

UNIVERSIDAD DISTRITAL
FRANCISCO JOSÉ DE CALDAS

MODELO DE MAQUINAS DE SOPORTE VECTORIAL PARA LA DETECCIÓN DE FALLAS EN BICICLETAS BASADO EN ACÚSTICA

Camilo Esteban Jimenez Avellaneda - Grupo 1
José David Moreno Posada - Grupo 2
Grupo 20

Universidad Distrital Francisco José de Caldas
Facultad de Ingeniería, Especialización en Ingeniería del Software
Bogotá, Colombia
2017

MODELO DE MAQUINAS DE SOPORTE VECTORIAL PARA LA DETECCIÓN DE FALLAS EN BICICLETAS BASADO EN ACÚSTICA

Camilo Esteban Jimenez Avellaneda
José David Moreno Posada

Trabajo de grado presentado como requisito parcial para optar al título de:
Especialista en Ingeniería de Software

Director:
NANCY GELVEZ

Revisor:
MILENA CORTES

Línea de Investigación:
Inteligencia Artificial

Universidad Distrital Francisco José de Caldas
Facultad de Ingeniería, Especialización en Ingeniería del Software
Bogotá, Colombia
2017

Índice general

Índice de figuras **7**

Índice de cuadros **9**

INTRODUCCIÓN **1**

1. TITULO Y DEFINICIÓN DEL TEMA DE INVESTIGACIÓN **5**

2. ESTUDIO DEL PROBLEMA DE INVESTIGACIÓN **7**
2.1. Planteamiento del Problema 7
2.2. Formulación del Problema 8
2.3. Sistematización del Problema 8

3. OBJETIVOS DE LA INVESTIGACIÓN **9**
3.1. Objetivo General 9
3.2. Objetivos Específicos 9

4. JUSTIFICACIÓN DE LA INVESTIGACIÓN **11**

5. HIPÓTESIS DE TRABAJO **13**

6. ASPECTOS METODOLÓGICOS **15**
6.1. Tipo de Estudio 15
6.2. Método de Investigación 15
6.2.1. Exploratoria 15
6.2.2. Diseño 16

6.2.3. Implementación 16
6.2.4. Resultados 16
6.2.5. Documentación 17
6.3. Fuentes y Técnicas para la Recolección de la Información . 17
6.4. Tratamiento de la Información 17

7. ALCANCES, LIMITACIONES Y RESULTADOS ESPERADOS 19
7.1. Alcances 19
7.2. Limitaciones 20
7.3. Resultados Esperados 21

8. MARCO DE REFERENCIA 23
8.1. Análisis Tiempo-Frecuencia 23
8.1.1. Transformada de Fourier 24
8.1.2. Transformada rápida de Fourier 25
8.1.3. Transformada Wavelet 26
8.2. Máquinas de Soporte Vectorial 28
8.2.1. Aprendizaje Supervisado 28
8.2.2. Definición 29
8.2.3. Forma de Operación 29
8.2.4. Kernel 30
8.3. Fallas en Bicicleta 31

9. CONSTRUCCIÓN DE BASE DE DATOS 35

10. CONSTRUCCIÓN MODELO DE SVM 37

11. RESULTADOS 39

12. CONCLUSIONES 43
12.1. Verificación, contraste y evaluación de objetivos 43
12.2. Aportes Originales 44

Bibliografía **47**

Índice de figuras

8.1. Señal Estacionaria y su Espectro de Frecuencias 24
8.2. Señal No Estacionaria y su Espectro de Frecuencias 25
8.3. Funcionamiento de algoritmo de aprendizaje supervisado . . 29
8.4. Datos extendidos en varias dimensione 31
8.5. KERNEL Polinomial 32
8.6. Kernel Perceptron 33
8.7. Función de base radial Gaussiana 33

11.1. Matriz de Confusión General 40
11.2. Matriz de Confusión para Falsos Positivos 41
11.3. Matriz de Confusión para Falsos Negativos 41
11.4. Curva ROC para el SVM cúbico. 42

Índice de cuadros

11.1. Precisión de Modelos de Máquinas de Soporte Vectorial. . . 39

INTRODUCCIÓN

Una de las mayores problemáticas de la ciudad de Bogotá consiste en su movilidad. Existen estadísticas realizadas por el observatorio ambiental de Bogotá donde se evidencia que el número total de vehículos, registrados oficialmente ante la secretaría de tránsito de Bogotá, ha ido incrementando de una manera vertiginosa en los últimos años. En seis años la ciudad pasó de tener 830.000 vehículos inscritos a más de 1'300.000 vehículos para el año 2013. Además, el estudio también demostró el incremento en la cantidad de motocicletas los cuales son de alrededor 350.000 para el mismo año. Todo esto ocurre en una ciudad donde el número de vías no es suficiente para atender la demanda actual y creciente sus ciudadanos, demostrando el colapso venidero del sistema de transporte [5].

La deficiencia en las vías públicas de la ciudad y la contaminación generada por los medios de transporte de combustible fósil, unido a una cultura de responsabilidad ambiental y recursividad, características de los ciudadanos, ha generado la necesidad de buscar medios de transporte eficientes, económicos y amigables con el ambiente. Una opción que satisface las condiciones anteriores consiste en la bicicleta, la cual ha sido adoptada por los ciudadanos como una buena alternativa para su movilidad.

En el 2012 las Naciones Unidas realizó en Río de Janeiro, Brasil, una conferencia sobre el Desarrollo Sostenible, más conocida como "Río+20". Más de 100 representantes de estados, gobiernos y más de 50.000 participantes del sector privado, ONGs y otros grupos, se reunieron para discutir acerca de cómo reducir la pobreza, avanzar en la equidad social y asegurar la protección medioambiental en un planeta que día a día es más poblado. Como resultado de este evento, se adoptó por consenso, un documento integral bajo el título "The Future We Want", en el cual se destacaron temas

como la transformación de ciudades, el transporte y el turismo sostenible [2].

Bogotá gracias a su contribución en temas asociados a la sostenibilidad urbana, el transporte y el turismo, se establece como referente internacional y nacional de buenas prácticas. Lo que la estableció para el año 2014 como sede mundial de los Diálogos de Alto Nivel "Implementación Decisiones Rio+20 y Promoción de Ciudades, Transporte y Turismo Sostenible". Gracias a los esfuerzos realizados por la ciudadanía y la secretaría de cultura, recreación y deporte Bogotá recibió el premio de Asentamientos Humanos Globales en Cultura Sostenible por la experiencia Ciclovía de Bogotá.

Es tanta la acogida de los ciudadanos por este medio de transporte que según la encuesta Bienal de Culturas, la bicicleta ocupa el cuarto lugar como medio de transporte principal sobrepasando la moto y el taxi para el año 2015.

De esta forma Bogotá, al igual que otras ciudades como Ámsterdam, Copenhague, Curitiba, Montreal, Portland, Basilea, Barcelona, Beijing y Trondheim, se perfila como un promotor del uso de la bicicleta y un comprometido con el ambiente.

Las bicicletas, al igual que otros medios de transporte, requiere de un mantenimiento por parte del usuario para asegurar un desplazamiento eficiente. Es de conocimiento general que el mantenimiento de las bicicletas no corresponde a un gasto muy elevado a comparación de los demás vehículos de transporte, esto debido a la complejidad de sus sistemas mecánicos los cuales comparados con los otros no son tan complejos. Sin embargo, esto no significa que este vehículo no se deba mantener en buenas condiciones debido a que una bicicleta en mal estado repercute directamente en un mayor gasto energético por parte del usuario y la posibilidad de causar accidentes.

Dada esta problemática, es importante elaborar una estrategia que permita a la creciente demanda de usuarios poder detectar las fallas en su vehículo con el propósito de prevenir accidentes y mantener en buen estado su vehículo.

