Soporte en Regresión (MVS-R), la cual permite predecir el valor de una variable dependiente en función de otras variables independientes o explicativas.

En la actualidad, la supervivencia de las empresas depende en gran medida de los procesos organizativos y de las tecnologías que éstas utilicen. Entre las metodologías empleadas se encuentra la Minería de Datos, la cual permite la extracción de información oculta, potencialmente útil, contenida

en bases de datos, la cual pueda ser utilizada en la toma de decisiones. Este conocimiento generalmente se cristaliza a través de la creación de patrones, reglas o modelos.

1.2 Antecedentes

Aunque existen muchas técnicas alternativas para enfrentar problemas de regresión, las máquinas de soporte vectorial han sido desarrolladas como una herramienta robusta para regresión en dominios complejos y ruidosos. Las MVS pueden ser usadas para extraer información relevante a partir de conjunto de datos y construir algoritmos de regresión rápidos para datos masivos (Carreras, 2004).

En la optimización de procesos industriales existen investigaciones asociadas a la búsqueda de patrones ocultos y de reglas asociativas en históricos de procesos industriales, tales como el proyecto de investigación realizado por el departamento de Ingeniería Mecánica de la Universidad de la Rioja, España titulado: “Descubrimiento de conocimiento mediante técnicas de Minería de Datos aplicadas a series temporales para la optimización de procesos industriales” con metodología orientada al uso de técnicas de Minería de Datos (Martínez, 2006).

Igualmente, existen investigaciones acerca de la búsqueda de patrones en las series temporales del proceso de galvanizado mediante la aplicación de técnicas de Minería de Datos, específicamente Dinámica Simbólica y Aproximación Simbólica (SAX) realizadas por tesis pertenecientes a la Facultad de Ingeniería, Escuela de Sistemas de la Universidad de Los Andes, Venezuela, titulados: “Aplicación de Dinámica Simbólica para descubrir patrones en series temporales” (Nava, 2008) y “Análisis de series temporales de un proceso industrial de galvanizado” (Herrera, 2008).

Los trabajos mencionados anteriormente acerca del Proceso Industrial de Galvanizado no explican el por qué de las diferencias encontradas entre las temperaturas de referencia y medida, de ahí el objetivo de esta investigación: detectar las diferencias en los cambios de temperatura y conocer de qué manera los parámetros que intervienen en el proceso influyen en estos cambios.

Se pueden clasificar trabajos donde se ha utilizado la formulación MVS-R para resolver problemas y aquellos que han tratado de ampliar la técnica de alguna manera. Tal es el caso de la tesis doctoral: “Máquinas de soporte vectorial en regresión” (Benavides, 2006).

1.3 Planteamiento del problema

La búsqueda constante por aumentar la calidad del producto fabricado y reducir los gastos ocasionados por fallos en el proceso de fabricación son requisitos fundamentales en una planta industrial. Este hecho ha incentivado la realización de estudios donde se han aplicado con éxito métodos y herramientas de Minería de Datos para el análisis de series temporales en la mejora de los procesos industriales. Sin embargo, surge la necesidad de aplicar varias técnicas en conjunto para poder obtener información de los registros históricos de un proceso industrial. Con este propósito, en este estudio, se plantea el desarrollo e implantación de un algoritmo de MVS-R para la estimación de parámetros que intervienen en el proceso industrial de galvanizado y así extraer información de los mismos para poder tener un mejor control y supervisión. Los resultados obtenidos mediante la estimación de dichos parámetros permitirán desarrollar estrategias de mejora del proceso industrial del acero.

1.4 Objetivos

1.4.1 Objetivo General

Aplicar una máquina de aprendizaje para estimar parámetros asociados a un proceso industrial de galvanizado.

1.4.2 Objetivos Específicos

- Realizar una revisión bibliográfica acerca de las Máquinas Vectoriales de Soporte en Regresión y del Proceso Industrial de Galvanizado.
- Analizar los parámetros que intervienen y describen el Proceso de Galvanizado.
- Programar e implantar en R el algoritmo de la máquina de aprendizaje desarrollado.
- Analizar los parámetros estimados del Proceso Industrial de Galvanizado.

1.5 Justificación

En los procesos industriales, particularmente en la industria del galvanizado de bobinas es común encontrar bases de datos que contienen series temporales. Usualmente, estas corresponden a lecturas de variables de control de un horno en el proceso de galvanizado tales como: temperatura y velocidad de la banda de acero a la entrada y salida del horno (Martínez, 2006). Ante la existencia de una base de datos con series temporales es necesario estudiar y analizar correctamente estos parámetros, que suelen ser controlados para obtener información útil y oculta, que pueda servir de gran ayuda en la toma de decisiones y en la generación de nuevos modelos de predicción.

En el caso específico en el que las señales de temperatura medida y de referencia de la banda de acero a la salida del horno presentan diferencias, se desea observar si los parámetros que intervienen en el proceso influyen en dicha diferencia. Esto es relevante al momento de hacer supervisiones y monitorizaciones en tiempo real, puesto que se pueden tomar decisiones y así controlar el proceso.

Las MVS-R son ampliamente usadas para estimaciones puesto que representan una técnica que produce modelos con mejores resultados, en comparación a otras técnicas y formulaciones (Benavides, 2006). Es por ello que esta investigación se realiza la implementación de esta técnica de Minería de Datos, la cual estimará la Temperatura Medida a la salida del horno.

Cabe destacar la importancia de este estudio en el momento en el que el sensor de temperatura medida a la salida del horno del Proceso de Galvanizado en continuo falle, puesto que se puede predecir de manera manual la Temperatura Medida con el Espesor de las bobinas, la Velocidad en el tren de laminado y la Temperatura de referencia y así controlar el mismo. Es decir, con el previo conocimiento de la mejor máquina se predicen los parámetros y posteriormente se comparan si las estimaciones son parecidas a las de referencia. Por el contrario, si el sensor se encuentra operativo, las especificaciones se pasan al mecanismo automático y así se detectan las posibles fallas.

Capítulo 2

Marco Teórico

En este capítulo se presentan los aspectos teóricos fundamentales del proceso industrial de galvanizado continuo por inmersión. Además, la descripción de la base de datos utilizada así como también un esquema general del proceso de Minería de Datos.

2.1 Galvanizado en caliente

Se denomina galvanizado en caliente al proceso mediante el cual se obtiene recubrimientos sobre acero o hierro por inmersión en un baño de zinc fundido. Existen muchos medios para proteger el acero o hierro de la corrosión, pero ninguno es tan efectivo, práctico y económico como la galvanización en caliente, ya que el zinc resiste muy bien la acción corrosiva del ambiente y, por ello, proporciona una protección a largo plazo. La galvanización en caliente evita la corrosión del acero y el hierro por los dos mecanismos siguientes:

- Proporcionando un recubrimiento aislante y protector muy duradero formado por zinc metálico y aleaciones de zinc, el cual está unido metalúrgicamente al acero o hierro básico.
- Por un efecto de protección catódica, también llamado de "sacrificio", el zinc se corroe muy lentamente y con preferencia al acero o al hierro, impidiendo la corrosión incluso sobre las pequeñas zonas del metal base que pueden quedar accidentalmente expuestas al medio ambiente por deterioro mecánico del recubrimiento o por algún defecto en el proceso (Somanin, 2004).

2.2 Descripción del proceso industrial de galvanizado

A grandes rasgos, este proceso se puede describir de la siguiente manera: El primer paso en la línea es la formación de una banda continua a partir de las bobinas de acero procedentes del tren tándem. A continuación, la banda atraviesa una serie de hornos en los que recibe un tratamiento térmico, paso previo a su inmersión en el baño de zinc líquido. Este tratamiento es esencial para la mejora de las propiedades de la banda (Martínez, 2006).

El tratamiento térmico, consiste en elevar la temperatura de la banda hasta una temperatura objetivo, manteniéndola durante un cierto tiempo, para posteriormente enfriarla siguiendo unas curvas previamente establecidas para cada tipo de acero. De este baño, la banda sale verticalmente pasando entre las cuchillas de aire que regulan el espesor del recubrimiento. El control del espesor de recubrimiento en las líneas de galvanizado en continuo se ha abordado con técnicas muy diferentes. En la actualidad, el sistema empleado en la mayoría de las líneas de galvanizado en continuo es el conocido como control por cuchillas de aire.

La banda continua de acero, tras sumergirse en el baño de zinc fundido, pasa entre dos toberas denominadas cuchillas por su especial forma que soplan aire a presión contra el recubrimiento de zinc cuando aún es líquido. La posición de dichas cuchillas y la presión del aire proyectado contra la banda, entre otros factores, determina la cantidad de zinc que permanecerá sobre la banda. El resto de zinc escurrirá hacia el baño de metal líquido.

Por último, atraviesa una serie de pasos refrigerantes donde recibe un tratamiento químico de pasivizado para ser bobinada de nuevo (Martínez, 2006).

2.2.1 Descripción de la línea de galvanizado

Los materiales de partida son bobinas de acero procedentes del tren de laminación. Las bobinas tienen el espesor requerido dentro del tren de laminado en frío. Para transformar las bobinas en una banda

continua, éstas se desenrollan, despuntando la cabeza y la cola de la bobina, y se sueldan a solape. Las impurezas arrastradas de la laminación se eliminan mediante el calentamiento en atmósfera no oxidante. Una vez limpia la banda, se somete a un ciclo de calentamiento y enfriamiento, conocido como ciclo de recocido, que tiene como objetivo el de mejorar las propiedades del acero de la misma. A continuación, para mejorar la resistencia a la corrosión de la banda de acero, se sumerge en una piscina de zinc fundido quedando revestida de este metal. El control del revestimiento se realiza proyectando aire a presión sobre la banda recubierta. Para prevenir la oxidación de la banda, se somete a un tratamiento superficial de ácido crómico. Después de este proceso, la banda es aplanada obteniéndose el producto acabado bien en forma de bobinas o de chapas cortadas (Martínez, 2006).

La línea de galvanizado puede considerarse dividida en tres secciones:

- Sección I o de Entrada: que comprende las unidades de debobinado, enderezado, corte y soldadura.
- Sección II o de Proceso: que comprende la unidad de tensión, horno del proceso, unidad de revestimiento, control de revestimiento, equipo de enfriamiento, unidad de tratamiento químico y unidades de aplanado.
- Sección III o de Salida: que comprende el equipo de bobinado y de salida de bobinas, tijera, aplanadoras, inspección, apiladora y salida de chapas de rechazo, apilado y salida de chapas de primera calidad (Martínez, 2003).
-

En la figura 2.1 se muestra el esquema básico de una línea de galvanizado en caliente.

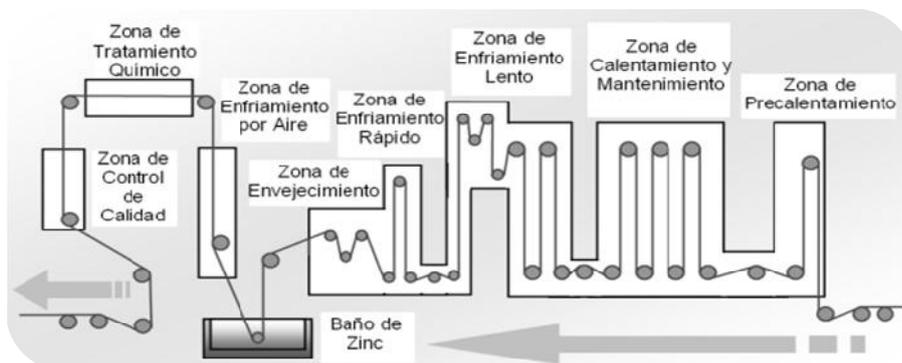


Figura 2.1: Proceso de Galvanizado (Martínez, 2006).

2.2.2 Modelo de control del horno

A continuación, se describe el modelo matemático de la zona de calentamiento del horno de recocido en continuo de la línea de galvanizado continuo por inmersión.

El control de la zona de calentamiento del horno de recocido es fundamental, ya que tiene como objetivo recristalizar el metal endurecido que sale del laminado en frío y homogeneizar la estructura cristalina del acero.

El modelo físico del horno se fundamenta en los mecanismos de transmisión de calor por: conducción, convección y radiación (Martínez, 2006).

1.- Conducción: explica el mecanismo de transferencia de calor, debidos a movimientos moleculares, entre dos cuerpos de íntimo contacto. Se define como: (Martínez, 2006)

$$dQ = -K \cdot A \cdot \frac{dT}{dx} \cdot dt \quad (2.1)$$

donde:

dQ : Cambio en la cantidad de calor (Kcal)

K : Conductividad térmica del medio de transmisión (Kcal/m²·°C·h)

A : Área a través de la que pasa el Calor Q(m²)

dT : Variación de la temperatura (°C)

x : Dirección en la que varía la temperatura (m)

dt : Intervalo de tiempo en que se calienta el área.

2.- Convección: corresponde con el mecanismo de transferencia de calor en el seno de un fluido debido a los movimientos de masa del mismo. Cuando se trata de explicar el fenómeno de convección de un sólido y el fluido que lo rodea, se desarrolla un coeficiente empírico, llamado coeficiente de película, que se obtiene del propio proceso de convección y no depende de las propiedades físicas del material. Se define con la siguiente ecuación: (Martínez, 2006)

$$dQ = h \cdot dA \cdot (T_s - T_f) \quad (2.2)$$

donde:

dQ : Cambio en la cantidad de calor (Kcal)

h : Coeficiente de película (Kcal/ $m^2 \cdot ^\circ C$)

dA : Área a través de la que pasa el calor $Q(m^2)$

T_s : Temperatura del sólido ($^\circ C$)

T_f : Temperatura del fluido ($^\circ C$)

3.- Radiación: explica el mecanismo de transmisión de calor que tiene su origen en la emisión de energía interna de un cuerpo en forma de ondas electromagnéticas. Ésta depende de la naturaleza del cuerpo y de su temperatura. La ecuación básica se define como: (Martínez, 2006)

$$Q = \sigma \cdot S \cdot \varepsilon \cdot (T_f^4 - T_s^4) \quad (2.3)$$

donde:

Q : Cantidad de calor transferida (Kcal)

σ : Constante de Stefan Boltzmann ($4,88 \times 10^{-8}$ Kcal/ $m^2 \cdot h$)

S : Área de intercambio (m^2)

ε : Coeficiente de emisividad

T_f : Temperatura del elemento radiador ($^\circ K$)

T_s : Temperatura del elemento receptor ($^\circ K$)

2.2.3 Modelo Matemático

De todos estos mecanismos mencionados anteriormente, es importante destacar que el flujo de calor intercambiado entre dos cuerpos debido al mecanismo de radiación térmica, depende de las temperaturas de cada uno de los dos y no solo de su diferencia, tal y como sucede en los procesos de convección y conducción. Esto indica que, estos dos últimos procesos son predominantes cuando las temperaturas son bajas, mientras que, para temperaturas elevadas, la radiación térmica es el mecanismo de transmisión de calor más importante. Debido a que la sección de calentamiento del horno se mueve entre los $750^\circ C$ y $950^\circ C$, se considerará solamente el mecanismo de radiación para el cálculo de los modelos. De esta forma, la primera aproximación considera la temperatura de la atmósfera del horno equivalente a la de los tubos radiantes y que la temperatura de las paredes del horno es del orden de la de la atmósfera del horno. Así se llega a la siguiente ecuación:

$$\sigma \cdot S \cdot RC \cdot (T_f^4 - T_s^4) = \rho \cdot d \cdot L_s \cdot W \cdot (QS_d - QS_e) \quad (2.4)$$

donde:

σ : Constante de Stefan Boltzmann ($4,88 \times 10^{-8} \text{Kcal/m}^2 \cdot \text{h}$)

S : Área de intercambio de calor (m^2)

RC : Coeficiente de emisividad

T_f : Temperatura del horno ($^{\circ}\text{K}$)

T_s : Temperatura de la banda ($^{\circ}\text{K}$)

ρ : Densidad del acero (7.859Kg/m^3)

d : Espesor de la banda (m)

L_s : Velocidad de la banda (m/min)

W : Ancho de banda (m)

$Q \cdot S_d$: Capacidad de calentamiento de la banda a la salida del horno (Kcal/Kg)

$Q \cdot S_e$: Capacidad de calentamiento de la banda a la entrada del horno (Kcal/Kg)

2.2.4 Modelización matemática del calentamiento de la banda

Dentro de las diferentes formas de resolver la ecuación del modelo físico, Martínez (2003) y Drever (1998), proponen la siguiente ecuación lineal interpolada:

$$TF = A \cdot TSot + B \cdot (LS \cdot d) + C \cdot \frac{TSot}{RC} + D \cdot \frac{(LS \cdot d)}{RC} + E \quad (2.5)$$

donde:

TF : Temperatura de la banda

$TSot$: Temperatura de referencia para cada bobina

d : Espesor de la banda (m)

LS : Velocidad de la banda (m/min)

RC : Coeficiente de emisividad

A, B, C, D, E y RC : Son coeficientes tomados de una tabla empírica dependiente de la temperatura de referencia, del producto $LS \cdot d$ y de perfiles de calentamiento que corresponden con las diferencias de temperaturas entre zonas de calentamiento.

Una vez obtenidos los coeficientes, se procede a calcular las temperaturas de cada una de las zonas mediante ecuaciones interpoladas, el momento de envío de las nuevas temperaturas de referencia, la velocidad de la banda, ente otras características.

2.2.5 Calidad del Producto

Las bobinas de acero son convertidas en una banda continua que es limpiada mediante calentamiento no oxidante. Al finalizar la limpieza, a la banda se le dan las características mecánicas deseadas mediante un ciclo de recocido, que consta de un calentamiento y enfriamiento controlado en cuanto a temperaturas y a intervalos de tiempo. El control de estas temperaturas es indispensable para obtener unas bobinas con características adecuadas (Martínez, 2006).

Después del ciclo de recocido, se realiza el galvanizado a través de la inmersión en un pote con zinc, recubriendo la banda por adherencia con una capa de espesor uniforme. El sistema empleado en líneas de galvanizado de este tipo instaladas en el mundo es el control por cuchillas de aire. Sobre la banda inciden dos chorros de aire que eliminan el zinc sobrante devolviéndolo al pote. Con el fin de evitar defectos superficiales, tras el enfriamiento de la banda, ésta es sometida a un tratamiento químico (Martínez, 2006).

Resumiendo, la calidad del producto se puede focalizar en dos aspectos fundamentales:

- En cuanto a las propiedades del acero, depende fundamentalmente de: la composición del acero, el proceso de fundición, los procesos de laminación y el ciclo de recocido.
- En cuanto a las características anticorrosivas, viene marcada por el espesor del recubrimiento de zinc y por la uniformidad del mismo, y depende básicamente de: la preparación superficial del metal base, el control de la temperatura de recubrimiento y homogeneización de la misma, la composición del baño, el control de las cuchillas de aire y velocidad de la banda.

De esta forma, tal como se ha comentado anteriormente, las propiedades finales del acero y el grado de adherencia del espesor de la capa de zinc, van a estar influenciadas por el grado de efectividad con que se aplique el ciclo térmico para cada tipo de bobina.

2.2.6 Base de datos

La base de datos está compuesta por la información registrada en un sensor de temperatura ubicado a la salida del horno de la línea de galvanizado continuo por inmersión. Se disponen de registros de temperatura de referencia, TMPP2C, es decir la temperatura deseada que debe tener la banda a la salida de la zona de calentamiento, y la temperatura medida, TMPP2M, es decir, la temperatura medida de la banda de acero a la salida del horno.