El procedimiento llevado a cabo por parte de los especialistas en mecánica de bicicletas consiste en observar y escuchar el sonido emitido por el vehículo y, posteriormente, realizar un diagnóstico para su correcto mantenimiento.

El objetivo de este trabajo consiste en llevar el conocimiento de estos especialistas a una máquina para su posterior uso por parte de los ciudadanos que utilizan este medio de transporte. Para esto se pretende utilizar las Máquinas de Soporte Vectorial las cuales permiten asociar un conjunto de características con una clase, en este caso el conjunto de características corresponde al sonido emitido por la bicicleta y el diagnóstico es la clase.

Esta técnica ha demostrado ser eficiente para la resolución de problemas del diario vivir, como lo es el dictado por voz [27], reconocimiento de texto y rostros [16], entre otros. Considerando el éxito alcanzado por esta técnica, se decidió hacer uso de ella dado que en trabajos realizados anteriormente en problemas semejantes a la clasificación de sonidos se han obtenido resultados satisfactorios, con altos índices de aceptación y precisión.

Capítulo 1

TITULO Y DEFINICIÓN DEL TEMA DE INVESTIGACIÓN

DETECCIÓN DE FALLAS EN BICICLETAS BASADO EN ACÚSTICA IMPLEMENTANDO MÁQUINAS DE SOPORTE VECTORIAL

Tema de Investigación

Análisis de Señales, Psicoacústica, Caracterización de Señal y Máquinas de Soporte Vectorial, Aprendizaje de Máquina.

Holotipo de Investigación

El tipo de investigación permite pronosticar algunas fallas presentadas en las bicicletas y que puedan ser inferidas a partir del sonido, por lo tanto el holotipo de la investigación es predictiva.

Capítulo 2

ESTUDIO DEL PROBLEMA DE INVESTIGACIÓN

2.1. Planteamiento del Problema

La creciente demanda de ciudadanos movilizados en bicicleta presentan una oportunidad para la elaboración de servicios orientados a mejorar la experiencia del transporte urbano. Los seguros contra accidentes, el mantenimiento y la reparación corresponden solo a una pequeña parte de los servicios que pueden ser ofrecidos a este nicho de mercado.

Uno de los servicios más solicitados por los usuarios corresponde a la reparación y mantenimiento de su vehículo debido al desgaste sufrido sobre las diferentes piezas causado por su diario uso y el mal estado de las vías.

De no facilitar el acceso a los usuarios a este servicio, existe una mayor probabilidad de que aumente el número de accidentes causados por problemas mecánicos, perjudicando la imagen de este medio de transporte amigable con el ambiente.

Las técnicas de aprendizaje de máquina se presentan como una herramienta disponible para sistematizar estos servicios y mejorar el acceso por parte de los usuarios a los mismos. La construcción de un modelo capaz de identificar problemas mecánicos en bicicletas permitiría a los usuarios

acceder a parte del conocimiento de un mecánico virtual y dar una posible solución a sus problemas de movilidad.

2.2. Formulación del Problema

¿Es posible diagnosticar problemas mecánicos a partir del sonido emitido por la cadena de una bicicleta a través de un modelo óptimo de máquinas de soporte vectorial capaz?

2.3. Sistematización del Problema

- ¿Qué tratamientos se debe realizar sobre la señal para obtener las características de la misma?
- ¿Cuáles son las características más relevantes del sonido que permiten asociarla eficientemente a un problema mecánico?
- ¿Cuánto es el número de ejemplos de entrenamiento necesarios para abstraer el conocimiento de un mecánico hacia la deteccion de fallas a partir del sonido en un modelo óptimo de máquinas de soporte vectorial?

Capítulo 3

OBJETIVOS DE LA INVESTIGACIÓN

3.1. Objetivo General

Diseñar, desarrollar y evaluar un modelo de clasificación basado en máquinas de soporte vectorial que permita reconocer el estado de funcionamiento del sistema de la cadena de una bicicleta según su acústica.

3.2. Objetivos Específicos

- Construir una base de datos usando medios electrónicos de grabación para incorporar características del sonido emitido por la cadena de la bicicleta, obtenidas mediante Matlab y permitir su asociación a un problema mecánico.
- Simular el conocimiento en mecánica de bicicletas hacia percepción de sonidos orientados al funcionamiento, mediante la adaptación e implementación de un modelo usando máquinas de soporte vectorial.
- Desarrollar un ambiente de simulación implementando Matlab con la finalidad de evaluar y validar el modelo de reconocimiento de problemas mecánicos.

Capítulo 4

JUSTIFICACIÓN DE LA INVESTIGACIÓN

Los usuarios que optan por la bicicleta como medio de transporte deben revisar constantemente el buen estado de su vehículo para evitar accidentes y un mayor gasto de energía. Desafortunadamente, no todos los usuarios poseen el conocimiento necesario para realizar un mantenimiento general de su vehículo.

Desde un punto de vista mecánico, el sonido emitido por la bicicleta alerta a los usuarios acerca de la condición de su vehículo, los usuarios aprenden a reconocer el buen estado de su vehículo a partir de un sonido y en el momento en que perciben un sonido diferente a este lo asocian a un problema mecánico. Existe un área especializada en el estudio de la percepción del sonido y sus respuestas psicológicas conocida como psicoacústica.

La información que definen las señales son valores definidos paramétricamente que no permiten visualizar toda la información que contienen, la cual puede ser utilizada y aprovechada con beneficios prácticos. Por lo anterior, es necesario procesar la señal con herramientas matemáticas para llegar a la representación más efectiva que permita encontrar información. La señal del sonido puede ser caracterizada por su composición o por su dinámica, y esta caracterización se realiza por medio de transformadas.

Para el caso de esta investigación, se hace necesario caracterizar las señales que no se encuentran en estado estacionario por medio del uso de transformadas y asociarla a la existencia de un problema mecánico,

permitiendo la creación de una base de datos pertinente para el aprendizaje un sistema inteligente.

Es bien conocido que el campo de la inteligencia artificial pretende generar herramientas computacionales para simular la forma de aprendizaje de los seres humanos. El uso de una técnica de inteligencia artificial, a partir de una buena base de datos, permitirá distinguir las anomalías sonoras y generar un diagnóstico sobre el estado de la bicicleta.

El desarrollo de dicho modelo permitirá la creación de aplicaciones que facilitarán el acceso al servicio de mantenimiento y reparación de este vehículo, beneficiando ampliamente a todos los usuarios que usen este medio de transporte y dispongan de dispositivos inteligentes.

Además, los resultados de esta investigación podrán ser ampliamente utilizados para la aplicación de otras técnicas de aprendizaje de máquina diferentes a las aquí implementadas, el diagnóstico de otros problemas mecánicos diferentes a los abordados y la extensión al diagnóstico sobre otros tipos de vehículos.

El éxito de este trabajo representaría la oportunidad de generar más trabajos de investigación asociados a la aplicación del análisis de señales, las técnicas de aprendizaje de máquina y la psicoacústica, permitiendo articular las áreas de la ingeniería con las áreas de la psicología.

Por lo tanto, la construcción de este trabajo no solo representa la elaboración de un modelo matemático, sino la posibilidad de creación de producto software y la ampliación del conocimiento en la aplicación de la inteligencia artificial.

Capítulo 5

HIPÓTESIS DE TRABAJO

Es posible construir un modelo óptimo de máquinas de soporte vectorial basado en la señal de sonido emitido por la bicicleta y su asociación a un problema mecánico.

Capítulo 6

ASPECTOS METODOLÓGICOS

En este capitulo se describen los aspectos metodológicos del proyecto de investigación a través de la definición del tipo de estudio, la explicación del método de investigación, la exposición fuentes y técnicas para la recolección de la información y los métodos tratamiento de la información.