Estos registros serán considerados como las series temporales a analizar. Las series temporales están constituidas por 1979 muestras, resultado de promediar las medidas realizadas cada 100 metros de banda para cada bobina en la zona de control del horno. Estos datos corresponden a datos relativos a 35 días del proceso de galvanizado continuo por inmersión. La longitud aproximada de las bobinas es entre 350 y 5538 metros. Los espesores de las láminas oscilan en el rango 0.430 mm a 2 mm.

A continuación se describen las variables de la base de datos utilizada:

- CODBOBINA código numérico que identifica cada bobina.
- TMPP2M valor entero que representa la temperatura media de la banda medida a la salida de la zona de calentamiento del horno.
- TMPP2C valor entero que representa la temperatura esperada de la banda a la salida de la zona de calentamiento del horno.
- VELOCIDADFIN valor entero, que representa la velocidad medida de la banda en el centro del horno en metros por minuto.
- ESPESOR valor decimal que representa el espesor de la banda de acero medido a la salida en milímetros.

Para una visualización de lo anteriormente descrito, en la Tabla 2.1 se muestra una parte de la estructura física de la base de datos usada en este trabajo.

Luego en las Figuras 2.5 y 2.6 se muestra la dinámica real de las variables ESPESOR y VELOCIDADFIN. Adicionalmente, en la Figura 2.7 se muestra la matriz de dispersión y correlaciones lineales de las variables.

	A	B	C	D	E
1	CODBOBINA	TMPP2M	TMPP2C	ESPESOR	VELOCIDADFIN
2	23293006	754	750	0.600000023841858	145
3	23293007	749	750	0.600000023841858	145
4	23293008	761	770	0.600000023841858	138
5	23293009	755	750	0.600000023841858	145
6	23293010	752	750	0.600000023841858	105
7	23293011	753	750	0.600000023841858	132
8	23293012	786	794	0.600000023841858	131
9	23293013	830	825	0.600000023841858	100
10	23293014	830	825	0.600000023841858	80
11	23293015	826	825	0.600000023841858	80
12	23293016	824	825	0.600000023841858	80
13	23293017	821	825	0.600000023841858	89
14	23293018	823	825	0.600000023841858	90
15	23293019	822	821	0.600000023841858	81
16	23293020	789	789	0.600000023841858	98
17	23293021	780	780	0.600000023841858	115
18	23293022	774	780	0.600000023841858	120
19	23293023	791	824	0.600000023841858	120
20	23293024	814	825	0.600000023841858	120
21	23293025	823	825	0.600000023841858	120
22	23293026	810	800	0.600000023841858	120
23	23293027	803	800	0.600000023841858	120
24	23293028	802	800	0.600000023841858	120
25	23293029	803	800	0.600000023841858	120
26	23293030	803	800	0.600000023841858	120
27	23293031	804	800	0.600000023841858	120

Tabla 2.1: Estructura física de la Base de Datos

En la base de datos completa se encuentran todos los registros de las temperaturas de referencia y medidas durante el proceso de galvanizado. Con más detalles en las Figuras 2.2 y 2.3 se muestra la dinámica real de las variables TMPP2C y TMPP2M.

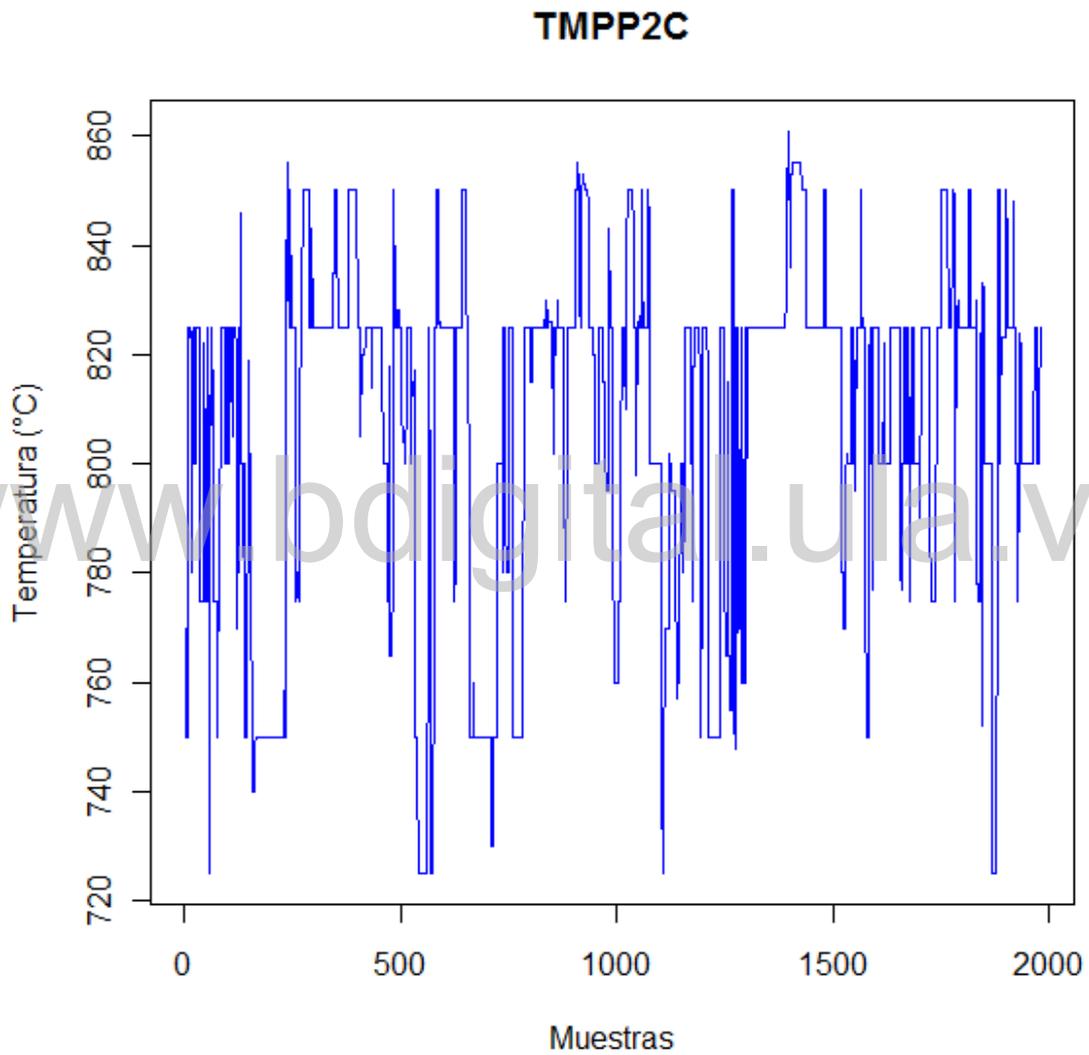


Figura. 2.2: Registro de la temperatura TMPP2C en la zona de salida del horno

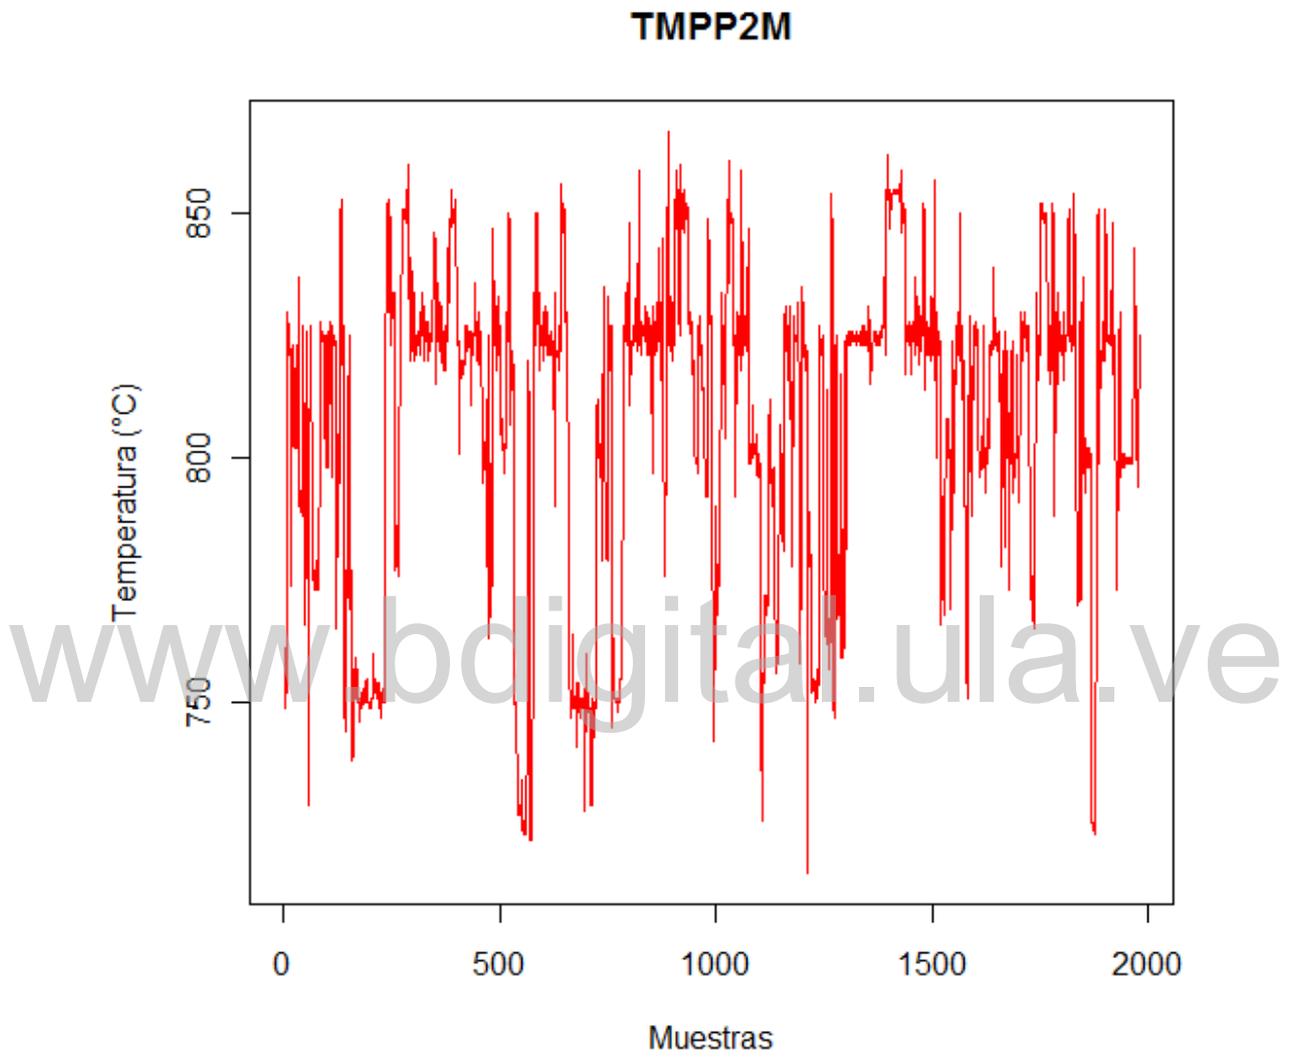


Figura. 2.3: Registro de la temperatura TMPP2M en la zona de salida del horno

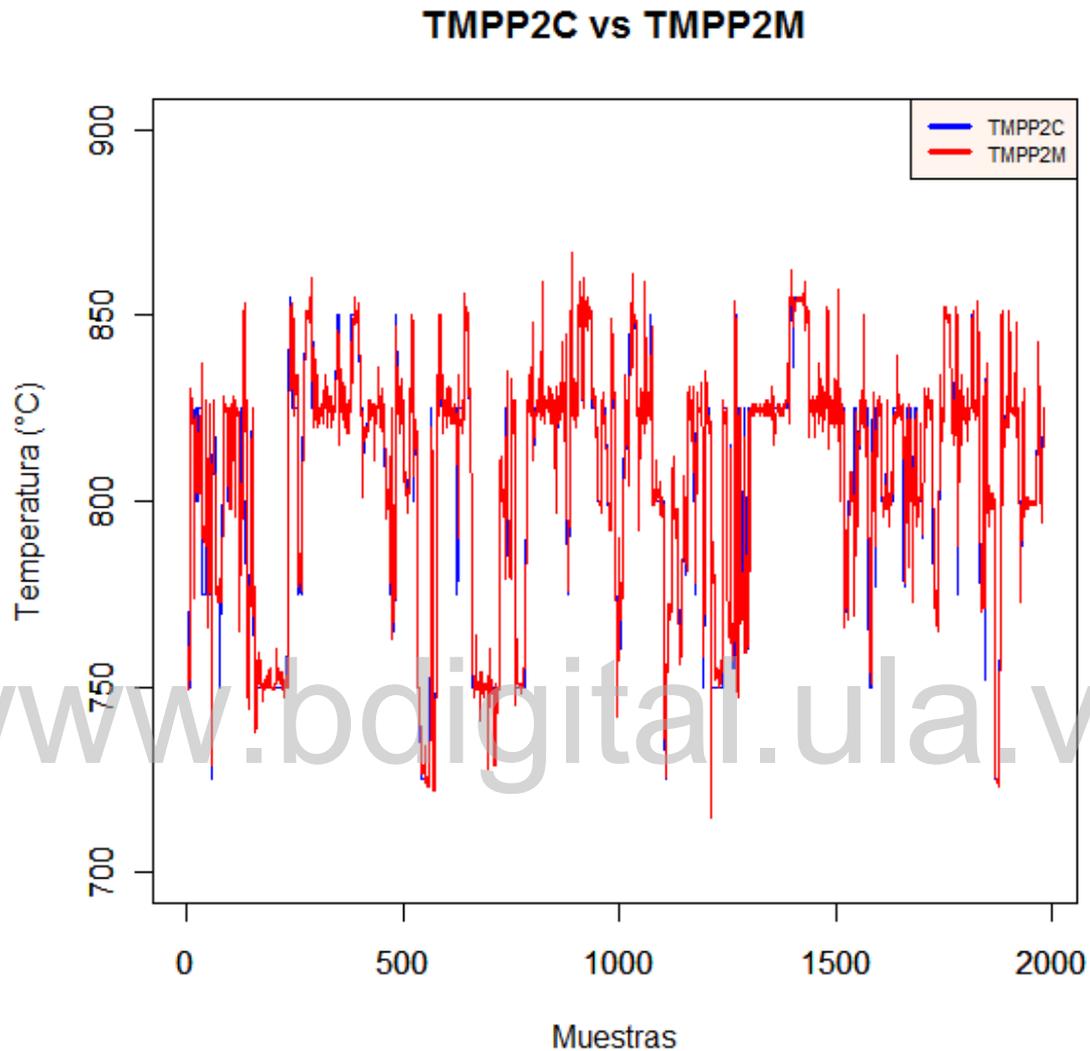


Figura. 2.4: Series temporales de la temperatura de referencia (TMPP2C) y temperatura medida (TMPP2M) a la salida del horno (N=1.979 muestras). Se puede observar claramente la diferencia entre ambas temperaturas a la salida del horno.

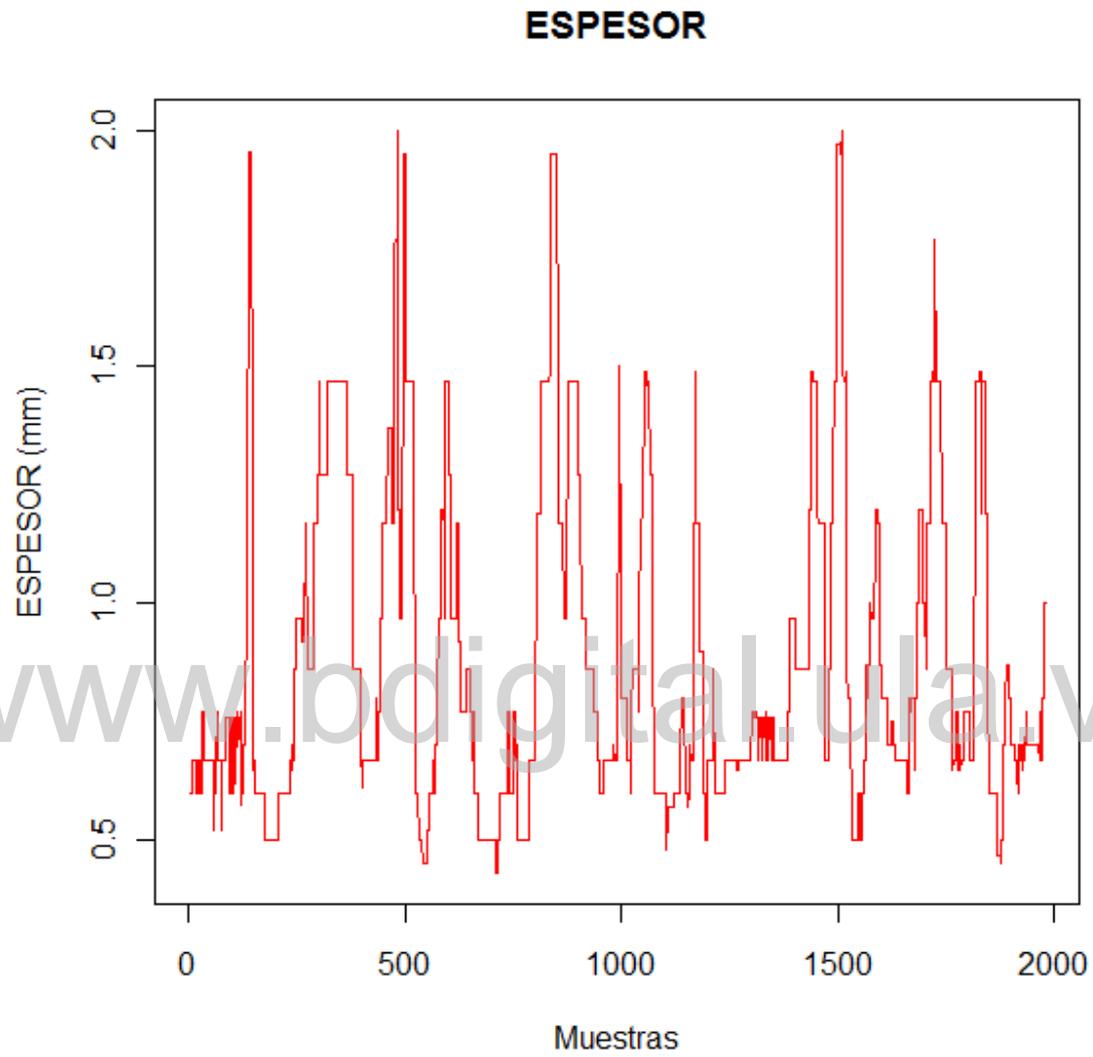


Figura. 2.5: Registro del Espesor en la zona de salida del horno

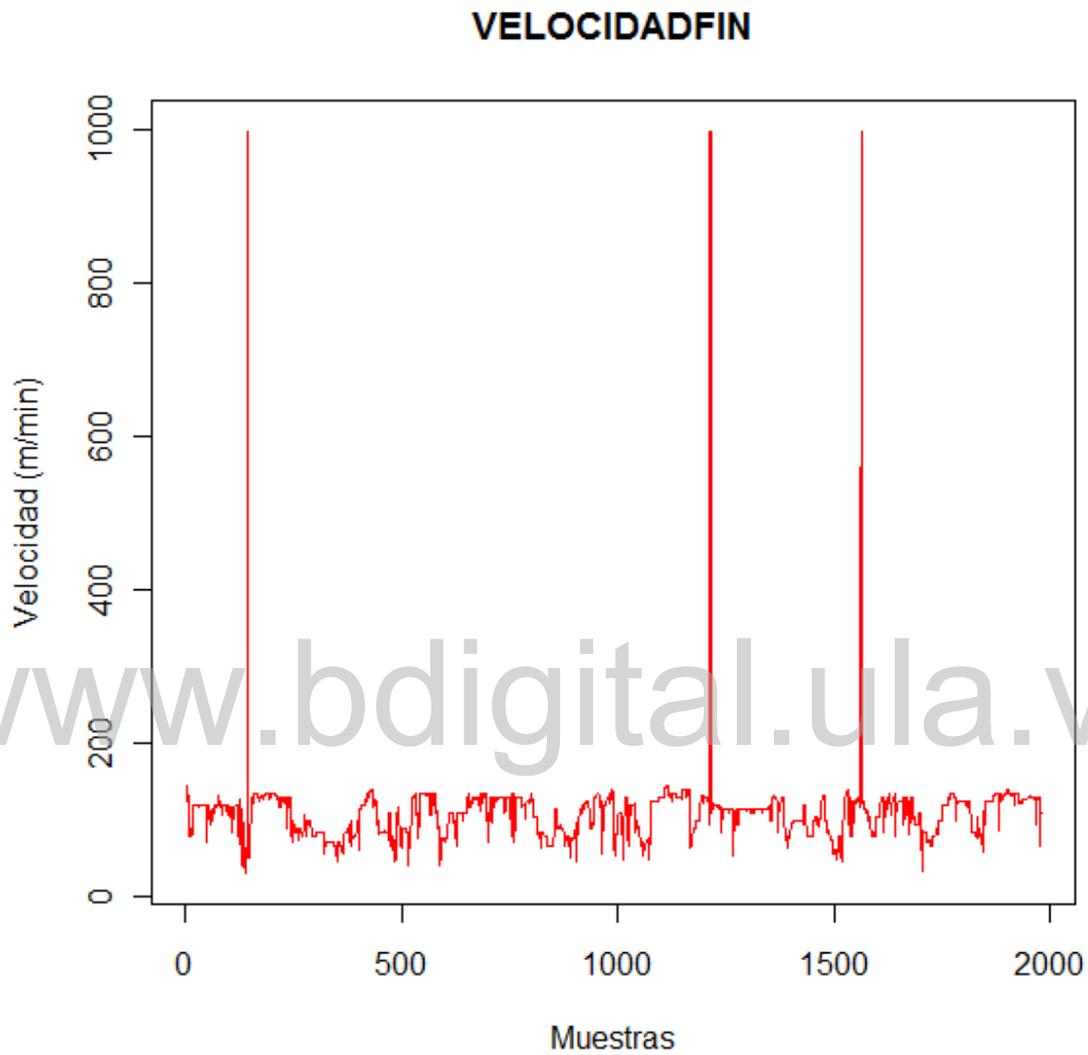


Figura. 2.6: Registro de la Velocidad en la zona de salida del horno. Se pueden observar los espurios en la serie temporal.

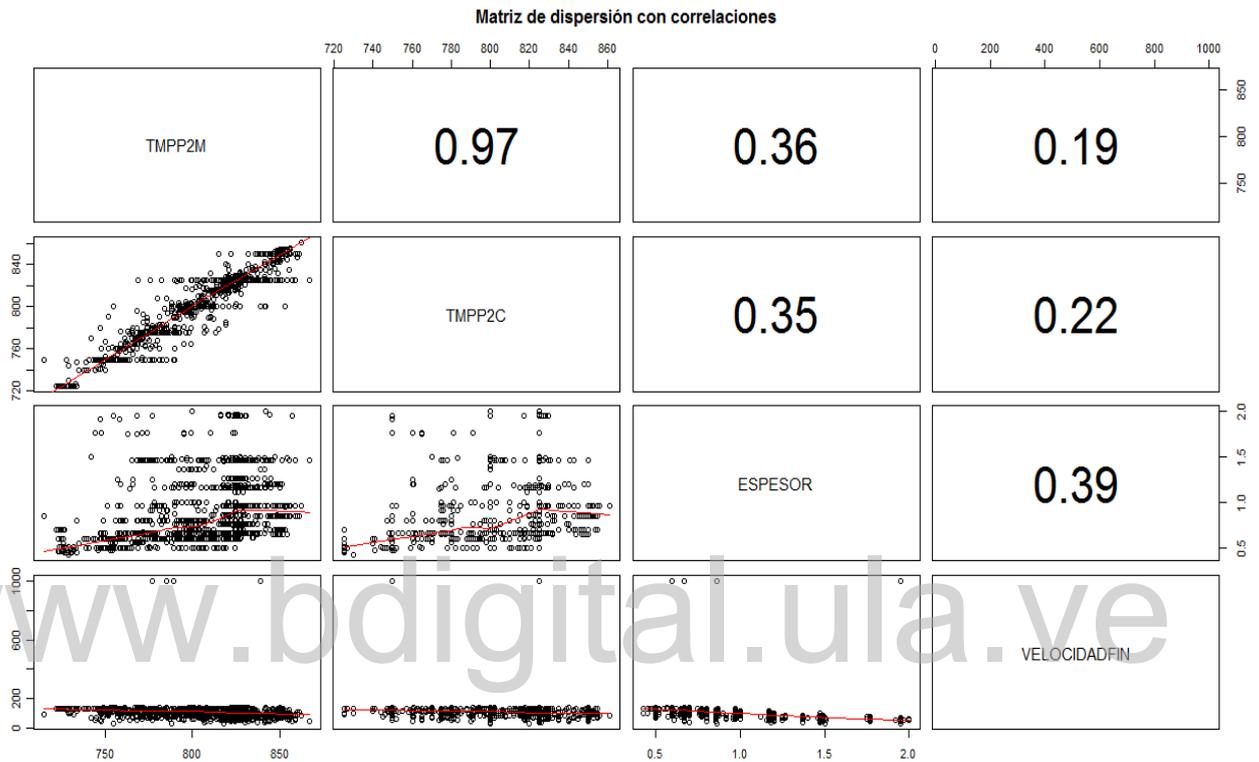


Figura. 2.7: Matriz de Dispersión de las variables con Correlaciones Lineales.

En la Figura 2.7 se puede apreciar que existe una alta correlación entre la Temperatura de Referencia y la Temperatura Medida, esto es debido a que físicamente estas dos temperaturas están vinculadas, ya que la Temperatura de Referencia obedece un modelo matemático con parámetros físicos del proceso y especificaciones de las bobinas y la Temperatura Medida expresa que el modelo que se plantea del proceso de galvanizado es consistente con la física inherente.

2.3 Minería de datos

La minería de datos es un conjunto de metodologías y herramientas que permiten, generalmente a partir de grandes cantidades de datos, extraer el conocimiento útil, ya sea patrones de comportamiento, modos de operación, información útil para descubrir fallos, tendencias ocultas, etc., que sirva de ayuda en la toma de decisiones, comprensión y mejora de sistemas o procesos, mejora de calidad, reducción de gastos, optimización, etc.

Para alcanzar buenos resultados es necesario comprender que la minería de datos no se basa en una metodología estándar y genérica que resuelve todo tipo de problemas, sino que consiste en una metodología dinámica e iterativa que va a depender del problema planteado, de la disponibilidad de la fuentes de datos, de las aptitudes de las personas que la realizan, del conocimiento y eficiencia de las técnicas necesarias y de los requerimientos y recursos de la empresa (Martínez, 2006).

La minería de datos (DM, Data Mining) consiste en la extracción no trivial de información que reside de manera implícita en los datos. Dicha información era previamente desconocida y podrá resultar útil para algún proceso. En otras palabras, la minería de datos prepara, sondea y explora los datos para sacar la información oculta en ellos (Wikipedia, 2004).

Bajo el nombre de minería de datos se engloba todo un conjunto de técnicas encaminadas a la extracción de conocimiento procesable, implícito en las bases de datos. Está fuertemente ligado con la supervisión de procesos industriales, ya que resulta muy útil para aprovechar los datos almacenados en las bases de datos. Las bases de la minería de datos se encuentran en la inteligencia artificial y en el análisis estadístico. Mediante los modelos extraídos utilizando técnicas de minería de datos se aborda la solución a problemas de predicción, clasificación y segmentación.

Capítulo 3

Metodología

En el presente capítulo se explica de manera detallada los aspectos fundamentales sobre máquinas vectoriales de soporte en regresión. Así mismo la forma en que dicha técnica es aplicada para resolver el problema en estudio.

3.1 Introducción a las MSV

Las Máquinas de Vectores de Soporte (MVS), también conocidas como máquinas de soporte vectorial, representan una técnica de clasificación y predicción basada en aprendizaje supervisado y no supervisado que ha estado ganando popularidad en los últimos años.

Sus fundamentos teóricos se basan en las teorías de aprendizaje estadístico desarrolladas por Vapnik y otros autores a finales de los 70 y principios de los 80, pero no es hasta la década de los 90 que se presenta el modelo formal de las MVS como se conoce hoy día, para así poder comenzar a aplicarlas en problemas reales de reconocimiento de patrones, demostrando su gran desempeño, introduciéndose como una herramienta poderosa para la resolución de problemas de clasificación (Orallo J., 2004).

Hoy en día, las MVS pueden ser utilizadas para resolver problemas tanto de clasificación como de regresión, gracias a que incluyen aspectos y técnicas del aprendizaje automático, estadístico, análisis funcional y optimización.

Algunas de las aplicaciones de clasificación o reconocimiento de patrones que se han realizado con esta técnica son las siguientes: reconocimiento de firmas, reconocimiento de imágenes y aplicaciones de regresión que incluyen predicción de series de tiempo.

Las MVS han sido desarrolladas como una técnica robusta para clasificación y regresión para grandes conjuntos de datos complejos, la aplicación de otras técnicas aumentan la posibilidad de error en los resultados ya que les resulta difícil cuantificar y observar gran cantidad de datos. (Orallo J., 2004)

La robustez de las MVS se debe a sus características principales, el alto nivel de generalización y las funciones kernel, las cuales permiten identificar correctamente observaciones no conocidas y manejar datos no lineales sin necesidad de que se requiera conocer algún algoritmo no lineal explícito.

La formulación matemática de las Máquinas de Vectores Soporte varía dependiendo de la naturaleza de los datos, ya que existen formulaciones para casos lineales y para casos no lineales.

3.2 Ventajas de las MVS

Las MVS poseen características importantes que las han puesto en ventaja respecto a otras técnicas populares de clasificación y/o regresión, una de estas características es que las MVS pertenecen a las disciplinas de aprendizaje automático o aprendizaje estadístico, donde la idea fundamental de este tipo de aprendizaje es hacer que las máquinas puedan ir aprendiendo, por medio de ejemplos, las salidas correctas para determinadas entradas, sin necesidad de conocer la naturaleza o distribución de los datos con que se desea trabajar.

Cuando las MVS son entrenadas con pares de datos entrada/salida el aprendizaje es conocido como aprendizaje supervisado, debido a que dichos pares generalmente reflejan una relación funcional que mapea las entradas a las salidas, estos pares de datos se conocen como conjunto de entrenamiento.

Es importante destacar que esta característica permite obviar gran parte del trabajo del diseño y programación inherente a ciertas metodologías tradicionales.

Algunos autores como Gunn (1998) afirman que las MVS están ganando popularidad debido a sus tantas características atractivas, entre las cuales destaca la incorporación del principio de Minimización de Riesgo Estructural, el cual ha demostrado ser superior al principio tradicional de Minimización de Riesgo Empírico empleado por redes neuronales y otros métodos lineales convencionales, ya que minimiza un límite superior de riesgo esperado, mientras que el principio tradicional de minimización de riesgo empírico minimiza el error en los datos de entrenamiento, esta diferencia dota a las MVS con una mayor habilidad para generalizar, es decir, tener una alta capacidad de pronóstico para nuevas observaciones.

Otras de las características de las MVS es que existen pocos parámetros a ajustar, debido a que el modelo sólo depende de los datos con mayor información, la estimación de los parámetros se realiza a través de la optimización de una función de costo, lo cual evita la existencia de un mínimo local, y la solución de las MVS es esparcida, donde la mayoría de las variables son cero en la solución, lo que implica que el modelo final puede ser escrito como una combinación de un número muy pequeño de vectores de entrada llamados vectores de soporte.

3.3 Definiciones básicas de las MVS

Para poder comprender a cabalidad el funcionamiento teórico y matemático de las MVS es necesario tener claro las siguientes definiciones:

3.3.1 Dimensión VC

La dimensión VC (Vapnik-Chervonenkis) es un concepto fundamental dentro de la teoría de aprendizaje estadístico la cual se define como el máximo número de puntos que puede separar de manera óptima cierto algoritmo de clasificación, es decir representa la capacidad de ciertas funciones

para separar un conjunto de datos (puntos) de entrenamiento. De esta manera, si la dimensión VC es h , existe por lo menos un conjunto de h puntos que pueden ser separados (Gunn S., 1998).

3.3.2 Maximización del margen

La maximización del margen es la idea que corresponde con exactitud a la aplicación del principio de Minimización de Riesgo Estructural. La maximización del margen, definido como la distancia de las muestras de entrenamiento a la frontera de decisión, se refiere a la selección del hiperplano separador que está a la misma distancia de los ejemplos más cercanos de cada clase.

Carreras, Márquez y Romero (2004) señalan que lo anterior es equivalente a decir que se debe encontrar el hiperplano separador que está a la misma distancia de los ejemplos más cercanos de cada clase, donde los ejemplos se refieren a los datos utilizados para el entrenamiento. Además, mencionan que dicho hiperplano sólo considera los vectores soporte, es decir, aquellos puntos que están en las fronteras de la región de decisión, que es la zona donde puede haber dudas sobre a qué clase pertenece un ejemplo.

El modelo más simple de las MVS, conocido como clasificador de margen máximo, funciona sólo para datos linealmente separables en el espacio de características, por lo que no puede ser usado en muchas aplicaciones de la vida real. Sin embargo, tal como lo afirman Cristianini y Shawe-Taylor (2000), es el algoritmo más fácil de aprender y forma la base fundamental para MVS más complejas.

En la figura 3.1 se muestra geoméricamente el hiperplano de margen máximo. La maximización del margen se encuentra dentro de la teoría de aprendizaje estadístico, específicamente dentro del principio de minimización de riesgo estructural.

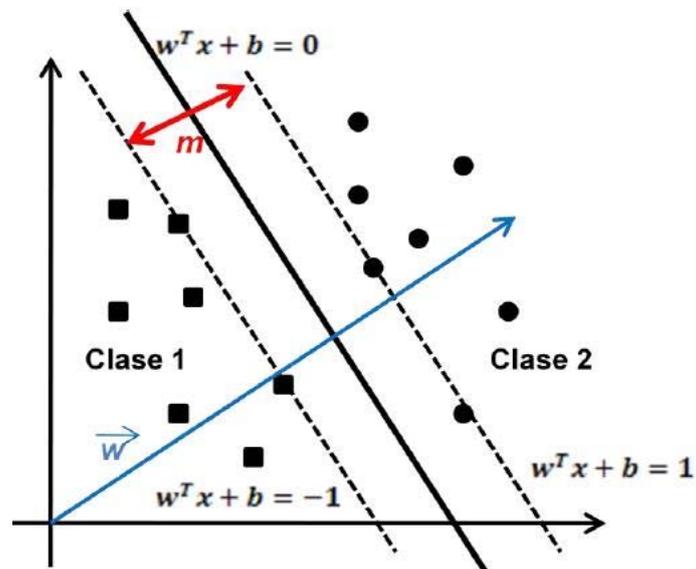


Figura 3.1. Hiperplano de margen máximo

3.4 MVS para el caso lineal

Las MVS lineal con margen máximo es el modelo más sencillo de clasificación de esta técnica y el que tiene menos condiciones de aplicabilidad debido a que parte del supuesto de que el conjunto de entrada es linealmente separable en el espacio de entrada, es decir, que los ejemplos pueden ser separados por un hiperplano de tal forma, que en cada lado del mismo, sólo queden ejemplos de una misma clase sin hacer ninguna transformación de los datos, como se puede observar en la Figura 3.2. Matemáticamente, esto es equivalente a decir que existe un hiperplano $h: x \in \mathbb{R}$ tal que $h(x) > 0$ para los ejemplos de la clase +1 y $h(x) < 0$ para los ejemplos de la clase -1.

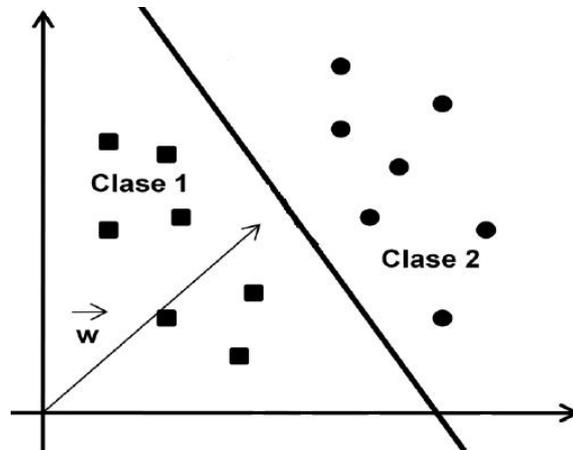


Figura 3.2. Caso linealmente separable

La distancia de un vector x a un hiperplano h , definido por (ω, b) como $h(x) = \langle \omega, x \rangle + b$, viene dada por la fórmula $\text{dist}(h, x) = |h(x)| / \|\omega\|$, donde $\|\omega\|$ es la norma R^D asociada al producto escalar. Así pues, el hiperplano equidistante a dos clases es el que maximiza el valor mínimo de $\text{dist}(h, x)$ en el conjunto de datos.

Como el conjunto es linealmente separable, se puede reescalar w y d de manera que la distancia de los vectores más cercanos al hiperplano sea $1 / \|\omega\|$, (Carreras et al. 2004). Así, el problema de encontrar el hiperplano equidistante a dos clases se reduce a encontrar la solución al siguiente problema de optimización con restricciones:

$$\text{Maximizar } \frac{1}{\|\omega\|} \tag{3.1}$$

$$\text{sujeto a: } y_i(\langle \omega, x_i \rangle + b) \geq 1$$

$$1 \leq i \leq N$$

Escrito de otra manera, el problema puede ser resuelto a través de la siguiente formulación:

$$\begin{aligned} & \text{Maximizar } \frac{1}{2} \langle \omega, \omega \rangle \\ & \text{sujeto a: } y_i (\langle \omega, x_i \rangle + b) \geq 1 \\ & \qquad \qquad \qquad 1 \leq i \leq N \end{aligned} \tag{3.2}$$

Como se puede observar, es un problema de optimización, consistente en minimizar una función cuadrática bajo restricciones en forma de desigualdad lineal.