6.1. Tipo de Estudio

El proyecto busca la creación de un modelo matemático capaz de asociar un conjunto de características n dimensionales a un conjunto de vectores unitarios k dimensionales. Por lo tanto, el tipo de estudio es formulativo.

6.2. Método de Investigación

El desarrollo del proyecto de investigación se contempla en cinco fases con sus correspondientes actividades principales descritas a continuación:

6.2.1. Exploratoria

En esta fase se define el campo de acción en el que se desenvuelve la investigación.

- Análisis y estudio detallado de las investigaciones previas y actuales sobre análisis de señales y técnicas de aprendizaje de máquina aplicado a psicoacústica.
- Estudio sobre el mantenimiento y reparación de bicicletas.

6.2.2. Diseño

En esta fase se realiza la recolección de datos y el diseño del modelo de máquinas de soporte vectorial.

- Captura de sonidos emitidos por bicicletas.
- Filtro sobre señales.
- Caracterización de señales.
- Asociación de señales a problemas mecánicos.
- Creación de base de datos.
- Diseño de modelo de máquinas de soporte vectorial.
- Diseño de métricas de desempeño.

6.2.3. Implementación

En esta fase se realiza la implementación de los diseños obtenidos en la fase de diseño.

- Implementación del modelo de máquinas de soporte vectorial.

6.2.4. Resultados

En esta fase se realiza el análisis de las pruebas realizadas y los ajustes necesarios sobre el modelo, en caso de no obtener los resultados deseados se volverá a la fase de diseño hasta lograr el desempeño deseado.

- Evaluación del desempeño desarrollado a través de simulaciones con datos.
- Análisis de los resultados obtenidos.

6.2.5. Documentación

En esta fase se realiza la recolección y refinación de la documentación obtenida en las fases anteriores y se realizan las publicaciones pertinentes.

- Realizar un artículo publicable en una revista indexada.
- Documentación del proyecto de investigación.

6.3. Fuentes y Técnicas para la Recolección de la Información

Para el desarrollo del trabajo de investigación se toma como base los trabajos desarrollados en [16], [24] y [11].

La recolección de datos se realiza con observación directa, entrevistas y encuentros con expertos en mecánica de bicicletas. Se toma una bicicleta en buen estado y en un ambiente sin ruido se graba el sonido emitido por esta, después intencionalmente se genera un problema mecánico con la ayuda del experto y se graba el nuevo sonido emitido. Este proceso se realiza con diversas bicicletas y problemas mecánicos para la construcción de una base de datos.

6.4. Tratamiento de la Información

Luego de la construcción de la base de datos, se procede a aplicar filtros para eliminar y normalizar la señal capturada. Posteriormente, se realiza la aplicación de transformadas para obtener las características inherentes de la señal. Finalmente, se construye una nueva base de datos con las características de la señal asociadas a un problema mecánico.

Capítulo 7

ALCANCES, LIMITACIONES Y RESULTADOS ESPERADOS

7.1. Alcances

Dada la cantidad de posibles fallos en una bicicleta y la complejidad que presentan la extracción, análisis y caracterización del sonido emitido por esta, poder determinar todos los tipos fallas que puedan presentarse en el vehículo puede extender la duración del proyecto. Por lo tanto, solo se tendrán en cuenta los siguientes puntos:

- Se analizarán únicamente anomalías a partir del sonido emitido por la cadena y su interacción con el plato, el piñón y el carrete. En caso de no reconocer la falla asociada, siemplemente indicara que no presenta un sonido de bicicleta en buen estado.
- Dado que el ruido emitido bicicleta depende del terreno donde ésta se movilice, solo se tendrá en cuenta el sonido de la bicicleta con la llanta trasera girando, es decir, en un estado estacionario sin que la bicicleta tenga contacto con el terreno.

- El sonido presente en el ambiente puede generar ruido en la señal emitida por la bicicleta, perturbando sus características y perjudicando el objetivo de la investigación. Por lo tanto las señales se capturan en un ambiente controlado donde no esten presentes todos los posibles ruidos emitidos por el ambiente de la ciudad. No está dentro del alcance de esta investigación la eliminación del ruido del ambiente sobre la señal.

7.2. Limitaciones

Dado que para resolver este problema es necesario contar con una serie de recursos físicos, humanos y de software, se presentan ciertas limitaciones que pueden en algún momento afectar el normal desarrollo del proyecto. Dentro de las principales limitaciones se contemplan las siguientes:

- Para la implementación del modelo matemático se planea utilizar matlab, dado que el licenciamiento para su uso es elevado, se dispone de los laboratorios de la universidad distrital los cuales cuentan con el licenciamiento necesario.

- Considerando la limitación anterior, los horarios en los que se puede hacer uso de los laboratorios de la universidad para el desarrollo de actividades extracurriculares es escaso y en algunas ocasiones no disponible.

- El tiempo de asesoría con el director del proyecto es sumamente importante, ya que son pocas las ocasiones en que coinciden los horarios libres de los investigadores y este. Este tiempo es necesario para la orientación sobre la ejecución de cada una de las actividades del proyecto.

- Puesto que la universidad no cuenta con un ambiente de pruebas donde se pueda realizar la extracción del sonido sin señales que interfieran, el poder conseguir un ambiente de pruebas externo que favorezca la recoleccion de datos dicientes es una tarea que posiblemente dificultará el pleno desarrollo del proyecto.

7.3. Resultados Esperados

El modelo de máquinas de soporte vectorial será capaz de caracterizar ciertos problemas presentes en el correcto funcionamiento de la bicicleta. en caso de presentar anomalias en el sonido emitido que difieran al de una bicicleta en buen estado, el resultado sera obtenido a partir de la captación del sonido en pocos segundos, brindando información para prevenir el deterioro del vehículo y hacer más ameno el uso de la bicicleta gracias a su facilidad de uso y accesibilidad.

Capítulo 8

MARCO DE REFERENCIA

8.1. Análisis Tiempo-Frecuencia

Algunos sistemas presentan signos y comportamientos que son registrados a lo largo del tiempo; a esta manera de interpretarlos se le denomina "señal".

Las señales que pueden ser descritas y modeladas por expresiones matemáticas son denominadas señales determinísticas. Las señales determinísticas pueden ser estacionarias, que mantienen constantes en el tiempo en parámetros temporales significativos o no estacionarias con cambios de frecuencia a través del tiempo.

A partir del análisis de estas señales, se han venido creando técnicas que se empezaron a desarrollar alrededor de los años 1940, son técnicas matemáticas que permiten estudiar el comportamiento de la señal del ruido en dos dimensiones o dos dominios, los cuales son el tiempo y la frecuencia, son bastante utilizadas en el área de procesamiento y análisis de señales de tipo no estacionarias, como por ejemplo, al momento de usar los pedales en la bicicleta el sonido emitido es una señal no estacionaria, así que estas técnicas de análisis tiempo-frecuencia son las más convenientes para el estudio y caracterización de estas señales. Dentro de las técnicas más utilizadas pertenecientes a esta familia se encuentran la Transformada de Fourier, Transformada de Fourier rápida o de tiempo Corto y Transformada Wavelet.

8.1.1. Transformada de Fourier

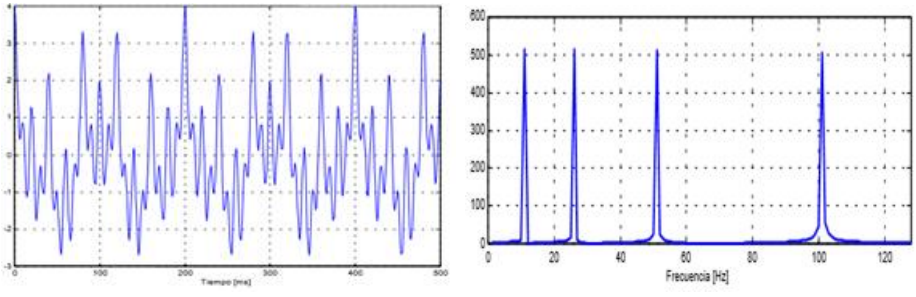
Es una función desarrollada en términos de series trigonométricas que pueden ser obtenidas por integración. La transformada de Fourier puede expresarse como una suma de funciones seno y coseno, permitiendo determinar el contenido de la frecuencia en la función.