3.5 MVS para el caso no lineal

En los problemas de clasificación ó regresión que se encuentran en la vida real es común que la naturaleza de los datos no sean linealmente separables, es decir que se comportan como en la Figura 3.3, es por ello que las MVS proponen una manera para resolver este tipo de problemas mediante una transformación no lineal del espacio de atributos de entrada en un espacio de características mucho mayor, donde sí es posible separar linealmente los problemas a través de las llamadas funciones núcleos o kernels, las cuales calculan el producto escalar de dos vectores en el espacio de características sin necesidad de calcular de forma explícita las transformaciones de los ejemplos de aprendizaje.

Las MVS tienen dos formas de tratar los datos en el caso no lineal, la primera, cuando los datos pueden ser separables con margen máximo pero en un espacio de características y, la segunda, cuando no es posible separar dichos datos linealmente incluso en un espacio de características. Ambos casos se explicarán en las subsecciones siguientes.

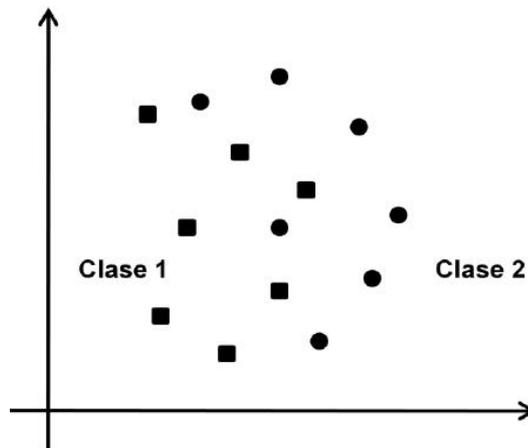


Figura 3.3. Caso no linealmente separable

3.5.1 MVS con margen máximo en el espacio de características

Algunas veces los datos, debido a su naturaleza, no pueden separarse por medio de un hiperplano óptimo, por lo que, se utilizan las MVS con margen máximo en el espacio de características, las cuales a través de una transformación no lineal del espacio de entrada permitan una separación lineal de los datos en un espacio de características y en este espacio se pueden aplicar los mismos razonamientos que para las MVS lineal con margen máximo. Si bien, la dimensión del espacio de características para poder separar un conjunto de datos puede ser muy grande, existe una forma muy efectiva de calcular el producto escalar en ciertos espacios de características y en ciertas transformaciones usando las denominadas funciones núcleos.

Como se puede observar en la Figura 3.4, utilizando esta técnica se puede pasar de un problema donde los datos no se pueden separar linealmente a uno donde si se puedan separar linealmente.

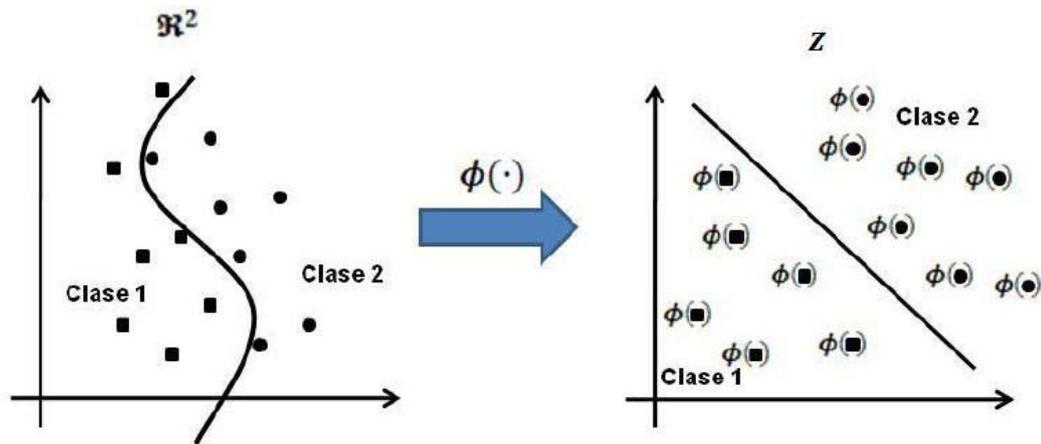


Figura 3.4. Transformación del espacio de entrada mediante el uso de un Kernel.

Una función núcleo o kernel es aquella que permite realizar una separación de los datos en el espacio de características. En términos matemáticos, un kernel es una función $K: X \times X \rightarrow \mathbb{R}$ tal que $k(x, y) = \langle \phi(x), \phi(y) \rangle$, donde ϕ es una transformación de X en un cierto espacio de Hilbert \mathfrak{H} . Existen diversos kernels entre los cuales se pueden destacar el lineal, la Función de Base Radial (RBF), el polinomial, el sigmoideal, entre otros, en la Tabla 3.1 se observa la función que representa a cada uno de estos kernels así como también los parámetros a ajustar.

Carreras et al. (2004) señalan que lo interesante de usar funciones núcleo con MVS es que el producto escalar se puede calcular implícitamente, sin conocer de manera explícita \mathfrak{H} ni la transformación ϕ y evitando el coste computacional derivado de la posible alta dimensionalidad de \mathfrak{H} .

Una vez definida la función núcleo y de conocer cuál es su objetivo se procede a especificar el problema de optimización a resolver para las MVS con margen máximo en el espacio de características. El problema de programación cuadrática con restricciones a resolver es el que se presenta a continuación:

$$\text{Maximizar } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j K(x_i, x_j)$$

(3.3)

$$\text{sujeto a: } \sum_{i=1}^N y_i \alpha_i = 0$$

$$\alpha_i \geq 0, \quad 1 \leq i \leq N$$

Donde $K(x, y)$ es la función núcleo.

3.5.2 MVS con margen blando

Las MVS con margen blando se utilizan en aquellos casos en los cuales no es posible encontrar una transformación de los datos que permitan separarlos linealmente en el espacio de entrada ni en el espacio de características a través de una función núcleo.

Este enfoque también es necesario cuando los datos se pueden separar linealmente en el espacio de características pero las soluciones son sobreajustadas a los ejemplos, y por lo tanto se tiende a tener una mala generalización.

La característica más resaltante de las MVS con margen blando es que son capaces de tratar conjuntos de datos no linealmente separables y con ruido, ya que son modelos más robustos que las MVS con margen máximo.

Las MVS con margen blando introducen variables de holgura al modelo, permitiendo que ciertos datos violen con cierto margen las restricciones, pero a su vez tiende a tener una mejor generalización. Estas variables de holgura vienen dadas por un vector que tiene la misma dimensión del conjunto de datos, pues para cada instancia de datos se tendrá su respectiva variable de holgura, cuyo valor será siempre positivo o igual a cero.

Al introducir variables de holgura a las restricciones en el modelo debe incluirse en la función objetivo el parámetro C , el cual puede ser definido como un parámetro de regularización. Este es el

único parámetro libre de ser ajustado en la formulación de la MVS. El ajuste de este parámetro puede hacer un balance entre la maximización del margen y la violación a la clasificación.

Con esto, el problema a optimizar es similar al de los modelos de margen máximo, la diferencia reside en que en el modelo con margen blando la función objetivo dependerá del parámetro C y de las variables de holgura, así como también, cada restricción contendrá las respectivas variables de holgura y se incluirá una nueva restricción que limita el valor del parámetro C.

A continuación se procede a especificar el problema de optimización a resolver para las MVS con margen máximo.

$$\begin{aligned}
 & \text{Minimizar } \frac{1}{2} \langle \omega, \omega \rangle + C \sum_{i=1}^N \xi_i \\
 & \text{sujeto a: } y_i (\langle \omega, x_i \rangle + b) \geq 1 - \xi_i, \quad 1 \leq i \leq N \\
 & \text{sujeto a: } \xi_i \geq 0, C \gg 0 \quad 1 \leq i \leq N
 \end{aligned}
 \tag{3.4}$$

3.6 Máquinas Vectoriales de Soporte en Regresión

La técnica de MVS-R es utilizada para determinar el valor de una variable dependiente que está en función de otras denominadas independientes o explicativas, buscando la mejor función que determine esta variable.

Supongamos que se nos ha dado un conjunto de datos para entrenamiento $T = \{(x_i, y_i), i=1, \dots, I\}$ donde $x \in \mathbb{R}$ y $y \in \mathbb{R}$. De esta manera podemos construir una función de regresión lineal como:

$$F(x) = \omega^T \phi(x) + b
 \tag{3.5}$$

en un espacio de características Z . Donde ω es un vector en Z y Φ mapea los puntos de entrada x , a un vector en Z , ($\Phi(x_i) = Z_i$). El vector W y la constante b en la ecuación anterior son obtenidos mediante el uso de la siguiente función de pérdida ε -sensible de Vapnik:

$$|y - f(x, \omega)|_\varepsilon = \max\{0, y - f(x, \omega) - \varepsilon\}$$

donde

$$\left\{ \begin{array}{ll} |y - f(x, \omega)|_\varepsilon = 0 & \text{si } |y - f(x, \omega)| \leq \varepsilon \\ |y - f(x, \omega)| - \varepsilon & \text{en otro caso} \end{array} \right. \quad (3.6)$$

Si la función de pérdida es cero, la discrepancia entre el valor de la predicción y el observado es menor a ε . Es decir, sólo los patrones que se encuentren fuera del margen generado por $f(x) \pm \varepsilon$, serán penalizados.

Ahora, para ajustar mejor la función de regresión, se ingresan variables de holgura, que penalizarán aquellos puntos que se encuentren fuera de los márgenes, de manera que el problema de optimización restringida asociado para el caso de estimación de funciones es

$$\text{Minimizar } \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*)$$

Sujeto a:

$$\left\{ \begin{array}{l} y_i - (\omega^T x_i) - b \leq \varepsilon + \xi_i \\ (\omega^T x_i) + b \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{array} \quad \forall i = 1, \dots, l \right. \quad (3.7)$$

Donde la constante $C \gg 0$ penalizan los datos que se encuentran fuera de los márgenes. Los criterios de optimización para este problema de programación cuadrática penalizan aquellos datos que se encuentran fuera del rango generado por $f(x) \pm \varepsilon$. Esta penalización se representa mediante las

variables de holgura ξ_i y ξ_i^* , que castigan esta desviación positiva y negativa respectivamente, tal como lo muestra la figura 3.5:

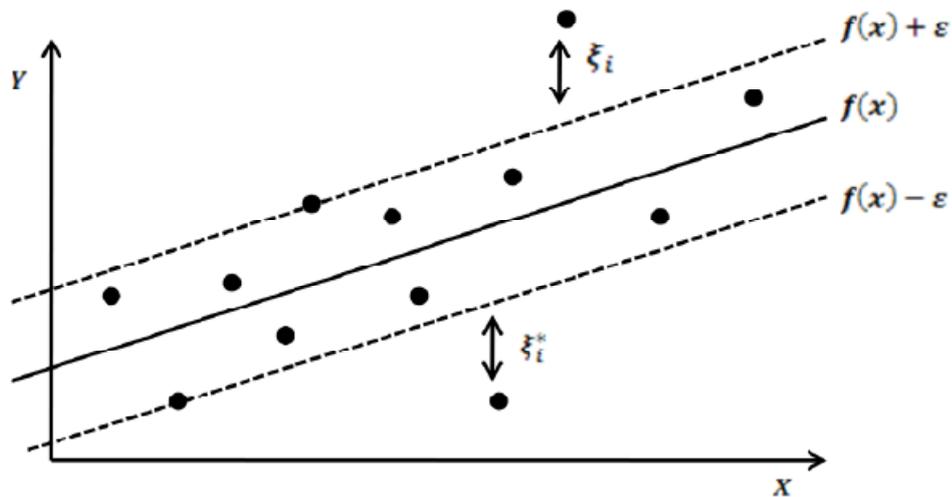


Figura 3.5: La función de pérdida ε -insensitiva de Vapnik y las variables de holgura ε_i y ε_i^* .

Para resolver el problema de programación cuadrática, se debe construir el siguiente Lagrangiano en su forma dual:

$$L - \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) + \sum_{i=1}^l (\xi_i \eta_i + \xi_i^* \eta_i^*) + \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i + y_i - (\omega^T Z_i) - b) - \sum_{i=1}^l \alpha_i^* (\varepsilon + \xi_i^* - y_i - (\omega^T Z_i) + b) \quad (3.8)$$

donde α , α^* , n y n^* son multiplicadores de Lagrange. Ahora, el problema a resolver es:

$$\begin{aligned} & \min_{\alpha, \alpha^*} D(\alpha, \alpha^*) \\ & \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l Q_{ij} (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) + \varepsilon \sum_{i=1}^l (\alpha_i - \alpha_i^*) - \sum_{j=1}^l Y_j (\alpha_i - \alpha_i^*) \\ & 0 \leq \alpha, \alpha^* \leq C \quad i = 1, \dots, l \end{aligned}$$

$$\sum_{j=1}^l (\alpha_j - \alpha_j^*) = 0$$

$$\alpha_j, \alpha_j^* \in [0, C] \tag{3.9}$$

donde

$$Q_{ij} = \phi(x_i)^T \phi(x_j) = Z_i^T Z_j = K(x_i, x_j)$$

De esta manera, y utilizando una función Kernel $K(x_i, x_j)$, podemos escribir la función de regresión como:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \tag{3.10}$$

Y la constante b puede ser encontrada utilizando las condiciones de Karush-Kuhn-Tucker.

3.7 Procedimiento para el ajuste de los parámetros del modelo

Para realizar los experimentos, se sigue el siguiente procedimiento:

- 1.- Fragmentación del conjunto de datos en dos, para entrenar y para validar.
- 2.- Ajuste del Kernel a utilizar.
 - a.- Se utilizaron los siguientes Kernel:

<i>Kernel</i>	<i>Función</i>	<i>Parámetros a Ajustar</i>
Líneal	$K(x, y) = x * y$	Ninguno
Polinomial	$K(x, y) = (g * x * y + coef)^d$	d: grado del polinomio
RBF	$K(x, y) = e^{-g * x - y ^2}$	g: gamma

Tabla 3.1: Tipos de Kernel utilizados para el ajuste.

- b.- Para realizar el ajuste de Kernel, se utilizan los valores por defecto $\epsilon = 0.1$ y $C = 1$ los cuales se ajustaron según correspondía.

3.- Ajuste de los parámetros

- a.- Costo de error C, que penaliza aquellos valores que se encuentran fuera de un rango predeterminado.
 - b.- Épsilon (ϵ), que determina el ancho del margen.

4.- Entrenar la máquina

Al entrenar la máquina, se determina el modelo a utilizar, es decir, se identifican el número de vectores de soporte y los parámetros correspondientes para el conjunto de entrenamiento.

5.- Se utiliza el modelo obtenido tras el entrenamiento, para poner a prueba la máquina, es decir, se contrastan los valores objetivos reales con los que entrenó la maquina, para determinar que tan precisa fue.

3.8 Salidas de la máquina

<i>Etapa</i>	<i>Salida</i>	<i>Descripción</i>
ENTRENAMIENTO	ϵ	Épsilon
	c	Costo de Error
	rho	Valor de b en la función objetivo
	nVS	Número de vectores de soporte
	VC PRECM	Porcentaje de la raíz del Error Cuadrático Medio de la Validación Cruzada
	VC CD	Coefficiente de Correlación Ajustado
VALIDACION	PRECM	Porcentaje de la raíz del Error Cuadrático Medio

Tabla 3.2: Salidas de la Máquina.

El Error Cuadrático Medio, en inglés, Mean Square Error (MSE), es una medida de la desviación entre el valor real y el que predice la máquina, por lo tanto, entre menor sea el error, mejor será la aproximación.

Posteriormente, se calcula el Porcentaje de la raíz del Error Cuadrático Medio dividiendo el Error Cuadrático Medio entre el promedio de los valores reales y multiplicando este resultado por cien, como se muestra a continuación:

$$PRECM = \sqrt{\frac{\sum_{i=1}^N |\theta_i - \theta_{i\text{obs}}|^2}{N}} \times \frac{100}{\theta_{i\text{obs}}} \quad (3.11)$$

En la fase de entrenamiento, para determinar el error del proceso, se utiliza la técnica de validación cruzada (n -fold Cross Validación). Este es un método en donde los datos de entrenamiento se dividen en n partes iguales, secuencialmente cada conjunto es probado utilizando un clasificador entrenado con los $n-1$ conjuntos restantes. De esta manera, todos los datos del conjunto de entrenamiento son predichos una vez, por ende, la validación cruzada es el porcentaje de ajuste de los datos que han sido correctamente clasificados.

3.9 Análisis de Correlación y Selección de las muestras

El primer paso fundamental es realizar un análisis de correlación entre las variables, ya que esto permite visualizar si posee sentido aplicar la metodología. Posteriormente, el siguiente paso para llevar a cabo estimaciones con MVS-R, al igual que con otras técnicas, se refiere a la selección de las muestras. Para esto es necesario determinar cuáles observaciones o conjunto de datos se utilizarán para el entrenamiento y cuáles para la validación. Dicha selección se puede hacer de manera aleatoria siempre y cuando se garantice que dentro de cada conjunto se esté incluyendo diversidad de los datos con los que se esté trabajando.

Cabe destacar que algunos software disponibles para clasificación con Máquinas de Vectores Soporte en Regresión brindan herramientas de selección de muestras de acuerdo a diferentes criterios.

3.10 Transformación de los datos al formato del software

Luego de haber seleccionado el software con el cual se procederá a realizar la clasificación, se deben transformar los datos al formato compatible con dicho software. El formato que deben tener los datos depende exclusivamente del programa que se utilizará, en este caso los datos están organizados en un archivo texto donde se tiene el nombre de las variables y su respectivo valor.

3.11 Entrenamiento

Una vez que se ha seleccionado el tipo de kernel óptimo de acuerdo a la naturaleza de los datos estudiados y los valores óptimos de los parámetros asociados, se puede proceder a hacer el entrenamiento formal de las MVS-R. La tarea de estimación involucra tanto entrenamiento como validación de instancias de datos. Así, lo que se hace en esta fase es especificar cuál es el conjunto de

datos que se usará para el entrenamiento, es decir, los datos que se le darán a las MVS-R para que ellas “aprendan” a predecir correctamente las instancias con el menor error de predicción posible.

3.12 Validación

La última fase de las MVS-R consiste en realizar las respectivas validaciones para medir el desempeño de la máquina, esta fase es la que permite medir la capacidad de estimación para nuevas observaciones, la cual es una de las características más atractivas de esta técnica. En este sentido, el objetivo que se busca es producir un modelo que permita predecir correctamente la clase a la que pertenece cada instancia.

Esta fase es de gran importancia ya que a partir de los resultados que se obtengan, se puede inferir sobre los mismos respecto a diferentes medidas de evaluación de desempeño de las MVS-R. Uno de los factores que se observa en esta etapa es la habilidad de los modelos probados para predecir correctamente instancias desconocidas. En otras palabras, lo que se hace es evaluar la efectividad de los parámetros seleccionados para producir estimaciones acertadas.

3.13 Interpretación de los resultados

Una buena interpretación de los resultados obtenidos a través de la aplicación de la técnica se hace fundamental pues sin ella el estudio pierde sentido. Siempre es necesario interpretar los resultados que se obtienen con la idea de darle significado a los valores obtenidos, para lo cual se requiere que el investigador conozca a fondo los datos que se están estudiando. El análisis de los resultados de las MVS-R incluye la identificación del error de predicción que se tiene con el modelo seleccionado. En muchos casos, la interpretación incluirá comparaciones con otras técnicas estudiadas con la intención de verificar la capacidad predictiva de las MVS-R.

3.14 Especificación de los recursos utilizados:

Para realizar las pruebas se utilizaron los siguientes elementos:

- Equipo HP Pavilion dv 6000 de 667 MHz con 2 Gb MRAM
- Librería e1071 desarrollada bajo el lenguaje de programación R (Chang, 2005).

Capítulo 4

Resultados

Este capítulo presenta los resultados obtenidos de la metodología MVS-R en la estimación de parámetros asociados al Proceso Industrial de Galvanizado. Se muestran las máquinas de estimación, los Kernel y los parámetros estimados, dejando ver así las relaciones entre los mismos y las posibles causas de las diferencias entre la Temperatura Medida y de Referencia. En primer lugar, se realizó la estimación de la Temperatura Medida a partir de la Velocidad final, el Espesor y la Temperatura de Referencia utilizando la base de datos completa ($n= 1.979$). En segundo lugar, se aplicó una técnica estadística para separar en umbrales los parámetros Espesor y Velocidad final y así observar los cambios en la estimación de la Temperatura Medida. En ambos casos de las 1.979 muestras, un 80% (1.583 muestras) son utilizadas para la fase de entrenamiento y un 20% (396 muestras) son utilizadas para la fase de validación.

4.1. Estimación de la Temperatura Medida a partir de la Velocidad final, el Espesor y la Temperatura de Referencia (n=1979).

4.1.1 Ajuste de kernel

KERNEL LINEAL		
ETAPA	SALIDA	
ENTRENAMIENTO	E	0.1
	C	1
	Rho	-0.000132
	nVS	637
	VC PRECM	7.2560
	VC CD	0.943
VALIDACION	PRECM	6.7196

Tabla 4.1: Kernel tipo Lineal para la TMPP2M utilizando MVS-R.

KERNEL POLINOMIAL				
Etapa	Salida	Parámetro: Grado del polinomio		
		2	3	4
ENTRENAMIENTO	ϵ	0.1	0.1	0.1
	c	1	1	1
	rho	-0.0112	-0.0278	0.000709
	nVS	619	635	645
	VC PRECM	7.3303	9.8013	11.096
	VC CD	0.942	0.0233	7.22e-05
VALIDACION	PRECM	6.6413	6.5126	6.5702

Tabla 4.2: Kernel tipo Polinomial para la TMPP2M utilizando MVS-R.

KERNEL RBF						
Etapa	Salida	Parámetro: Gamma				
		0.001	0.01	0.1	1	2
ENTRENAMIENTO		0.1	0.1	0.1	0.1	0.1
	c	1	1	1	1	1
	rho	0.0254	0.605	0.482	0.334	0.322
	nVS	818	633	635	654	645
	VC PRECM	7.9742	7.3551	7.4170	7.9618	8.0980
	VC CD	0.943	0.942	0.941	0.937	0.936
VALIDACION	PRECM	6.9524	6.6282	6.4970	6.6670	6.6757

Tabla 4.3: Kernel tipo RBF para la TMPP2M utilizando MVS-R.

4.1.1.1 Gráfico de los errores

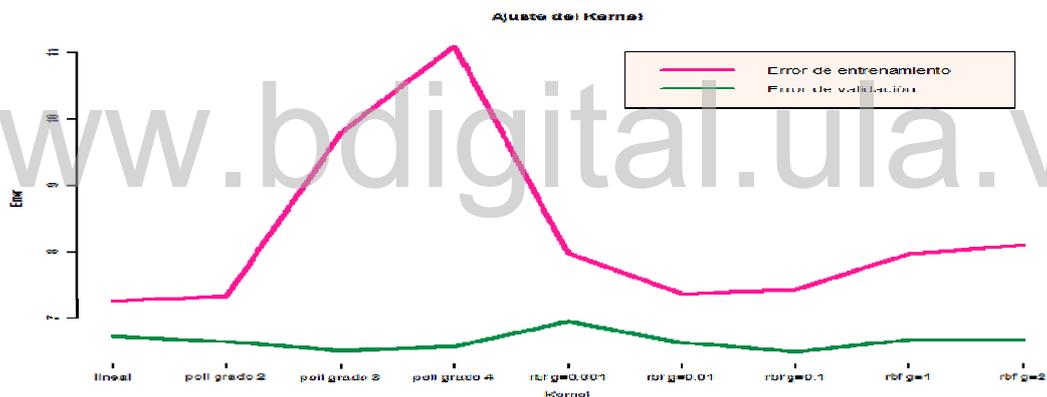


Figura 4.1: Errores para el Ajuste del Kernel

<i>Mínimo VC PRECM 7.2560</i>	<i>Lineal</i>
<i>Mínimo PRECM 6.4970</i>	<i>RBF, g=0,1</i>

Tabla 4.4: Mínimo MSE

En la Tabla 4.4, al comparar los mínimos errores de entrenamiento y validación, se observa que el menor PRECM corresponde a la fase de validación, es decir, los mejores valores se obtienen para el Kernel de Base Radial, sin embargo, a medida que aumenta el valor de gamma aumenta tanto el error de entrenamiento como el de validación. En la Figura 4.1 se observa el gráfico de los errores para el ajuste del Kernel dejando ver así cual Kernel posee el menor error y por consiguiente es el mejor para el problema.

Por consiguiente, para la siguiente etapa se seleccionó el Kernel RBF con gamma igual a 0.1.

4.1.2 Ajuste de los Parámetros: A continuación se ajustan los parámetros C y ϵ

4.1.2.1 Ajuste de C

AJUSTE DE PARAMETROS: C							
Etapa	Salida	C					
		0.01	0.1	1	10	100	1000
ENTRENAMIENTO	ϵ	0.1	0.1	0.1	0.1	0.1	0.1
	rho	0.266	0.391	0.482	0.538	0.966	1.6
	nVS	964	719	635	634	637	652
	VCPRECM	15.1064	8.2095	7.4418	7.4418	7.8875	8.5933
	VC CD	0.92	0.935	0.941	0.941	0.938	0.932
VALIDACION	PRECM	10.8821	7.2409	6.4970	6.4454	6.4922	6.6372

Tabla 4.5: Ajuste del parámetro C utilizando MVS-R.

4.1.2.1.1 Gráfico de los errores

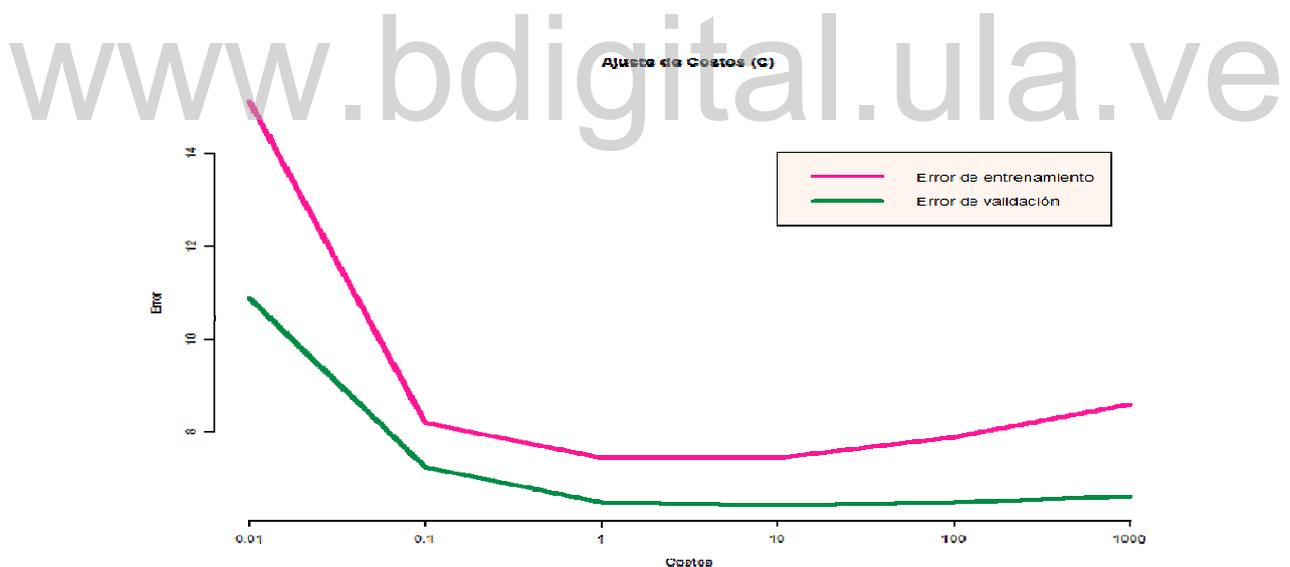


Figura 4.2: Errores para el Ajuste de C

Mínimo CV PRECM 7.4418	C= 10
Mínimo PRECM 6.4454	C= 10

Tabla 4.6: Mínimo MSE

Al comparar los mínimos PRECM, se puede observar que tanto el de entrenamiento como el de validación, siguen un patrón muy similar, encontrándose el mínimo cuando $C=10$.

4.1.2.2 Ajuste de

AJUSTE DE PARAMETROS: ϵ						
Etapa	Salida	ϵ				
		0.001	0.01	0.1	0.5	1
ENTRENAMIENTO	C	10	10	10	10	10
	rho	0.328	0.339	0.538	0.638	0.405
	nVS	1559	1452	634	86	19
	VCPRECM	7.4541	7.4541	7.4170	9.6334	21.2976
	VC CD	0.942	0.941	0.941	0.93	0.861
VALIDACION	PRECM	6.6082	6.6125	6.4454	7.4648	18.8576

Tabla 4.7: Ajuste del parámetro ϵ utilizando MVS-R.

4.1.2.2.2 Gráfico de los errores

www.bdigital.ula.ve

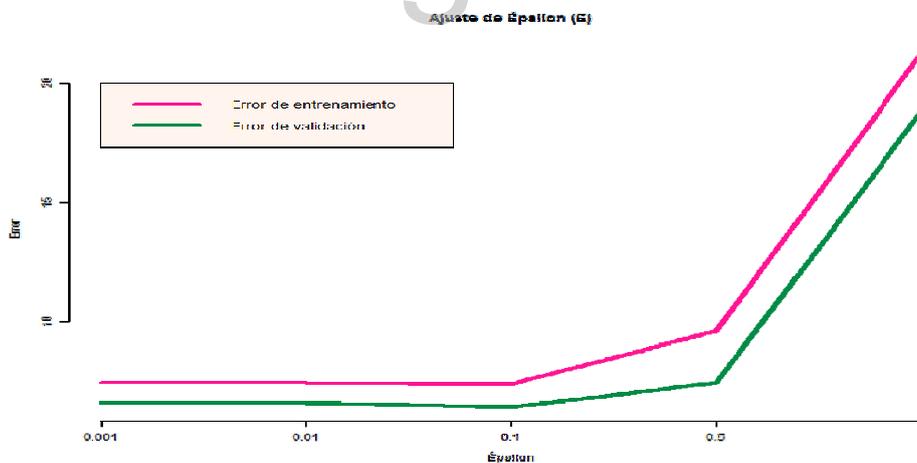


Figura 4.3: Errores para el Ajuste de ϵ

Figura 4.3: Errores para el Ajuste de ϵ

Mínimo VC PRECM 7.4170	$\epsilon = 0.1$
Mínimo PRECM 6.4454	$\epsilon = 0.1$

Tabla 4.8: Mínimo MSE

Obsérvese en la Tabla 4.8 y en la Figura 4.3, que al comparar los mínimos PRECM para las etapas de entrenamiento y validación, ambos se encuentran cuando ε es igual a 0.1.

A medida que ε se acerca hacia el valor uno, aumenta fuertemente tanto el error de entrenamiento como el de validación. También se ha de notar que, a medida que ε se hace muy pequeño, los dos errores van aumentando de forma lenta, formándose así un valle alrededor del valor mínimo que es 0.1. Es decir, el mejor ajuste que se puede realizar utilizando MVS-R da un error final de 6.44%. La configuración que arroja mejores resultados es la que posee el Kernel de Base Radial con parámetros $C=10$ y γ igual a 0.1 generando una precisión de instancias correctamente predichas de 94.10%. En la Figura 4.4 se presenta la Temperatura Medida y la Estimada por la mejor máquina.

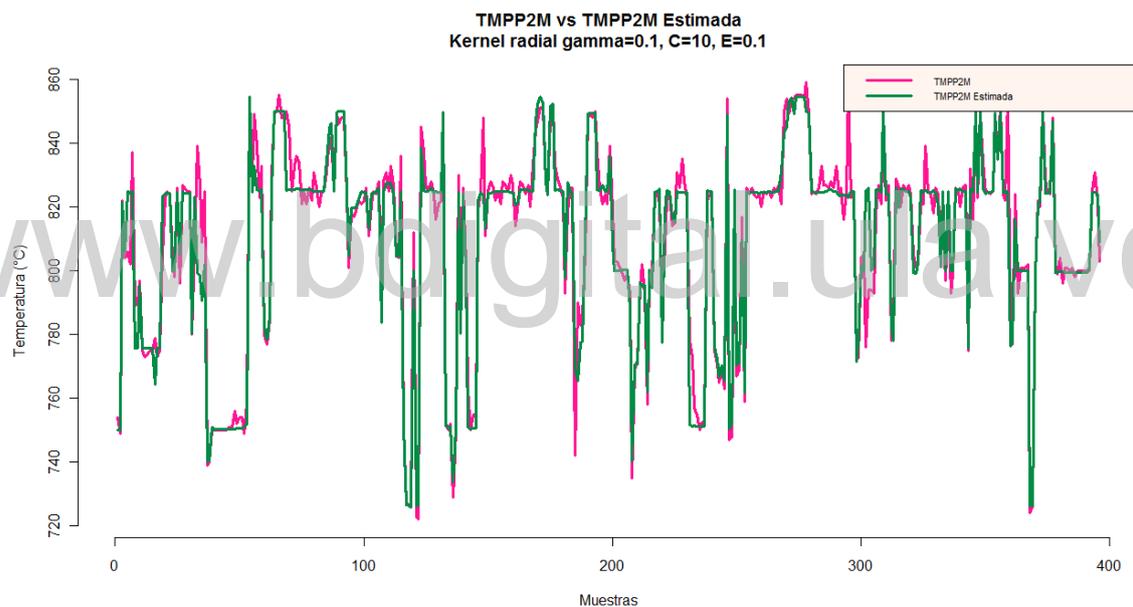


Figura 4.4: Óptimo ajuste utilizando MVS-R.

4.2 Estimación de la Temperatura Medida a partir de Temperatura de Referencia, la Velocidad y el Espesor (tomando el valor mínimo y el máximo de la Base de Datos)

La señal de referencia es determinada por parámetros de las bobinas como el Espesor y la Velocidad, donde la Velocidad de la bobina en el tren de laminado es controlada a partir del Espesor. Con este propósito se quiere investigar si los cambios observados en la Temperatura Medida están influenciados por el Espesor y la Velocidad. En vista de lo anterior, se procedió a dividir la Base de Datos en umbrales, tomando como límites la media y el mínimo valor de la Base de datos y la media y el máximo valor de la Velocidad y el Espesor, dando como resultado cuatro nuevas bases de datos: Espesor alto-velocidad baja (Ea_vb, n=197 observaciones), Espesor alto-velocidad alta (Ea_va, n= 45 observaciones), Espesor bajo-velocidad alta (Eb_va, n=776 observaciones) y Espesor bajo-velocidad baja (Eb_vb, n= 157 observaciones). A continuación se muestran los límites de los umbrales para el Espesor y la Velocidad.

Para la variable Espesor se tienen los siguientes índices:

La media: $\mu = 0.88$

El valor mínimo = 0.43

El valor máximo = 2.00

Y se definen los siguientes intervalos:

Espesor Bajo: [0.43; 0.88)

Espesor Alto: [0.88; 2.00]

En la Figura 4.24 se observan los intervalos definidos para el Espesor.

Seguidamente para la variable Velocidad:

La media: $\mu = 107.57$

El valor mínimo = 30

El valor máximo = 145

Y se definen los siguientes intervalos:

Velocidad Baja: [30; 107.57)

Velocidad Alta: [107.57; 145]

En la Figura 4.25 se aprecian los intervalos definidos para la Velocidad.

Seguidamente se procedió a estimar la TMPP2M en los intervalos definidos anteriormente, realizando combinaciones y haciendo uso de diferentes Kernel y parámetros asociados.

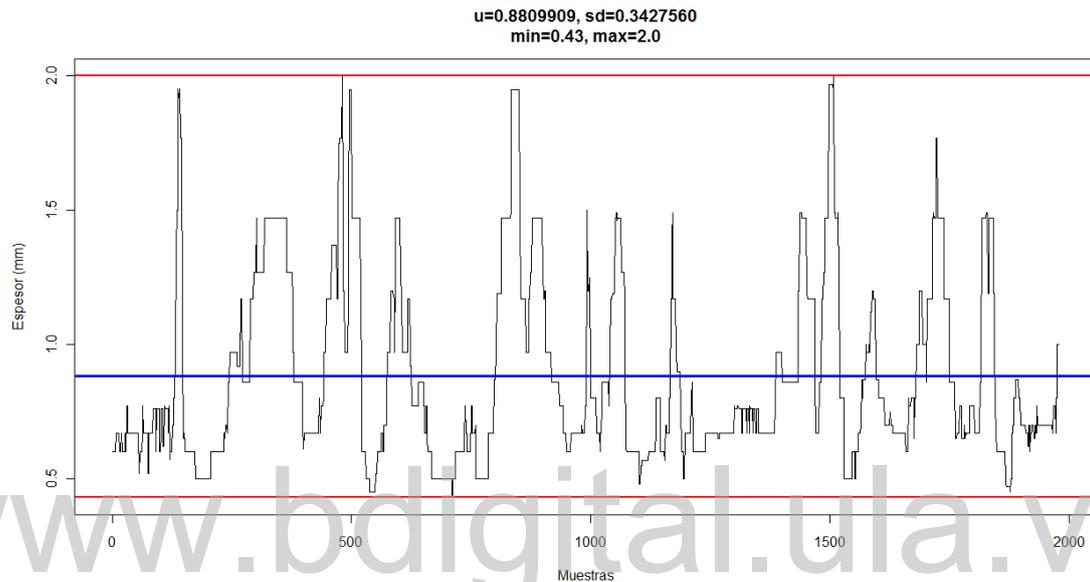


Figura 4.5: Umbrales para el Espesor tomando en cuenta el máximo y el mínimo valor

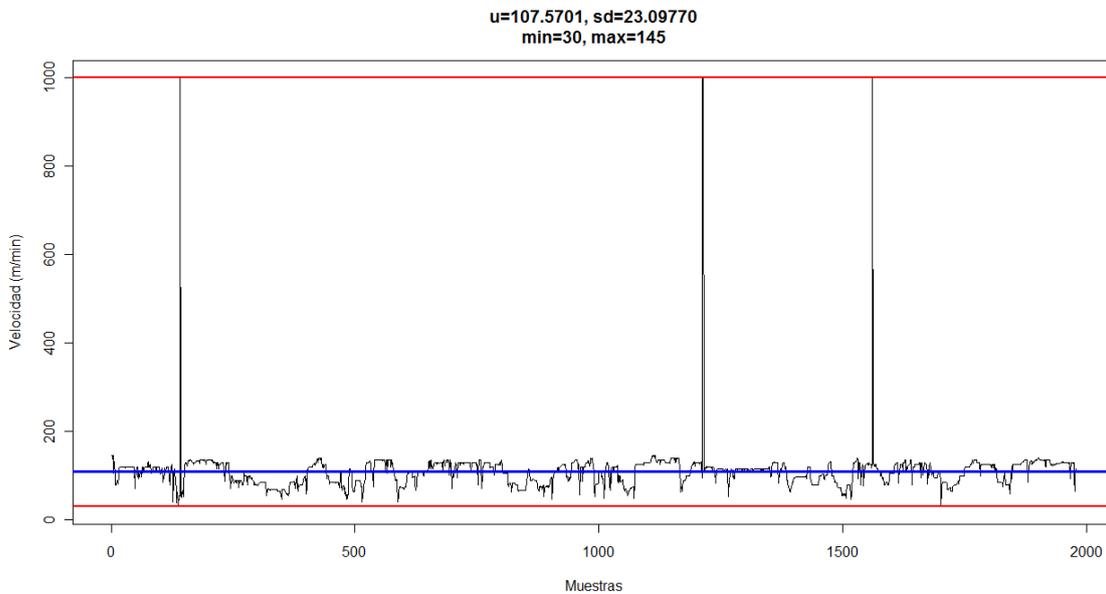


Figura 4.6: Umbrales para la Velocidad tomando en cuenta el máximo y el mínimo valor.