La transformada de Fourier expresa una función periódica como la suma de exponenciales complejas periódicas evidenciable en la ecuacion 8.1.

$$STFT_x^w(t', f) = \int_t [*x(t) * w(t - t')] * e^{-2*\pi*ift} dt \tag{8.1}$$

Donde: $X(f)$ es la transformada de Fourier de la señal en el dominio del tiempo.

En la fórmula anterior podemos evidenciar que no importa el instante de tiempo en el que aparece la componente de frecuencia f porque no afecta el resultado de la integración. Por lo tanto es por esto que la transformada de Fourier sólo permite entregar la información acerca de la existencia o no de las componentes de frecuencia.



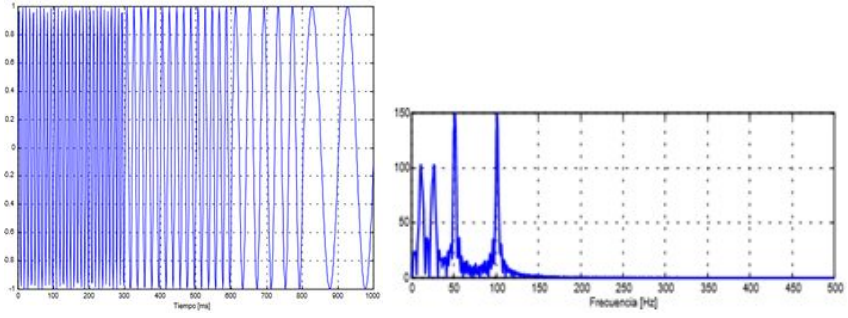
(a) Señal Estacionaria (b) Espectro de Frecuencias

Figura 8.1: Señal Estacionaria y su Espectro de Frecuencias

En la figura 8.1 se puede apreciar una señal estacionaria con frecuencias 10, 25, 50, y 100 Hz y se encuentran presentes en cualquier instante. La primera imagen representa la señal en dominio del tiempo (variable independiente) junto con la amplitud (variable dependiente). La segunda

imagen evidencia su respectiva transformada de Fourier en función de la frecuencia.

Ahora para otro caso se tomarán en cuenta cuatro componentes de frecuencia diferentes, para cuatro intervalos de tiempo distintos (señal no estacionaria). El intervalo de 0 a 300 ms tiene una señal de 100Hz, el intervalo de 300 a 600 ms de 50 Hz, de 600 a 800ms de 25Hz y finalmente de 800 a 1000ms una frecuencia de 10 Hz y al realizar su transformada de Fourier se obtiene la figura 8.2 con los cuatro picos de frecuencia.



(a) Señal No Estacionaria (b) Espectro de Frecuencias

Figura 8.2: Señal No Estacionaria y su Espectro de Frecuencias

Para ambos casos el espectro de frecuencias representado es muy similar, a pesar que ambas señales en el dominio del tiempo son completamente diferentes. Se puede ver por tanto que la transformada de Fourier puede presentar el contenido espectral de la señal, pero no la localización temporal de sus componentes.

8.1.2. Transformada rápida de Fourier

Ana María Moros Vivas 20 Seguidamente en 1946, Dennis Gabor, un físico británico-húngaro, presentó la transformación de Gabor, conocida como la Transformada de Fourier rápida o de Tiempo Corto.

Esta transformada nace a partir de la necesidad de ver el comportamiento de la frecuencia de la señal y su comportamiento en diferentes instantes de tiempo. La transformada rápida de Fourier básicamente se basa en di-

vidir la señal en varias partes en donde se puede asumir como estacionaria. El periodograma de esta señal tendrá un aspecto de tres dimensiones cuyos ejes indican la frecuencia, el tiempo y el valor de la potencia.

Para realizar el propósito de la transformada la señal debe ser multiplicada por una señal de ventana con una anchura igual a la parte de la señal que puede ser considerada estacionaria. Esta función de ventana se traslada en el tiempo y al producto se le aplica la transformada de Fourier.

Una vez realizada la transformada de Fourier se pueden obtener las frecuencias de la señal analizadas por la ventana en cada una de las traslaciones de la misma obteniendo las tres dimensiones: ventana (t), frecuencia (F) y potencia (FA^2) y mediante de la ubicación de sus puntos se puede obtener el periodograma.

La ecuación que representa la transformada rápida de Fourier es la mostrada en la ecuación 8.2.

$$STFT_x^w(t', f) = \int_t [*x(t) * w(t - t')] * e^{-2*\pi*ift} dt \tag{8.2}$$

Donde:

$X(t)$: Señal definida en X $W(t - t')$ Función ventana, retrasada en el tiempo un valor de t' F: Frecuencia t: Tiempo t': Tiempo en el cual se ubica el centro de la ventana

En esta transformada es bueno tener en cuenta que la variación de la longitud de la ventana agrega resultados diferentes. Cuando la ventana es más estrecha es obtenida una mejor resolución en el tiempo, así como mejor representación de la estacionalidad pero peor resolución en la frecuencia. Por el contrario una ventana ancha permite una buena resolución en el dominio de la frecuencia pero pobre resolución en el dominio del tiempo. El éxito de esta transformada de pende de la elección de la ventana para la señal a analizar. Este problema debe solucionarse con una transformada que otorgue información importante con relación a la información tiempo-frecuencia presente en la señal.

8.1.3. Transformada Wavelet

La Transformada de Wavelet ha nacido gracias a una serie de estudios para refinar el tratamiento de señales y superar las deficiencias me-

diante la Transformada de Fourier que tenía dificultades para ubicar en el tiempo las frecuencias predominantes cuando la señal era no estacionaria (la trasformada de Fourier puede entregar información en frecuencia de la señal, pero no puede indicar el instante de tiempo en el que parece) "http://www.javeriana.edu.co/biblos/tesis/ingenieria/tesis334.pdf" o la trasformada de Fourier de tiempo corto que cuando se desea ver frecuencia o tiempo, dependiendo de la ventana se pierde información de alguno de los dos. La Transformada Wavelet se ha trabajado desde la década de los 80, es una transformada que da bastante información acerca de la distribución de energía de la señal tanto en el dominio del tiempo como en el dominio de la frecuencia. La ventaja que tiene la transformada de Wavelet sobre la transformada de Fourier es que la transformada de Wavelet se localiza en el dominio de la frecuencia y en el dominio del tiempo haciendo referencia a la dilatación y a la traslación respectivamente.

El proceso matemático que realiza la transformada Wavelet es la división de la señal en pequeños fragmentos con el fin de poder capturar todos los comportamientos y singularidades que presenta la señal a través del tiempo y la frecuencia. El análisis Wavelet está especialmente diseñado para señales con cambios bruscos. Por lo tanto la Transformada de Wavelet recorre la señal con varios tamaños de ventana adaptados a la frecuencia diferenciándose de la transformada de Fourier de tiempo corto, permitiendo examinar señales con tiempo de cálculo reducido, teniendo más información de la señal de análisis.