4.2.1 Resultados del ajuste de la máquina para Ea_vb:

4.2.1.1) Ajuste de Kernel

KERNEL LINEAL		
ETAPA	SALIDA	
ENTRENAMIENTO	ϵ	0.1
	C	1
	Rho	0.0315
	nVS	306
	VCPRECM	10.0668
	VC CD	0.818
VALIDACION	PRECM	8.7671

Tabla 4.9: Kernel tipo Lineal para la TMPP2M utilizando MVS-R.

KERNEL POLINOMIAL				
Etapa	Salida	Parámetro: Grado del polinomio		
		2	3	4
ENTRENAMIENTO	ϵ	0.1	0.1	0.1
	C	1	1	1
	rho	0.0292	0.0346	0.0906
	nVS	302	291	302
	VCPRECM	10.1040	11.6765	21.4214
	VC CD	0.819	0.789	0.642
VALIDACION	PRECM	9.2802	9.2624	8.8599

Tabla 4.10: Kernel tipo Polinomial para la TMPP2M utilizando MVS-R.

KERNEL RBF						
Etapa	Salida	Parámetro: Gamma				
		0.001	0.01	0.1	1	2
ENTRENAMIENTO	ϵ	0.1	0.1	0.1	0.1	0.1
	C	1	1	1	1	1
	rho	0.0443	0.438	0.482	0.428	0.348
	nVS	342	308	303	302	303
	VCPRECM	27.1173	10.0421	10.0668	11.3917	13.8682
	VC CD	0.82	0.817	0.816	0.794	0.754
VALIDACION	PRECM	17.2906	8.4516	9.6539	11.4451	13.1101

Tabla 4.11: Kernel tipo RBF para la TMPP2M utilizando MVS-R.

4.2.1.1.1) Gráfico de los errores

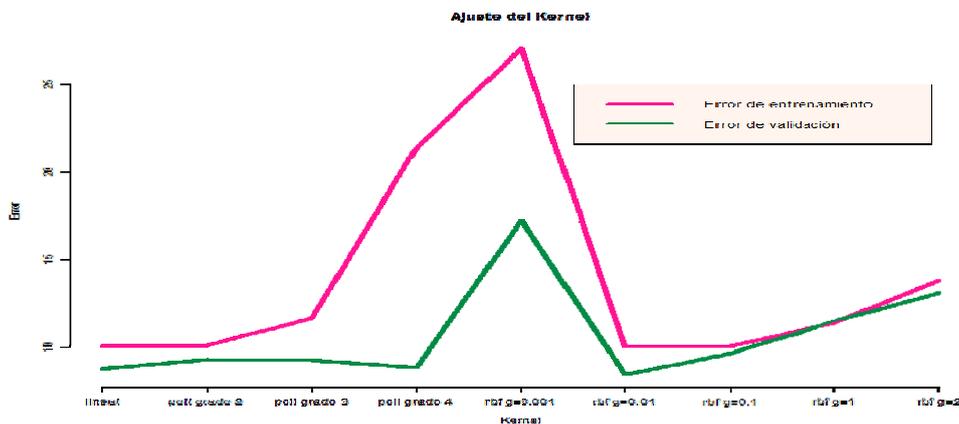


Figura 4.7: Errores para el ajuste del Kernel

Mínimo VC PRECM	10.0421	RBF, $g=0.01$
Mínimo PRECM	8.4516	RBF, $g=0.01$

Tabla 4.12: Mínimo MSE

Como se observa en la Tabla 4.44, el Kernel que mejor se ajusta al problema es el de Base Radial con gamma igual a 0.01, el cual se utilizará en la siguiente etapa. Véase la Figura 4.26.

4.2.1.2) Ajuste de Parámetros: A continuación se ajustan los parámetros C y ϵ

4.2.1.2.1) Ajuste de C

		AJUSTE DE PARAMETROS: C					
Etapa	Salida	C					
		0.01	0.1	1	10	100	1000
ENTRENAMIENTO	ϵ	0.1	0.1	0.1	0.1	0.1	0.1
	Rho	-0.223	0.0337	0.438	0.332	0.383	2.24
	nVS	338	345	308	300	292	292
	VCPRECM	54.4824	29.3462	9.9554	10.0297	10.2030	10.2030
	VC CD	0.813	0.815	0.819	0.819	0.817	0.816
VALIDACION	PRECM	41.8367	18.5318	8.4516	9.0142	9.2358	9.2515

Tabla 4.13: Ajuste del parámetro C utilizando MVS-R.

4.2.1.2.1.1) Gráfico de los errores

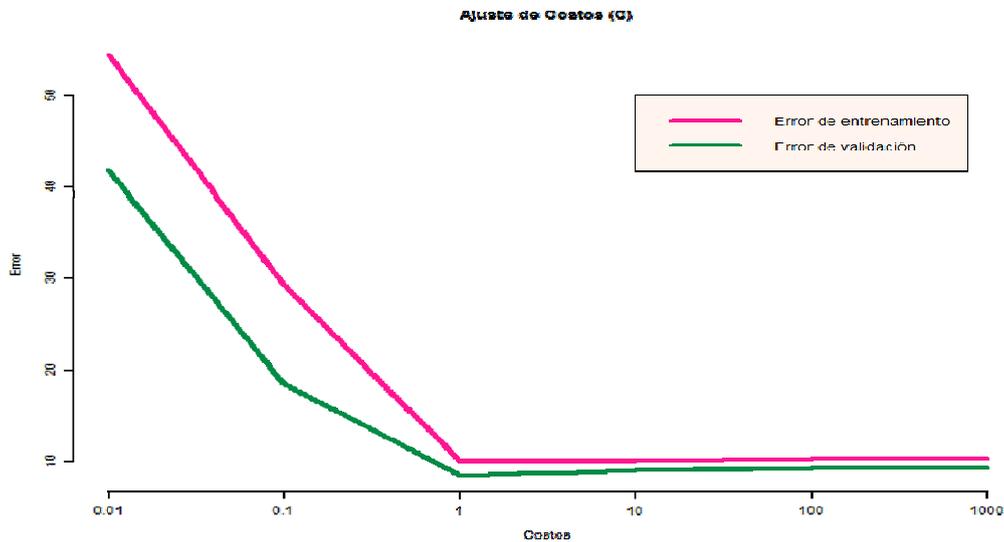


Figura 4.8: Errores para el ajuste de C

Mínimo VC PRECM	9.9554	C= 1
Mínimo PRECM	8.4516	C= 1

Tabla 4.14: Mínimo MSE

Como se observa en la Figura 4.27, a medida que C se acerca al valor 1000, disminuye fuertemente tanto el error de entrenamiento como el de validación, encontrándose el mínimo en C iguala 1.

4.2.1.2.2) Ajuste de ϵ

AJUSTE DE PARAMETROS: ϵ						
Etapa	Salida	ϵ				
		0.001	0.01	0.1	0.5	1
ENTRENAMIENTO	C	1	1	1	1	1
	Rho	0.487	0.48	0.438	0.496	0.645
	nVS	477	456	308	63	34
	VCPRECM	10.0668	10.1659	9.9182	10.5497	17.4591
	VC CD	0.817	0.815	0.82	0.812	0.804
VALIDACION	PRECM	8.6006	8.6325	8.4516	8.6886	13.4174

Tabla 4.15: Ajuste del parámetro ϵ utilizando MVS-R.

4.2.1.2.2.1) Gráfico de los errores

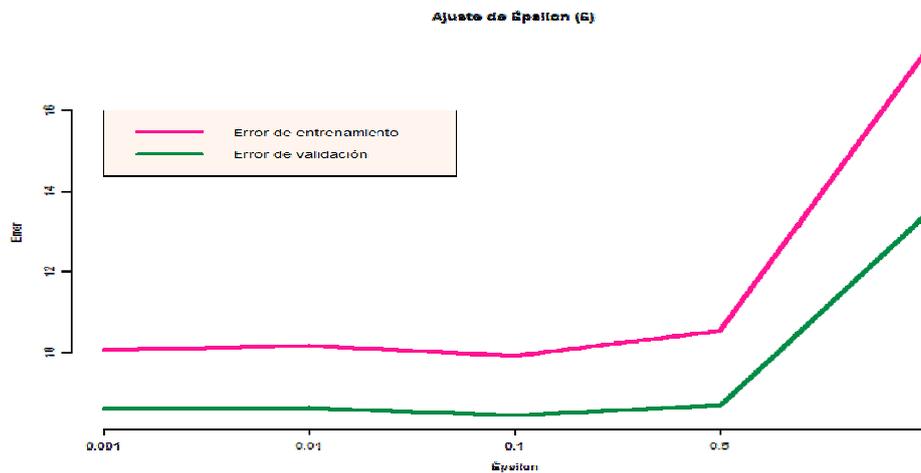


Figura 4.9: Errores para el ajuste de ϵ

Mínimo VC PRECM	9.9182	$\epsilon = 0.1$
Mínimo PRECM	8.4516	$\epsilon = 0.1$

Tabla 4.16: Mínimo MSE

En la Figura 4.28 se observa que a medida que ϵ se acerca al valor uno, el error de entrenamiento y validación aumentan fuertemente. El mínimo PRECM se encuentra en $\epsilon = 0.1$.

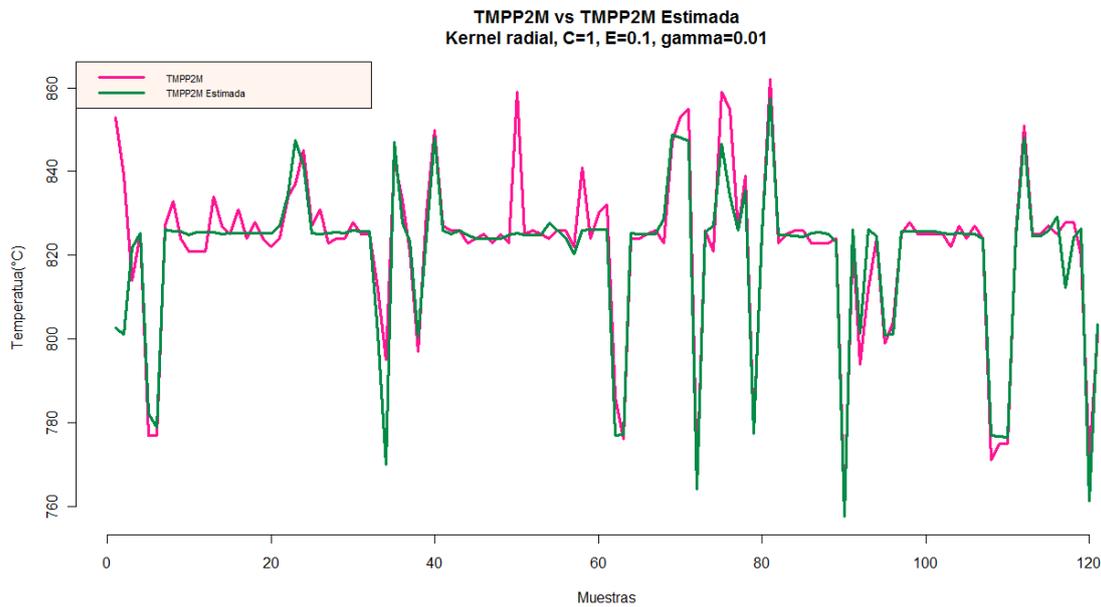


Figura 4.10 Optimo ajuste utilizando MVS-R.

Considerando el umbral Ea_{vb} la máquina que mejor se ajusta posee un Kernel de Base Radial con parámetro C igual a 1 y gamma igual a 0.1, un porcentaje de instancias correctamente predichas igual a 82%, con un PRECM igual a 8.45%. En la Figura 4.29 se observa la aproximación realizada por la máquina (color verde) para la Temperatura Medida.

4.2.2 Resultados del ajuste de la máquina para Ea_va:

4.2.2.1) Ajuste de Kernel

KERNEL LINEAL		
ETAPA	SALIDA	
ENTRENAMIENTO	ϵ	0.1
	C	1
	Rho	-0.0326
	nVS	19
	VCPRECM	6.2035
	VC CD	0.9
VALIDACION	PRECM	2.5894

Tabla 4.17: Kernel tipo Lineal para la TMPP2M utilizando MVS-R.

KERNEL POLINOMIAL				
Etapa	Salida	Parámetro: Grado del polinomio		
		2	3	4
ENTRENAMIENTO	ϵ	0.1	0.1	0.1
	C	1	1	1
	rho	-0.0953	0.313	0.351
	nVS	20	22	22
	VCPRECM	10.5126	43.2144	59.5591
	VC CD	0.869	0.443	0.414
	VALIDACION	PRECM	26.3667	84.3399

Tabla 4.18: Kernel tipo Polinomial para la TMPP2M utilizando MVS-R.

KERNEL RBF						
Etapa	Salida	Parámetro: Gamma				
		0.001	0.01	0.1	1	2
ENTRENAMIENTO	ϵ	0.1	0.1	0.1	0.1	0.1
	C	1	1	1	1	1
	rho	-0.283	0.0846	0.699	0.436	0.34
	nVS	30	29	20	26	26
	VCPRECM	63.1500	34.5468	10.4011	29.0985	26.6220
	VC CD	0.471	0.807	0.865	0.608	0.641
VALIDACION	PRECM	56.6711	18.3028	8.5540	28.4075	34.4896

Tabla 4.19: Kernel tipo RBF para la TMPP2M utilizando MVS-R.

4.2.2.1.1) Gráfico de los errores

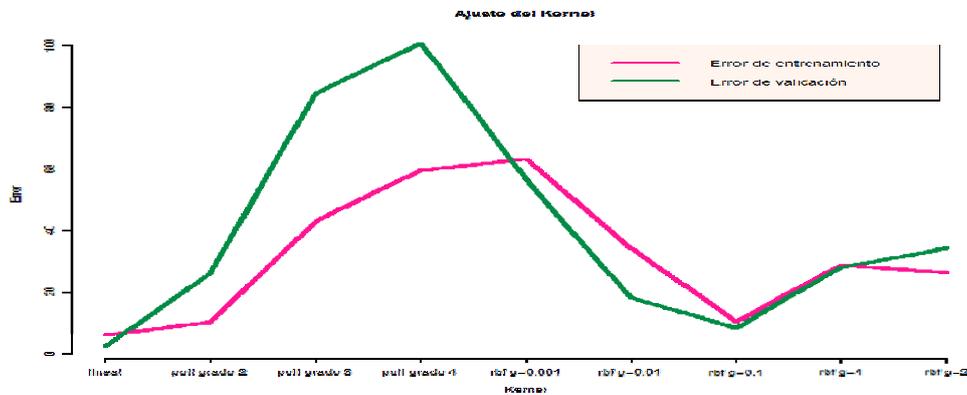


Figura 4.11: Errores para el ajuste del kernel

Mínimo VC PRECM 6.2035	Lineal
Mínimo PRECM 2.5894	Lineal

Tabla 4.20: Mínimo MSE

En la tabla 4.52 se observa que el Kernel Lineal se ajusta mejor al problema puesto que posee el menor PRECM para ambas etapas; entrenamiento y validación. Véase la Figura 4.30.

4.2.2.2) Ajuste de Parámetros: A continuación se ajustan los parámetros C y ϵ

4.2.2.2.1) Ajuste de C

		AJUSTE DE PARAMETROS: C					
Etapa	Salida	C					
		0.01	0.1	1	10	100	1000
ENTRENAMIENTO	ϵ	0.1	0.1	0.1	0.1	0.1	0.1
	rho	-0.224	-0.0675	-0.0326	-0.0306	-0.0306	-0.0304
	nVS	28	21	19	18	17	17
	VC PRECM	48.5388	6.3026	5.8447	6.7236	5.4482	6.4512
	VC CD	0.776	0.91	0.906	0.893	0.912	0.897
VALIDACION	PRECM	30.3256	2.7745	2.5894	2.5759	2.5753	2.5761

Tabla 4.21: Ajuste del parámetro C utilizando MVS-R.

4.2.2.2.1) Gráfico de los errores

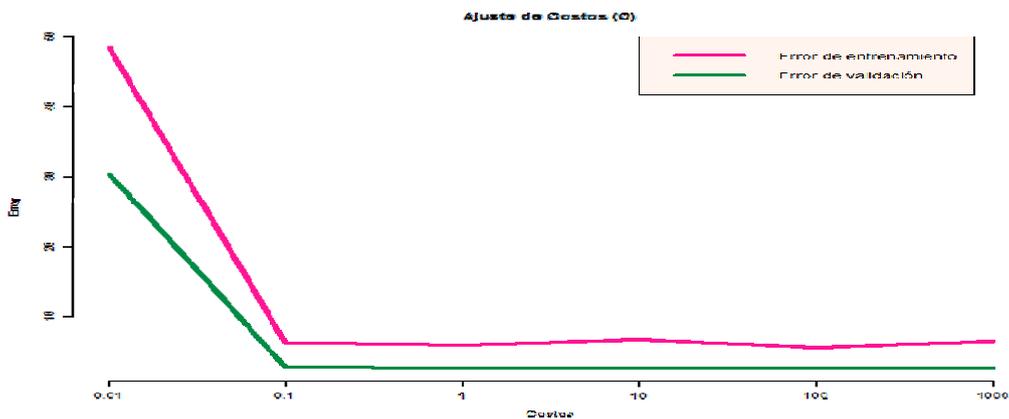


Figura 4.12: Errores para el ajuste de C

Mínimo VC PRECM	5.4482	C= 100
Mínimo PRECM	2.5753	C= 100

Tabla 4.22: Mínimo MSE

En la tabla 4.54 se observa que para ambos errores, validación y entrenamiento, el menor PRECM se encuentra en C igual a 100.

4.2.2.2.2) Ajuste de ϵ

AJUSTE DE PARAMETROS: ϵ						
Etapa	Salida	ϵ				
		0.001	0.01	0.1	0.5	1
ENTRENAMIENTO	C	100	100	100	100	100
	Rho	-0.0397	-0.0423	-0.0306	0.00622	0.067
	nVS	36	35	17	5	4
	VCPRECM	8.0856	6.5750	6.9712	10.0792	25.5076
	VC CD	0.879	0.892	0.894	0.835	0.74
VALIDACION	PRECM	2.7277	2.6831	2.5753	9.2432	15.9006

Tabla 4.23: Ajuste del parámetro ϵ utilizando MVS-R.

4.2.2.2.1) Gráfico de los errores

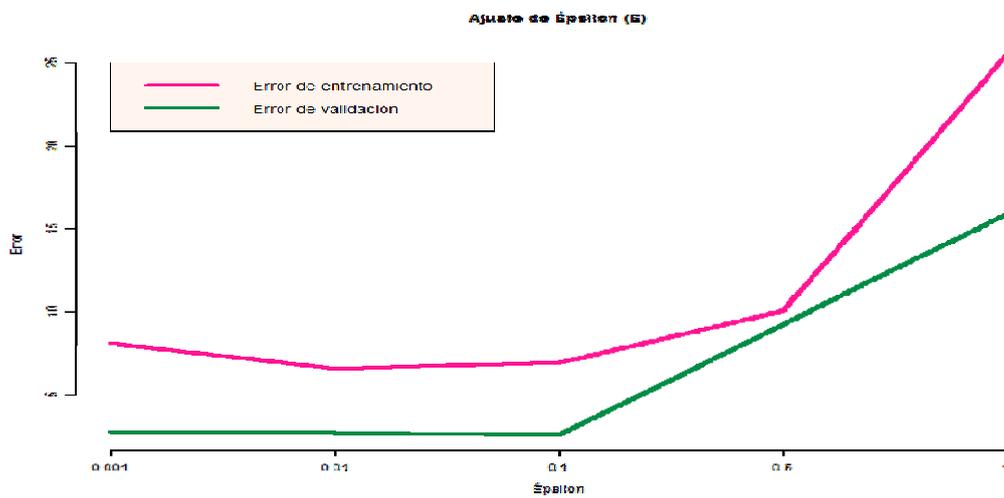


Figura 4.13: Errores para el ajuste de ϵ

Mínimo VC PRECM 6.5750	$\epsilon = 0.01$
Mínimo PRECM 2.5753	$\epsilon = 0.1$

Tabla 4.24 Mínimo MSE

Al observar la Figura 4.32 se puede notar que el mínimo PRECM es el de validación, con un ϵ igual a 0.1.

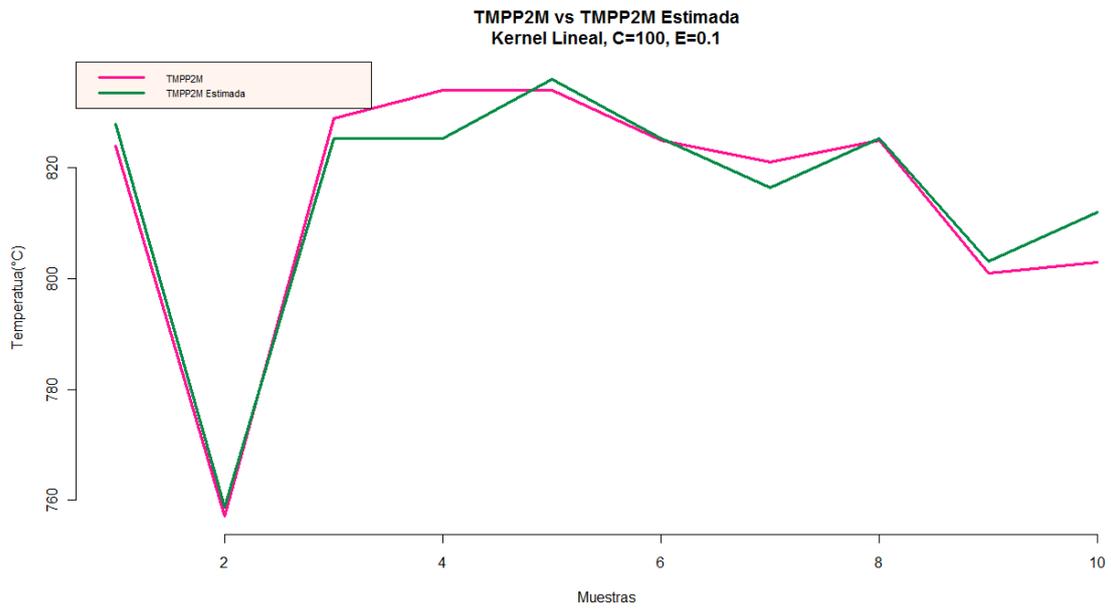


Figura 4.14: Optimo ajuste utilizando MVS-R.

www.bdigital.lula.ve

En el caso cuando el Espesor es alto y la Velocidad también los parámetros de la mejor máquina son: Kernel Lineal y C igual a 100. El porcentaje de instancias correctamente predichas es de 89.40% con un PRECM total de 2.57%.

4.2.3 Resultados del ajuste de la máquina para Eb_va:

4.2.3.1) Ajuste de Kernel

KERNEL LINEAL		
ETAPA	SALIDA	
ENTRENAMIENTO	ϵ	0.1
	C	1
	Rho	-0.0078
	nVS	284
	VCPRECM	5.0396
	VC CD	0.963
VALIDACION	PRECM	4.5520

Tabla 4.25: Kernel tipo Lineal para la TMPP2M utilizando MVS-R.

KERNEL POLINOMIAL				
Etapa	Salida	Parámetro: Grado del polinomio		
		2	3	4
ENTRENAMIENTO	ϵ	0.1	0.1	0.1
	C	1	1	1
	Rho	-0.0319	-0.0267	-0.0558
	nVS	295	301	311
	VCPRECM	4.9157	5.0643	5.6711
	VC CD	0.964	0.963	0.959
VALIDACION	PRECM	4.5705	4.6808	4.7281

Tabla 4.26: Kernel tipo Polinomial para la TMPP2M utilizando MVS-R.

KERNEL RBF						
Etapa	Salida	Parámetro: Gamma				
		0.001	0.01	0.1	1	2
ENTRENAMIENTO	ϵ	0.1	0.1	0.1	0.1	0.1
	C	1	1	1	1	1
	rho	0.54	0.453	0.156	0.226	0.195
	nVS	582	309	314	338	332
	VCPRECM	10.2402	5.0891	5.1139	5.2377	6.5626
	VC CD	0.944	0.963	0.963	0.962	0.952
VALIDACION	PRECM	8.3199	4.6861	4.8016	4.9551	5.4919

Tabla 4.27: Kernel tipo RBF para la TMPP2M utilizando MVS-R.

4.2.3.1.1) Gráfico de los errores

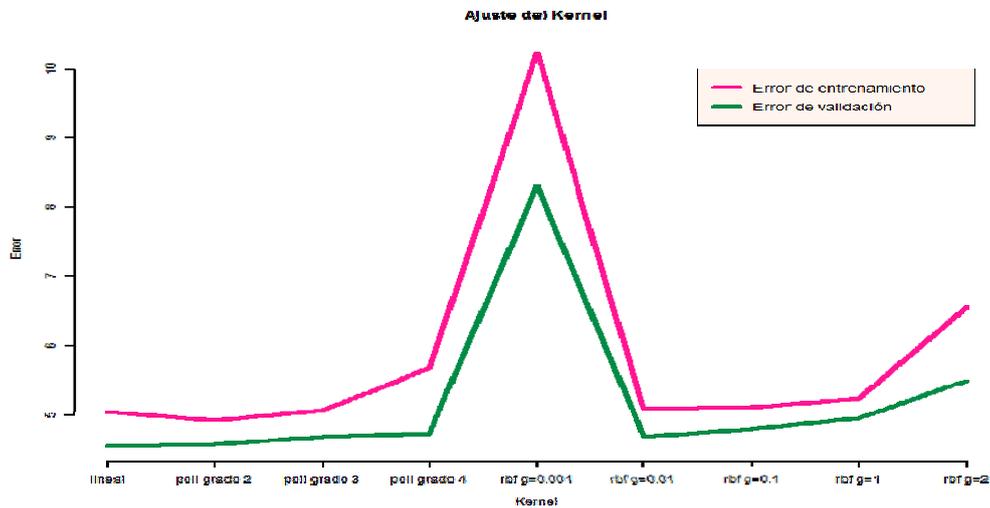


Figura 4.15: Errores para el ajuste del Kernel

Mínimo VC PRECM 4.9157	Polinomial, grado=2
Mínimo PRECM 4.5520	Lineal

Tabla 4.28: Mínimo MSE

Obsérvese en la Figura 4.34 que el Kernel Lineal se ajusta mejor a los datos que el Polinomial, por lo tanto se tomó el mismo para la siguiente etapa.

4.2.3.2) Ajuste de Parámetros: A continuación se ajustan los parámetros C y ϵ

4.2.3.2.1) Ajuste de C

AJUSTE DE PARAMETROS: C							
Etapa	Salida	C					
		0.01	0.1	1	10	100	1000
ENTRENAMIENTO	ϵ	0.1	0.1	0.1	0.1	0.1	0.1
	Rho	-0.00189	-0.00579	-0.0078	-0.00826	-0.00842	-0.00854
	nVS	329	295	284	285	285	285
	VCPRECM	5.1139	5.0396	5.0643	5.0520	5.0767	5.0643
	VC CD	0.963	0.963	0.963	0.963	0.963	0.963
VALIDACION	PRECM	4.6485	4.5590	4.5520	4.5561	4.5547	4.5659

Tabla 4.29: Ajuste del parámetro C utilizando MVS-R.

4.2.3.2.1.1) Gráfico de los errores

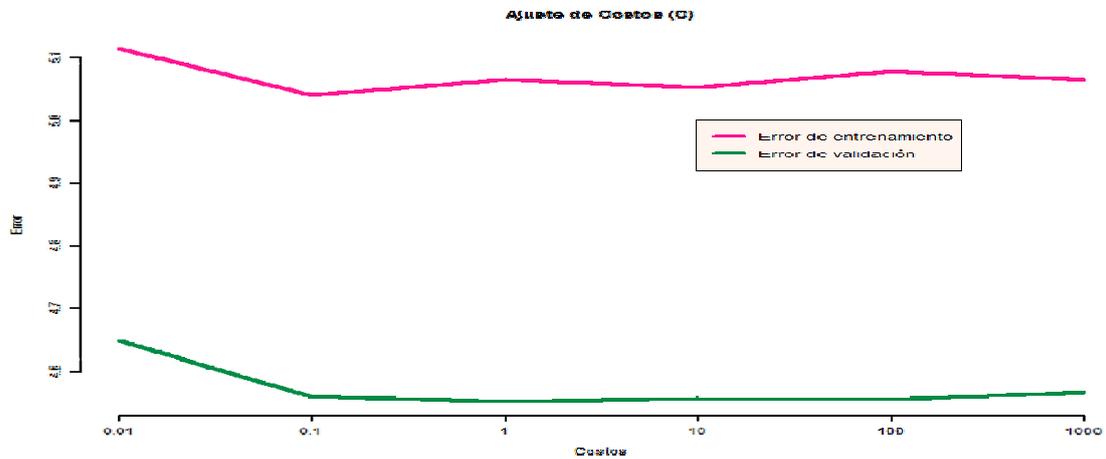


Figura 4.16: Errores para el ajuste de C

Mínimo VC PRECM 5.0396	C= 0.1
Mínimo PRECM 4.5520	C= 1

Tabla 4.30: Mínimo MSE

Para la siguiente etapa se tomó el menor error cuyo valor de C es igual a 1. Obsérvese la tabla 4.62.

4.2.3.2.2) Ajuste de ϵ

AJUSTE DE PARAMETROS: ϵ						
Etapa	Salida	ϵ				
		0.001	0.01	0.1	0.5	1
ENTRENAMIENTO	C	1	1	1	1	1
	Rho	0.00596	0.0093	-0.0078	0.026	0.222
	nVS	869	790	284	28	4
	VCPRECM	5.1263	5.1263	5.0891	8.1104	30.7082
	VC CD	0.963	0.963	0.963	0.96	0.95
VALIDACION	PRECM	4.4847	4.5056	4.5520	7.5776	30.2358

Tabla 4.31: Ajuste del parámetro ϵ utilizando MVS-R.

4.2.3.2.2.1) Gráfico de los errores

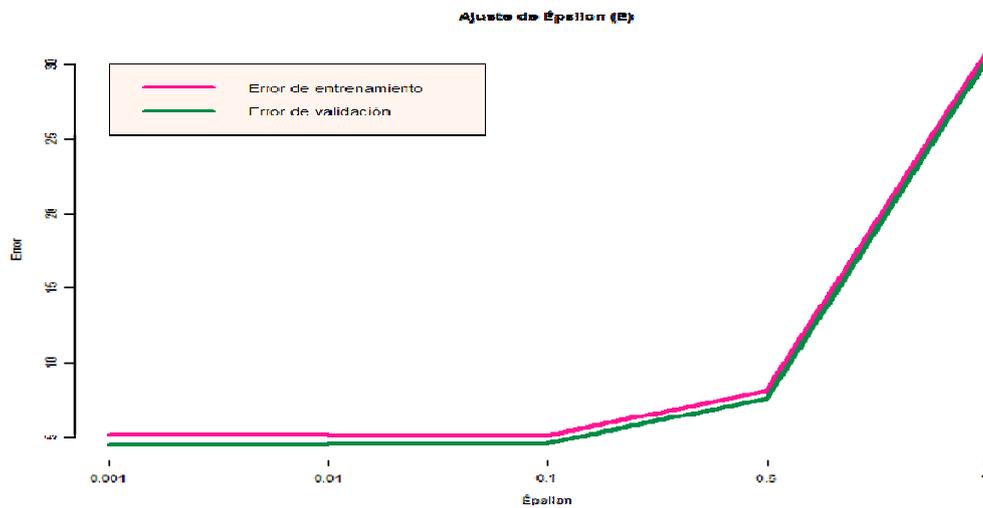


Figura 4.17: Errores para el ajuste de ϵ

Mínimo VC PRECM 5.0891	$\epsilon = 0.1$
Mínimo PRECM 4.4847	$\epsilon = 0.001$

Tabla 4.32: Mínimo MSE

Obsérvese en la Figura 4.36 que a medida que ϵ aumenta, tanto el error de entrenamiento como el de validación aumentan, siguiendo un patrón muy similar, encontrando el mínimo en $\epsilon = 0.001$.

En la Figura 4.37 se observa una comparación entre la estimación realizada por la máquina óptima y la Temperatura Medida. La configuración que arroja mejores resultados es la que posee el Kernel Lineal con un valor de parámetro C igual a 1, un porcentaje de instancias correctamente predichas de 96.30% y un PRECM de 4.48%.

En la Figura 4.38 se puede apreciar la Temperatura de Referencia vs la Temperatura Medida, gracias a la técnica estadística aplicada la predicción mejoró y la diferencia entre ambas temperaturas disminuyó en comparación con la estimación realizada con todos los datos.

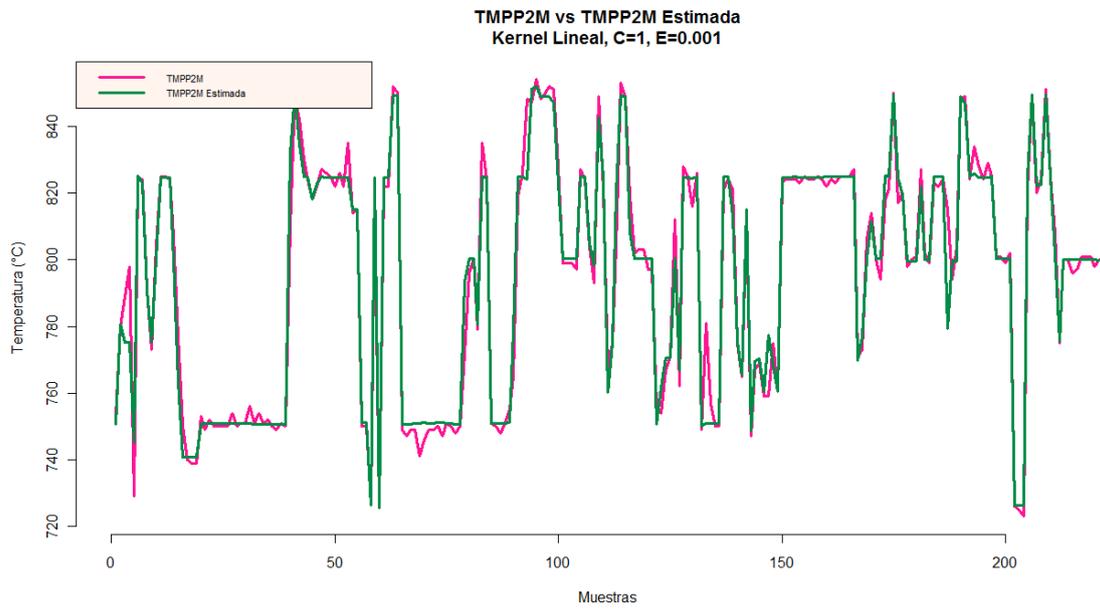


Figura 4.18: Optimo ajuste utilizando MVS-R.

www.bdigital.ula.ve

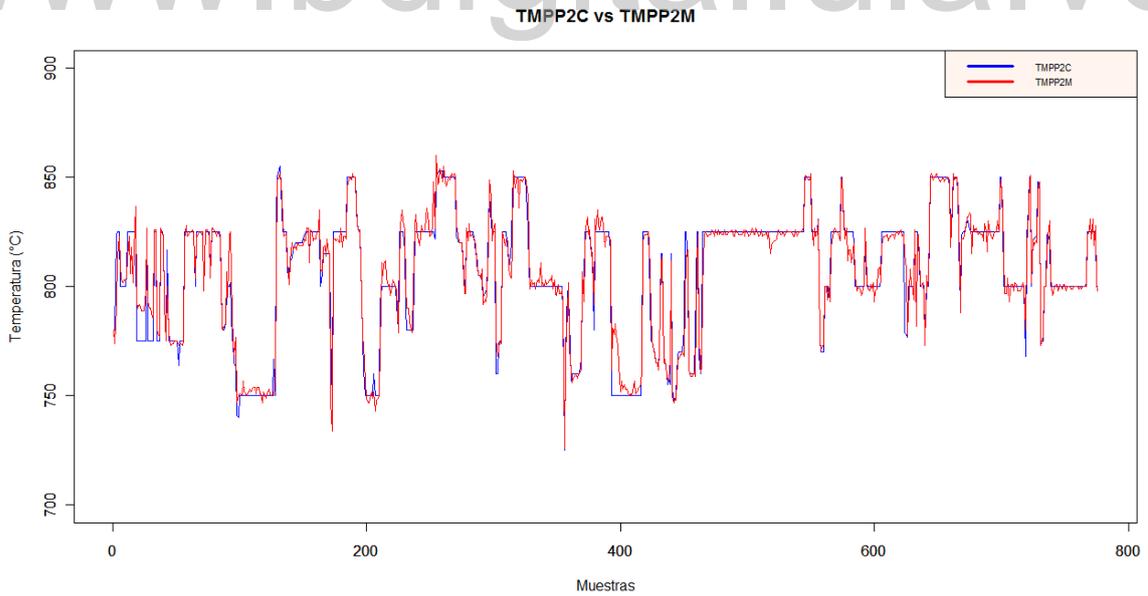


Figura 4.19: TMPP2C vs TMPP2M

4.2.4 Resultados del ajuste de la máquina para Eb_vb:

4.2.4.1) Ajuste de Kernel

KERNEL LINEAL		
ETAPA	SALIDA	
ENTRENAMIENTO	ϵ	0.1
	C	1
	Rho	-0.00987
	nVS	91
	VCPRECM	10.1040
	VC CD	0.923
VALIDACION	PRECM	11.2162

Tabla 4.33: Kernel tipo Lineal para la TMPP2M utilizando MVS-R.