Las transformaciones de wavelets resultaron funcionar mucho mejor que las transformaciones de Fourier, porque eran mucho menos susceptibles a pequeños errores de cómputo. Y por lo tanto son ampliamente utilizadas en la labor de caracterización de la señal. La transformada de Wavelet continua se define como se muestra en la ecuación 8.4.

$$C(\tau, s) = \int_{-\infty}^{\infty} f(t) * \psi^*_{\tau,s}(t)dt \tag{8.3}$$

Donde:

$$\psi_{\tau,s}(t) = \frac{1}{\sqrt{|s|}}\psi(\frac{t-\tau}{s}) \tag{8.4}$$

Para el caso de esta transformada la longitud de la ventana es finita, siendo una función de naturaleza oscilatoria, consta de una denominada "Wavelet madre" que es una función principal que permite la generación de otras funciones ventanas. Ahora la tarea para poder elegir un tipo de "Wavelet" para la caracterización de una señal debe tenerse en cuenta propiedades como la suavidad, localización espacial y temporal, localización de frecuencias, simetría y ortogonalidad. Dentro de los usos de la transformada Wavelet tenemos el análisis de señales electrocardiográficas, sísmicas, de sonido, de radar, así como comprensión de imágenes y reconocimiento de patrones. Ha sido adoptada como herramienta para un número de aplicaciones de la naturaleza diversa, reemplazando a menudo a la transformada de Fourier, en áreas como dinámica molecular, astrofísica, sísmica, óptica, mecánica de turbulencia, mecánica cuántica, procesamiento de imágenes, análisis de señales médicas, como electrocardiogramas, análisis de proteínas y ADN, climatología, topografía y geográfica, reconocimiento de voz y análisis multifractal.

8.2. Máquinas de Soporte Vectorial

8.2.1. Aprendizaje Supervisado

El aprendizaje supervisado consiste en la aplicación de un conjunto de algoritmos para predecir el valor de unos datos basado en un conjunto de ejemplos. En este tipo de aprendizaje, se dan las "respuestas correctas" al problema que se pretende resolver, esto se conoce como un problema de regresión: dar un valor continuo a un conjunto de datos para predecir el valor de la salida dado un valor diferente al del conjunto de datos (x, y). En la figura 8.3, se plantea una hipótesis como resultado de un algoritmo de aprendizaje, el cual recibe como insumo un conjunto de datos y parámetros para dar un valor estimado de y dadas las características x, estas características y valores estimados pueden estar en una dimensión R^n [8].

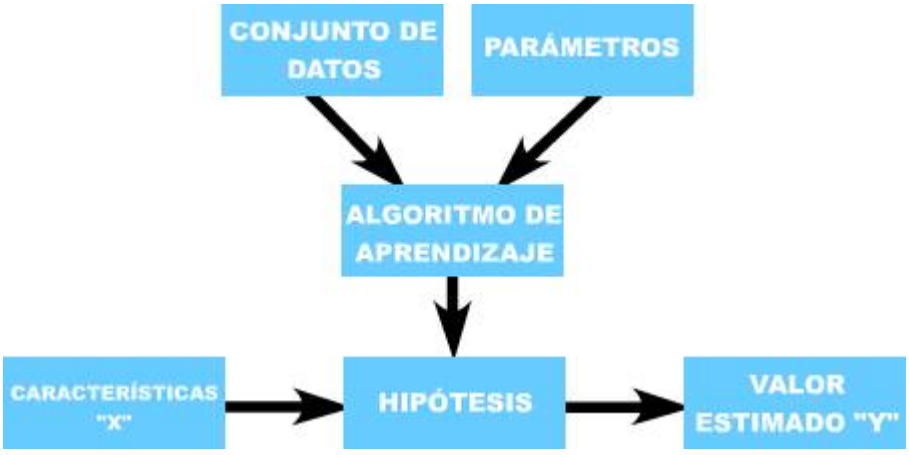


Figura 8.3: Funcionamiento de algoritmo de aprendizaje supervisado

8.2.2. Definición

Las máquinas de soporte vectorial o SVM por sus siglas en ingles corresponde uno de los algoritmos de aprendizaje de supervisado. Este algoritmo fue propuesto por Vladimir N. Vapnik y Alexey Ya. Chervonenkis en el año de 1963. Ellos propusieron un clasificador el cual aprovechaba las características de los Kernels para crear un amplio margen entre en el conjunto de datos. Esta característica le permite a los SVM la construcción de una serie de hiperplanos.

8.2.3. Forma de Operación

El principio de operación de las máquinas de soporte vectorial consiste en la creación de una función lineal en un espacio de alta dimensión, esta característica formada por el mapeo no lineal de un vector M-dimensional en un espacio característico K-dimensional (K ¿M) mediante el uso de la función $\phi(x)$.La separación de dos o más clases se realiza por el hiperplano definido formado por $g(x) = W^T\phi(x) + b = 0$, con $\phi(x)[\phi_1(x), \phi_2(x), ..., \phi_k(x),]^T$, w como el vector de pesos de la red $w = [w_1, W_2, ..., w_k]^T$, y b es el sesgo. El aprendizaje de la SVM está diri-

gida a la maximización del margen de separación entre dos o más clases, que se denota aquí como $d_1 = 1$ y $d_2 = -1$. Matemáticamente, esto corresponde con la minimización de la función de coste $\phi(w, \epsilon)$ definida como se muestra en la ecuación 8.5 para $i = 1, 2, ..., p$y con restricciones mostradas en 8.6 y 8.7, $C > 0$ corresponde al parámetro de regularización.

$$min\phi(w, \epsilon) = \frac{1}{2} * W * W^T + C * \sum_{i=1}^{P} \epsilon_i \tag{8.5}$$

$$d_i(W^T * \phi(x) + b) \geq 1 - \epsilon_i \tag{8.6}$$

$$\epsilon_i \geq 0 \tag{8.7}$$

8.2.4. Kernel

Al momento de realizar la imprementacion de máquinas de soporte vectorial no todos los casos a estudiar se presentan de dos dimensiones y las limitaciones computacionales no permiten ser utilizadas en todos los casos del mundo real, por lo cual el algoritmo usado debe contemplar:

- Casos con conjuntos de datos no separados
- Clasificaciones mayores a dos categorías
- Mas de dos variables

La representación de varios casos por medio de funciones kernel otroga una solución a este inconveniente aumentando la capacidad computacional de máquinas que usan el aprendizaje lineal, otorgando mas capacidad de entradas y entradas con mas dimensionalidad. Cuando los datos no pueden ser mostrados en dos dimensiones se pueden extender a tres dimensiones para hacer mas fácil la clasificación de las clases mediante un hiperplano [6].

Los Kernel usados comunmente son:

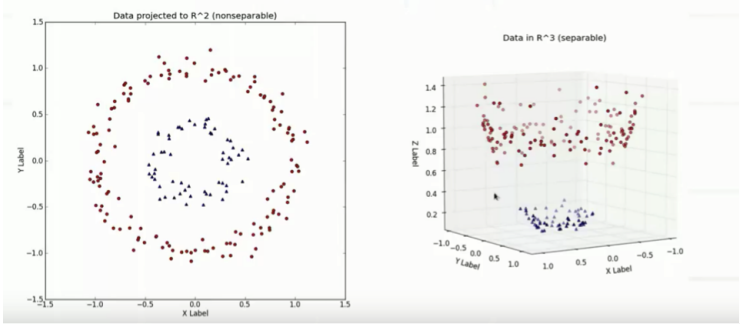


Figura 8.4: Datos extendidos en varias dimensione

- Polinomial homogéneo: efecto del grado
- Perceptron
- Función de base radial Gaussiana

8.3. Fallas en Bicicleta

El tren de transmisión para una bicicleta incluye platos y piñones. Comúnmente las bicicletas de ruta tienen dos platos: uno pequeño de 39 dientes y uno grande de 53 dientes. La parte trasera de la bicicleta en donde se alojan los piñones se denomina cassette. Que comúnmente consta de entre nueve y 10 piñones, aunque el mercado ofrece bicicletas con piñones variados.