KERNEL POLINOMIAL				
Etapa	Salida	Parámetro: Grado del polinomio		
		2	3	4
ENTRENAMIENTO	ϵ	0.1	0.1	0.1
	C	1	1	1
	Rho	-0.0386	-0.051	-0.0396
	nVS	81	86	89
	VCPRECM	11.5403	11.7384	31.3273
	VC CD	0.912	0.91	0.777
VALIDACION	PRECM	15.9024	19.4844	22.6638

Tabla 4.34: Kernel tipo Polinomial para la TMPP2M utilizando MVS-R.

KERNEL RBF						
Etapa	Salida	Parámetro: Gamma				
		0.001	0.01	0.1	1	2
ENTRENAMIENTO	ϵ	0.1	0.1	0.1	0.1	0.1
	C	1	1	1	1	1
	rho	0.00772	1.2	0.536	0.563	0.543
	nVS	156	101	85	87	92
	VCPRECM	70.7033	11.0203	10.5745	12.3576	16.7161
	VC CD	0.859	0.923	0.918	0.908	0.876
VALIDACION	PRECM	67.9656	15.8022	15.5554	24.4647	30.6805

Tabla 4.35: Kernel tipo RBF para la TMPP2M utilizando MVS-R.

4.2.4.1.1) Gráfico de los errores

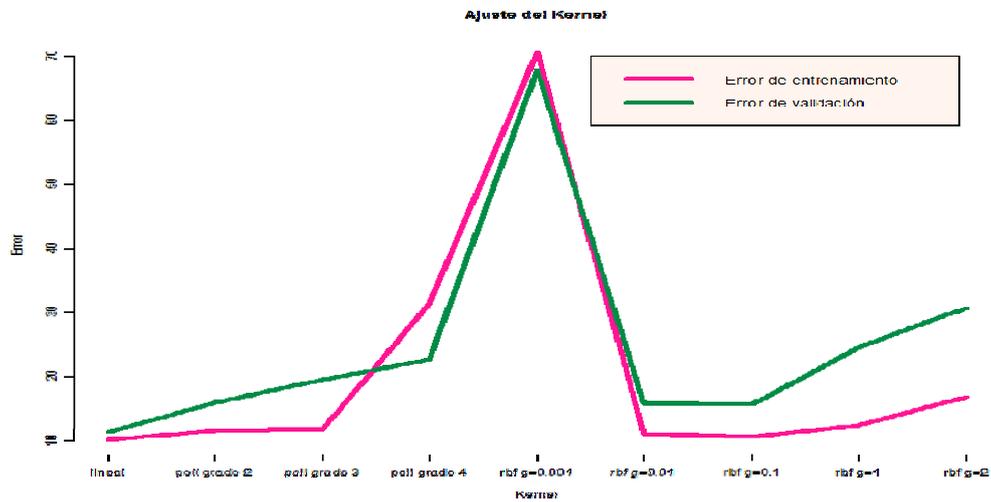


Figura 4.20: Errores para el ajuste del Kernel

Minimo VC PRECM	10.1040	Lineal
Minimo PRECM	11.2162	Lineal

Tabla 4.36: Mínimo MSE

Para el presente problema el Kernel que mejor se ajustó a los datos es el Lineal, como se observa en la Tabla 4.68 y en la Figura 4.39. Para la siguiente etapa se utilizó el mismo.

4.2.4.2) Ajuste de Parámetros: A continuación se ajustan los parámetros C y ϵ

4.2.4.2.1) Ajuste de C

AJUSTE DE PARAMETROS: C							
Etapa	Salida	C					
		0.01	0.1	1	10	100	1000
ENTRENAMIENTO	ϵ	0.1	0.1	0.1	0.1	0.1	0.1
	rho	-0.0585	-0.0168	-0.00987	-0.0232	-0.0235	-0.023
	nVS	118	88	91	90	90	90
	VCPRECM	16.4685	9.7696	10.1040	10.3268	10.2402	10.1535
	VC CD	0.909	0.924	0.923	0.921	0.922	0.922
VALIDACION	PRECM	23.1931	11.2988	11.2162	10.7316	10.7152	10.7226

Tabla 4.37: Ajuste del parámetro C utilizando MVS-R.

4.2.4.2.1.1) Gráfico de los errores

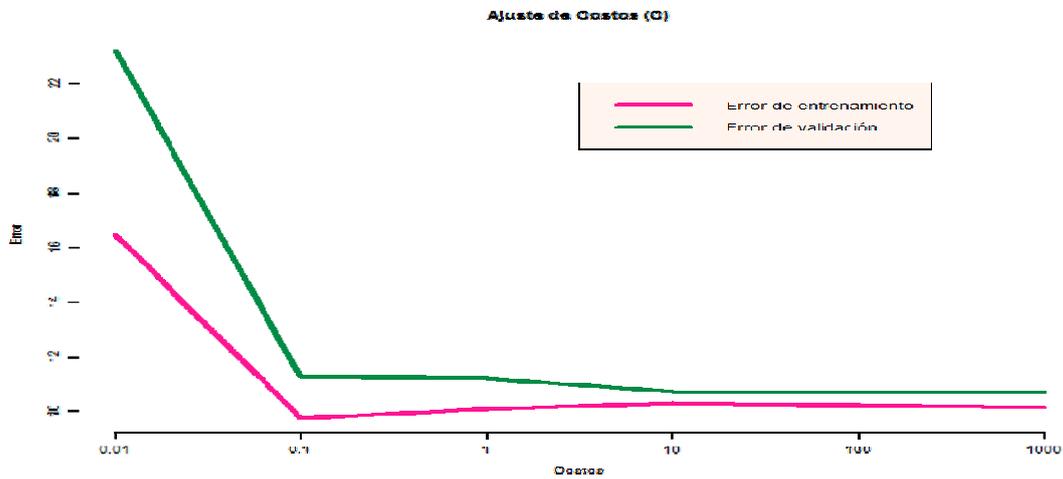


Figura 4.21: Errores para el ajuste de C

Mínimo VC PRECM	9.7696	C= 0.1
Mínimo PRECM	10.7152	C= 100

Tabla 4.38: Mínimo MSE

En la Tabla 4.70 se observa que el menor PRECM se encuentra en la etapa de entrenamiento. Es por ello que para la siguiente fase se utilizó este valor. Véase la Figura 4.40.

4.2.4.2.2) Ajuste de ϵ

AJUSTE DE PARAMETROS: ϵ						
Etapa	Salida	ϵ				
		0.001	0.01	0.1	0.5	1
ENTRENAMIENTO	C	0.1	0.1	0.1	0.1	0.1
	Rho	-0.00319	-0.00257	-0.0235	0.0193	0.392
	nVS	177	161	90	17	3
	VCPRECM	10.1163	10.1535	10.2526	11.7384	42.4715
	VC CD	0.922	0.921	0.921	0.91	0.852
VALIDACION	PRECM	10.0112	9.9628	10.7152	21.5086	54.4657

Tabla 4.39: Ajuste del parámetro ϵ utilizando MVS-R.

4.2.4.2.2.1) Gráfico de los errores

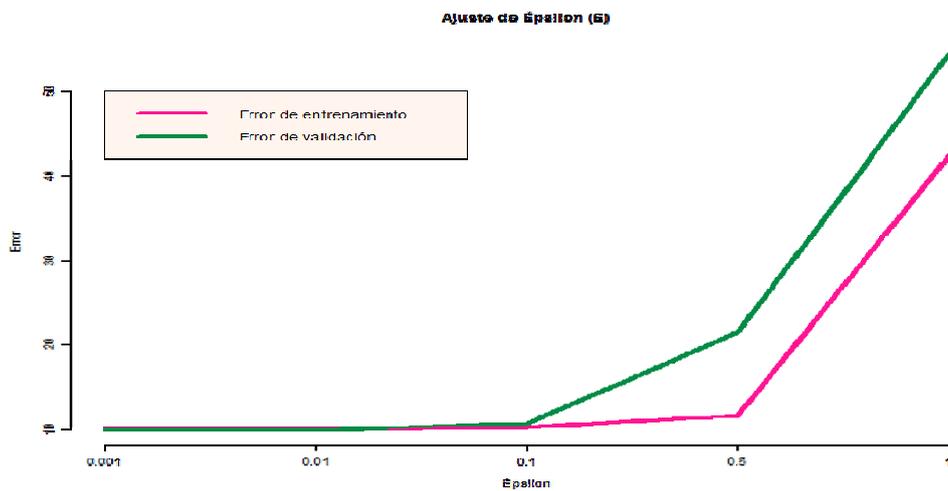


Figura 4.22: Errores para el ajuste de ϵ

www.bdigital.ula.ve

Mínimo VC PRECM 10.1163	$\epsilon = 0.001$
Mínimo PRECM 9.9628	$\epsilon = 0.01$

Tabla 4.40: Mínimo MSE

En la Figura 4.41 se observa que los errores aumentan fuertemente a medida que ϵ aumenta, encontrando el mínimo cuando $\epsilon = 0.01$.

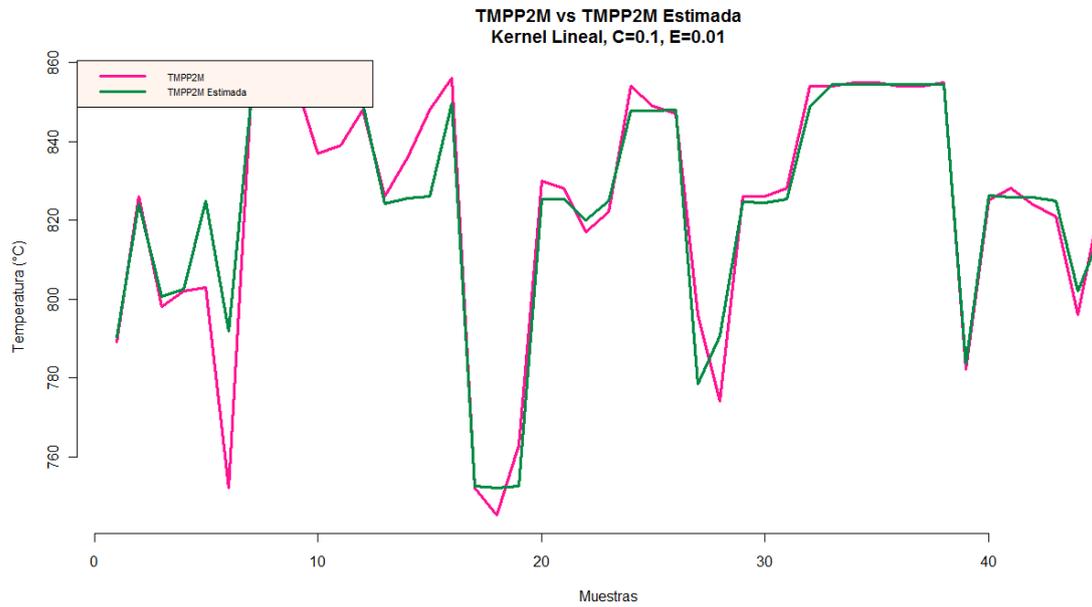


Figura 4.23: Optimo ajuste utilizando MVS-R.

www.bdigital.ula.ve

Al considerar el Espesor bajo y la Velocidad baja se encontró que los parámetros asociados a la máquina óptima son un Kernel lineal y C igual a 0.1. Con esta configuración se obtiene un 92.10% de instancias correctamente predichas con un PRECM de 9.96%. En la Figura 4.42 se presenta la Temperatura Medida (color rojo) y la estimación realizada con la máquina óptima (color verde).

Capítulo 5

Conclusiones

Este capítulo presenta las conclusiones derivadas del desarrollo del presente estudio.

5.1 Conclusiones

El estudio realizado en el presente trabajo se basó en investigar si las diferencias entre la Temperatura Medida y la Temperatura de Referencia a la salida del horno del proceso Industrial de Galvanizado, están influenciadas por las variables Espesor y Velocidad. Con este propósito se diseñó una máquina de aprendizaje con diferentes Kernel, la cual se aplicó a la base de datos completa ($n=1.979$ muestras) y a un conjunto de Bases de Datos obtenidas de la Base de Datos completa constituidas por intervalos de las variables Espesor y Velocidad.

La mejor máquina de aprendizaje para la estimación de la Temperatura Medida con toda la base de datos ($n=1.979$ muestras) se obtuvo con la función Kernel RBF con parámetros C igual a 10 y γ igual a 0.1 alcanzando un porcentaje de instancias correctamente predichas de 94.1% con un porcentaje del Error Cuadrático Medio de 6.44%. Sin embargo, este resultado obtenido no suministra información acerca de la influencia de las variables Espesor y Velocidad sobre la diferencia entre la Temperatura Medida y la Temperatura de Referencia por lo cual se procedió a dividir la base de datos en umbrales.

Con previo conocimiento de que la señal de referencia es determinada por parámetros de las bobinas como el Espesor y la Velocidad, donde la Velocidad de la bobina en el tren de laminado es controlada a partir del Espesor, se procedió a dividir la base de datos en umbrales tomando el mínimo y máximo valor de la base de datos, quedando la misma dividida de la siguiente manera: Espesor alto-velocidad baja (Ea_vb , $n=602$ observaciones), Espesor alto-velocidad alta (Ea_va , $n=47$ observaciones), Espesor

bajo-velocidad alta (Eb_va, n=1106 observaciones) y Espesor bajo-velocidad baja (Eb_vb, n=224 observaciones).

Los resultados para el primer umbral, Ea_vb, mostraron que el Kernel que mejor se ajusta al problema es el Radial con parámetros C igual a 1 y gamma igual a 0.1, un porcentaje de instancias correctamente predichas igual a 82% y un porcentaje del Error Cuadrático Medio de 8.45%. Para el segundo caso, Ea_va, el mejor Kernel es el Lineal con parámetro C igual a 100, un porcentaje de instancias correctamente predichas igual a 89.4% y un PRECM igual a 2.57%.

Para el tercer caso, Eb_va el mejor Kernel es el Lineal con parámetro C igual a 1, un porcentaje de instancias correctamente predichas de 96.3% y un PRECM igual a 4.48%, lo cual mejora significativamente respecto a las estimaciones anteriores.

Finalmente, para el caso Eb_vb, el kernel que mejor se ajusta es el Lineal con un parámetro C igual a 0.1, un porcentaje de instancias correctamente predichas de 92.1% y un PRECM de 9.96%.

Al comparar los resultados obtenidos por la variación de los parámetros de las funciones Kernel Lineal, Polinomial y RBF, se determinó que el mejor modelo para la estimación de la Temperatura Medida a partir de la Velocidad, el Espesor y la Temperatura de Referencia se obtuvo mediante el Kernel Lineal con parámetro C igual a 1, con un porcentaje de instancias correctamente predichas de 96.3% y un PRECM de 4.48%, el cual corresponde a la base de datos dividida por umbrales tomando en cuenta el valor mínimo y el máximo, específicamente el umbral Eb_va.

Cabe destacar la importancia de este estudio en el momento en el que el sensor de temperatura medida a la salida del horno del Proceso de Galvanizado en continuo falle, puesto que se puede predecir de manera manual la Temperatura Medida con el Espesor de las bobinas, la Velocidad en el tren de laminado y la Temperatura de referencia y así controlar el mismo. Es decir, con el previo conocimiento de la mejor máquina se predicen los parámetros y posteriormente se comparan si las estimaciones son parecidas a las de referencia. Por el contrario, si el sensor se encuentra operativo, las especificaciones se pasan al mecanismo automático y así se detectan las posibles fallas.

Finalmente, el grado de efectividad con que se aplique el ciclo térmico para cada bobina durante el proceso de galvanizado es de vital importancia para lograr óptimas propiedades finales del acero, por lo tanto, esta técnica podría ser utilizada como técnica de monitorización que permitiría analizar, controlar y predecir de la mejor manera posible las señales de referencia para cada tipo de bobina dentro de la zona de calentamiento del horno para una mejor toma de decisión o bien, en el caso de no contar con el sensor, disponer de la Temperatura Medida para la supervisión y control del proceso industrial.

www.bdigital.ula.ve

Bibliografía

Benavides, M. (2006). Máquinas vectoriales de soporte en regresión. Chile.

Carreras, X. (2004). *Máquinas de soporte vectorial*. España.

Gunn, S (1998), *Support Vector Machines for classification and regression*. University of Southampton, United Kingdom.

Herrera, M. (2008). Análisis de series temporales de un proceso industrial de galvanizado. Proyecto de Grado EISULA, Universidad de Los Andes, Escuela de Ingeniería de Sistemas.

Huawei, Z. (2006). Water saturation estimation using Support Vector Machine. University of Houston

Martínez, F. (2003). *Optimización mediante técnicas de minería de datos del ciclo de recocido de una línea de galvanizado*. España.

Martínez, F. (2006). *Aspectos básicos del proceso de galvanizado*. España.

Nava, B. (2008). Aplicación de dinámica simbólica para descubrir patrones en series temporales. Proyecto de Grado EISULA, Universidad de Los Andes, Escuela de Ingeniería de Sistemas.

Orallo, J. (2004), *Introducción a la minería de datos*. Editorial Pearson Prentice Hall, Primera edición, Madrid España.

Somanin (2004). Galvanizado en caliente. Visitado el 26 de Mayo de 2009, URL: <http://www.somanin.com/queesgalvanizado.htm>.

Wikipedia (2004). Minería de datos. Visitado el 27 de Mayo de 2009, URL: http://es.wikipedia.org/wiki/Mineria_de_datos.

www.bdigital.ula.ve

Apéndice

Glosario

Temperatura Medida: Es la temperatura medida por el pirómetro 2 a la salida del horno del Proceso Industrial de Galvanizado.

Temperatura de Consigna: Es la temperatura de referencia (condición automatizada) a la salida del horno del Proceso Industrial de Galvanizado.

Variables Predictoras: Son las variables independientes del modelo de regresión. Para esta investigación las variables predictoras son: la Velocidad en el tren de laminado, el Espesor y la Temperatura de consigna.

Variable Predicha: Es la variable dependiente del modelo de regresión. Para esta investigación la variable a predecir es la Temperatura Medida a la salida del horno.

Espacio de Características: un espacio de características es un espacio abstracto donde cada ejemplo (patrón) es representado como un punto en un *espacio n-dimensional*. Esta dimensión, está determinada por el número de características que describen los patrones, con lo cual objetos similares se encontrarán cercanos en el EC y de esta forma es posible realizar clasificación y agrupamiento de los mismos.

Espacio de Hilbert: se define como un espacio de producto interior que es completo con respecto a la norma vectorial definida por el producto interior. Los espacios de Hilbert sirven para clarificar y para generalizar el concepto de series de Fourier, ciertas transformaciones lineales tales como la transformación de Fourier, y son de importancia crucial en la formulación matemática de la mecánica cuántica.