A diferencia de los platos, teniendo en cuenta los piñones entre menos dientes más esfuerzo se requiere por parte del conductor de la bicicleta. El avance puede variar entre las combinaciones posibles entre platos y piñones cada combinación arroja un avance diferente, así que hay que buscar la correcta combinación para que la fuerza alcance para las necesidades que se requieran por parte del vehículo Las relaciones que avanzan menos requieren menos fuerza y se utilizan generalmente en los ascensos. En cambio, las de mayor avance requieren mayor fuerza y son ideales para el terreno plano [3].

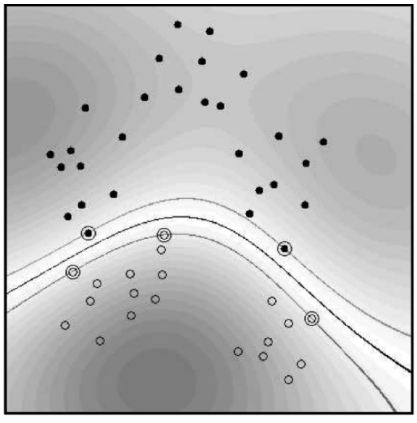


Figura 8.5: KERNEL Polinomial

Es de importancia tener en cuenta que utilizar el piñón más grande con el plato grande y el piñón pequeño con el plato pequeño representan un desgaste realmente alto por parte de la cadena. Claramente el correcto manejo de la relación entre piñones y platos además de situaciones de acuerdo al terreno, bicicleta, viento, etc permite a la cadena otorgarle una mayor vida útil.

El manejo de los piñones es complejo y lo mejor para decidir la relación correcta es desde la bicicleta, al lado del entrenador, y poco a poco entendiendo la combinación perfecta entre platos y piñones en las distintas situaciones de acuerdo al terreno, bicicleta, viento, entre un lote, individualmente, etc. Y solo después de muchos kilómetros el ciclista tendrá el juicio para combinar plato y piñón de la mejor manera [1].

No para todos los usuarios de las bicicletas es fácil el correcto manejo y funcionamiento de la trasmisión, por lo tanto es natural que el vehículo de desgaste y esté expuesto a fallos. Algunos daños que pueden ser tenidos en cuenta son:

- La cadena no cambia a un plato más pequeños: Esto generalmente se da porque hay mucha suciedad alojada en el cable o las fundas. Para este inconveniente es recomendable limpiar los cables, lubricarlos y desengrasar las fundas.

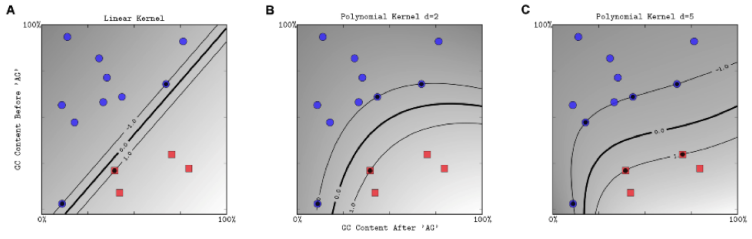


Figura 8.6: Kernel Perceptron

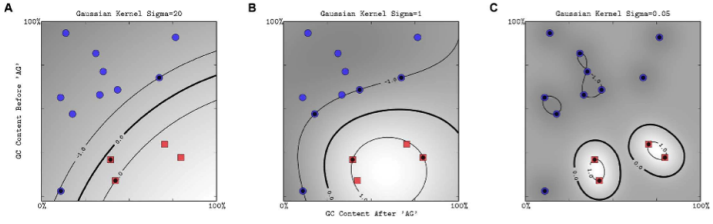


Figura 8.7: Función de base radial Gaussiana

- La cadena no cambia a alguna corona o tiene dificultad para hacerlo: Es un fallo que sucede porque el cable se encuentra demasiado tenso o el desviador se encuentra mal ajustado. Para esto es necesario ajustar tanto el cable como el desviador.
- Cambio de corona cuando se realiza fuerza en los pedales: Este error puede deberse a varias situaciones ya sea que los piñones están desgastados, el plato doblado o los eslabones agarrotados. En algunos casos para este problema es necesario cambiar la cadena como solución.
- La cadena roza con el desviador y tiende a salirse: Este fallo se debe a que el eje del pedalier se encuentra doblado o el pedalier desgastado.

Capítulo 9

CONSTRUCCIÓN DE BASE DE DATOS

Considerando los problemas más comunes asociados a una bicicleta, se escogieron cinco clases para ser caracterizados:

1. **Clase 1:** Las pastillas del freno esta rozando con el rin de la bicicleta.
2. **Clase 2:** Un radio de la bicicleta no se encuentra en la posición adecuada.
3. **Clase 3:** Los cambios de la bicicleta se encuentran desincronizados.
4. **Clase 4:** La cadena de la bicicleta esta sucia.
5. **Clase 5:** La bicicleta no presenta ningún problema mecánico.

Para la toma de muestras se utilizaron dos celulares, un Sony Xperia m4 aqua y un Samsung Galaxy S7 EDGE, estos fueron ubicados a 2 cm de la fuente de origen. En los celulares se descargó la aplicación Smart Recorder para el almacenamiento de sonidos y se configuró la frecuencia de muestreo en 44.1 kHz.

Posteriormente, se tomo una bicicleta en buen estado, con 7 piñones y 3 platos, y se causó el defecto descrito por cada una de las clases. En este punto, se capturaron los sonidos durante 20 segundos cambiando los cambios de la bicicleta haciendo que la cadena pase por cada uno de los

platos y piñones, y despreciando la combinación 3-1 y 1-7, ya que la tensión generada sobre la cadena en estos cambios provocaba el choque de la cadena con el descarrilador [1].

Las muestras fueron almacenadas en carpetas con el nombre de los identificadores de las clases logrando un registro de 121 archivos. Estas carpetas fueron exploradas recursivamente por un algoritmo encargado de partir las muestras cada 4 segundos y obtener las siguientes características:

- Máximo.
- Promedio.
- Mínimo.
- Mediana.
- Distancia Pico a Pico.
- Distancia Pico a Raíz Cuadrada Media.
- Suma de Raíces Cuadradas.
- Raíz Cuadrada Media.
- Desviación Estándar.
- Varianza.
- Kurtosis.
- Poder.
- Energía de la Transformada de Wavelet.
- Entropía de la Transformada de Wavelet.

Al final de cada uno de los registros, se asoció el nombre de la clase a la cual pertenecía la muestra. De esta manera, se logro la construcción de una base de datos de 484 registros.

Capítulo 10

CONSTRUCCIÓN MODELO DE SVM

Una vez generada la base de datos de características se construyeron 6 modelos de maquinas de soporte vectorial descritos a continuación:

- SVM Lineal
- SVM Cuadrática
- SVM Cúbica
- SVM Gaussiano Refinado
- SVM Gaussiano Mediano
- SVM Gaussinano Grueso

Aprovechando la herramienta CLASSIFICATION LERNER proporcionada por MATLAB, se entrenaron los modelos dividiendo en 5 grupos los datos y tomando cada grupo para entrenar el modelo deseado. De cada grupo se toman sus datos para validación y el resto de los demás grupos para entrenamiento. Esto genera 5 modelos diferentes por cada propuesta, posteriormente se promedian para generar un modelo representativo de la propuesta.

Capítulo 11

RESULTADOS

En la tabla 11.1 presentan las métricas de precisión para los modelos desarrollados.

Modelo	**Precisión**
SVM Lineal	68.9 %
SVM Cuadrática	82.6 %
SVM Cúbica	84.7 %
SVM Gausiano Refinado	81.6 %
SVM Gausiano Mediano	77.3 %
SVM Guasiano Grueso	62.6 %

Cuadro 11.1: Precisión de Modelos de Máquinas de Soporte Vectorial.

Los resultados anteriores demuestran que el modelo de maquinas de soporte tipo cúbico es el que mejor caracteriza los datos.

En las figura 11.1 se aprecia la matriz de confusión del modelo propuesto. En ella se evidencia las ocasiones en las que el modelo predijo de manera correcta o incorrecta la clase a la que pertenecía cada ejemplo. En general se aprecia que los valores por debajo y encima la diagonal principal son bajos, indicando que el modelo clasifica de forma incorrecta en pocas ocasiones.

Para las figura 11.2, se aprecian las tasas de predictividad negativas por cada una de las clases. El modelo presenta tasas de predictividad altas

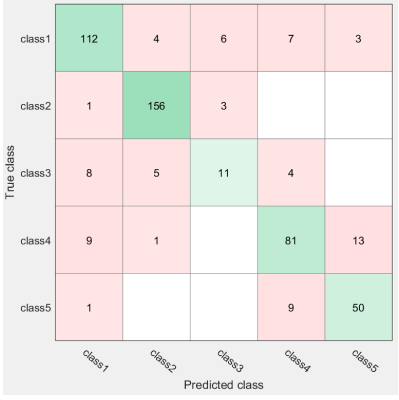


Figura 11.1: Matriz de Confusión General

para clases 1, 2, 4 y 5. Sin embargo, para la clase 3 el modelo presenta problemas al momento de la realizar la predicción.

Para las figura 11.3, se aprecian las tasas de predictividad positivas por cada una de las clases. El modelo presenta tasas de predictividad altas para clases 1, 2, 4 y 5. Sin embargo, para la clase 3 el modelo presenta problemas al momento de la realizar la predicción.

En las figura 11.4, se presenta las gráficas de la curva ROC (acrónimo de Receiver Operating Characteristic, o Característica Operativa del Receptor) para el modelo de maquinas de soporte vectorial cúbico. Estas gráficas, permiten deducir la capacidad de predicción del modelo por cada una de las clases.

Cuando el área debajo de la Curva corresponde al valor de 1, significa que el modelo tuvo un valor de predicción perfecto. Para las clases 1, 2, 4 y 5, se aprecia un valor muy cercano a 1 indicando que el modelo tiene un buen desempeño para estas clases. Sin embargo, la clase 3 es la que presenta el peor desempeño con un AUC de 0,82.

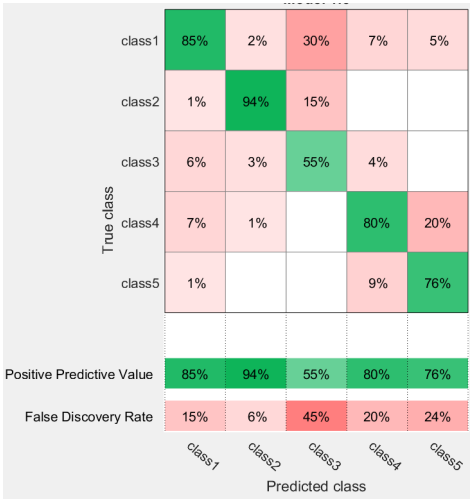
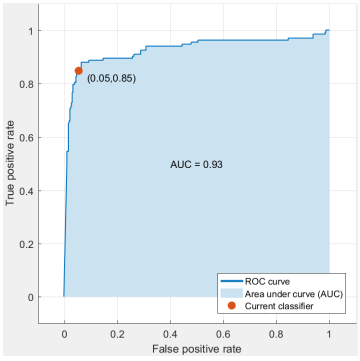


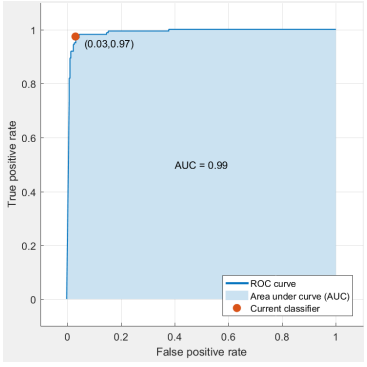
Figura 11.2: Matriz de Confusión para Falsos Positivos



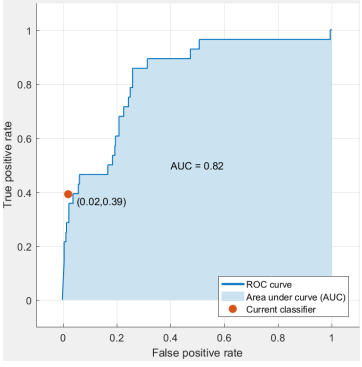
Figura 11.3: Matriz de Confusión para Falsos Negativos



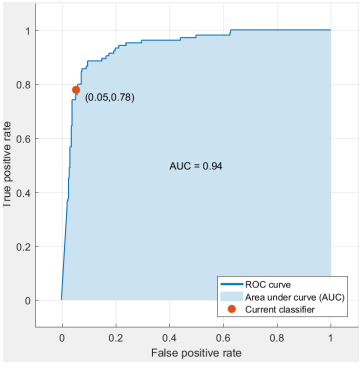
(a) Curva ROC para clase 1



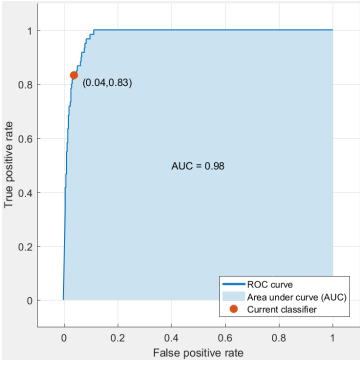
(b) Curva ROC para clase 2



(c) Curva ROC para clase 3



(d) Curva ROC para clase 4



(e) Curva ROC para clase 5

Figura 11.4: Curva ROC para el SVM cúbico.

Capítulo 12

CONCLUSIONES

12.1. Verificación, contraste y evaluación de objetivos

Tomando como punto de partida los objetivos planteados por el proyecto se hace un análisis del desarrollo de cada objetivo en el proyecto.

Objetivo general: Diseñar, desarrollar y evaluar un modelo de clasificación basado en máquinas de soporte vectorial.

Se lograron obtener varios modelos de maquinas de soporte vectorial cuyos resultados otorgaron cifras mayores al 60 %, logrando en el modelo mas acercado un porcentaje de aproximadamente 85 % gracias a los datos tomados y la manera de organizarlos .

Objetivo especifico: Construir una base de datos usando medios electrónicos de grabación para incorporar características del sonido emitido por la cadena de la bicicleta, obtenidas mediante MATLAB y permitir su asociación a un problema mecánico.

La recolección de los datos fue realizada fácilmente por parte de los dispositivos móviles, intentando obtener un sonido que además de estar en un ambiente que facilite el desarrollo del modelo mantuviera comportamiento constante en la trasmisión de la bicicleta, para posteriormente hacer el

tratamiento de cada señal mediante el uso de MATLAB.

Objetivo especifico: Simular el conocimiento de un experto en mecánica de bicicletas hacia percepción de sonidos orientados al funcionamiento, mediante la adaptación e implementación de un modelo usando máquinas de soporte vectorial.

El sistema arroja una adecuada clasificación de sonido emitido por el vehículo para los fallos contemplados previamente, demostrando que la técnica de máquinas de soporte vectorial es adecuada para la caracterización sin necesitar de grandes volúmenes de datos para otorgar resultados de valor

Objetivo especifico: Desarrollar un ambiente de simulación implementando Matlab con la finalidad de evaluar y validar el modelo de reconocimiento de problemas mecánicos.

Gracias al uso de la herramienta CLASSIFICATION LEARNER fue posible construir varias distintos modelos de maquinas de soporte vectorial para compararlos y obtener el mejor modelo.

12.2. Aportes Originales

- Es posible la implementación de un modelo basado en maquinas de soporte vectorial que reconozca e identifique las fallas presentes en elementos de la bicicleta a partir del sonido emitido por el vehículo. Los resultados obtenidos permiten validar los modelos generados y la caracterización de las fallas presentadas en el sistema de trasmisión de la bicicleta.

- Al comparar los resultados de desempeño de los 6 sistemas evaluados, se determina que el mejor comportamiento se obtiene con el uso del modelo de máquinas de soporte vectorial cubico (SVM), lo que no implica que el desempeño de los modelos no pueda ser optimizado, mejorando condiciones de sonidos ambientales, dispositivos para obtener la información y la muestra de los datos.

- A partir de la captación de señales de larga duración es posible otorgar mas elementos para la base de conocimiento que sean de valor y pueden aportar a la optimización del modelo basados en aprendizaje de maquina.
- Las máquinas de soporte vectorial son una técnica de aprendizaje de maquina con principio que ofrece mayor confiabilidad gracias a la reducción del riesgo estructural, además del uso de kernel para otorgarle una gran capacidad de generalización incluso cuando el conjunto de entrenamiento es pequeño.

Bibliografía

[1] Cadena-piñón, howpublished = http://concurso.cnice.mec.es/cnice2006/material107/mecanismos/mec_cadena-pinon.htm, note = Accessed: 2017-04-30.

[2] CLASIFICACIÓN DE SEÑALES SÍSMICAS POR MEDIO DE ONDITAS Y MÁQUINAS DE SOPORTE VECTORIAL, howpublished = https://www.researchgate.net/profile/german_castellanos-dominguez/publication/228546185_clasificacion_de_senales_sismicas_por_medio_de_onditas_y_maquinas_de_soporte_vectorial/links/09e4150a68f66e1605000000/clasificacion-de-senales-sismicas-por-medio-de-onditas-y-maquinas-de-s pdf, note = Accessed: 2017-04-30.

[3] Combinaciones de velocidades: piñones y platos, howpublished = https://melillaconbici.com/2011/01/23/combinaciones-de-velocidades-pinones-y-platos/, note = Accessed: 2017-04-30.

[4] Máquinas de Soporte Vectorial, howpublished = https://www.youtube.com/watch?v=_nu_vy_uanu&t=126s, note = Accessed: 2017-04-30.

[5] Número de vehículos en Bogotá creció un 91 % y malla vial 2,7 %, howpublished= http://www.elespectador.com/noticias/bogota/numero-de-vehiculos-bogota-crecio-un-91-y-malla-vial-27-articulo-3124 note = Accessed: 2017-04-30.

[6] SVM: Máquinas de Vectores Soporte, howpublished = `https://www.infor.uva.es/~calonso/mui-tic/mineriadatos/svm.pdf`, note = Accessed: 2017-04-30.

[7] Tres problemas clásicos con el cambio, howpublished = `https://nosinmibici.com/2013/05/19/tres-problemas-clasicos-con-el-cambio/`, note = Accessed: 2017-04-30.

[8] Tutorial sobre Máquinas de Vectores Soporte (SVM), howpublished = `http://www.ia.uned.es/~ejcarmona/publicaciones/[2013-carmona]%20svm.pdf`, note = Accessed: 2017-04-30.

[9] Wahyu Caesarendra, Achmad Widodo, and Bo-Suk Yang. Application of relevance vector machine and logistic regression for machine degradation assessment. *Mechanical Systems and Signal Processing*, 24(4):1161 – 1171, 2010.

[10] D. f. Wang, J. g. Jiang, Z. w. Liu, and X. l. Cao. Research on ane algorithm for sound quality control of vehicle interior noise. In *2010 Third International Conference on Information and Computing*, volume 3, pages 107–110, June 2010.

[11] Hai B. Huang, Xiao R. Huang, Ren X. Li, Teik C. Lim, and Wei P. Ding. Sound quality prediction of vehicle interior noise using deep belief networks. *Applied Acoustics*, 113:149 – 161, 2016.

[12] Hai B. Huang, Ren X. Li, Xiao R. Huang, Teik C. Lim, and Wei P. Ding. Identification of vehicle suspension shock absorber squeak and rattle noise based on wavelet packet transforms and a genetic algorithm-support vector machine. *Applied Acoustics*, 113:137 – 148, 2016.

[13] Roger Johnsson, Johan Odelius, and Matti Rantatalo. A new test track for automotive squeak and rattle sample detection. *Applied Acoustics*, 80:79 – 85, 2014.

[14] Sang-Kwon Lee, Ho-Wuk Kim, and Eun-Woo Na. Improvement of impact noise in a passenger car utilizing sound metric based on wavelet transform. *Journal of Sound and Vibration*, 329(17):3606 – 3619, 2010.

[15] Etienne Parizet, Erald Guyader, and Valery Nosulenko. Analysis of car door closing sound quality. *Applied Acoustics*, 69(1):12 – 22, 2008.

[16] M. P. Paulraj, S. Yaacob, and A. M. Andrew. Vehicle noise comfort level indication: A psychoacoustic approach. In *Signal Processing and Its Applications (CSPA), 2010 6th International Colloquium on*, pages 1–5, May 2010.

[17] Glenn Pietila and Teik C. Lim. Intelligent systems approaches to product sound quality evaluations – a review. *Applied Acoustics*, 73(10):987 – 1002, 2012.

[18] Roberto Ricci and Paolo Pennacchi. Diagnostics of gear faults based on {EMD} and automatic selection of intrinsic mode functions. *Mechanical Systems and Signal Processing*, 25(3):821 – 838, 2011.

[19] K. Soobbarayen, S. Besset, and J-.J. Sinou. A simplified approach for the calculation of acoustic emission in the case of friction-induced noise and vibration. *Mechanical Systems and Signal Processing*, 50–51:732 – 756, 2015.

[20] W.J. Staszewski, K. Worden, and G.R. Tomlinson. Time–frequency analysis in gearbox fault detection using the wigner–ville distribution and pattern recognition. *Mechanical Systems and Signal Processing*, 11(5):673 – 692, 1997.

[21] D. VÄSTFJÄLL, M.-A. GULBOL, M. KLEINER, and T. GÄRLING. Affective evaluations of and reactions to exterior and interior vehicle auditory quality. *Journal of Sound and Vibration*, 255(3):501 – 518, 2002.

[22] Y. Wang, C. m. Lee, H. He, and Y. Tian. A new intelligent technique for sound quality evaluation of nonstationary vehicle noises. In *2006 International Forum on Strategic Technology*, pages 33–36, Oct 2006.

[23] Y.S. Wang. Sound quality estimation for nonstationary vehicle noises based on discrete wavelet transform. *Journal of Sound and Vibration*, 324(3–5):1124 – 1140, 2009.

[24] Y.S. Wang, C.-M. Lee, D.-G. Kim, and Y. Xu. Sound-quality prediction for nonstationary vehicle interior noise based on wavelet preprocessing neural network model. *Journal of Sound and Vibration*, 299(4–5):933 – 947, 2007.

[25] Y.S. Wang, G.Q. Shen, H. Guo, X.L. Tang, and T. Hamade. Roughness modelling based on human auditory perception for sound quality evaluation of vehicle interior noise. *Journal of Sound and Vibration*, 332(16):3893 – 3904, 2013.

[26] Y.S. Wang, G.Q. Shen, and Y.F. Xing. A sound quality model for objective synthesis evaluation of vehicle interior noise based on artificial neural network. *Mechanical Systems and Signal Processing*, 45(1):255 – 266, 2014.

[27] Huadong Wu, M. Siegel, and P. Khosla. Vehicle sound signature recognition by frequency vector principal component analysis. *IEEE Transactions on Instrumentation and Measurement*, 48(5):1005–1009, Oct 1999.

[28] Y.F. Xing, Y.S. Wang, L. Shi, H. Guo, and H. Chen. Sound quality recognition using optimal wavelet-packet transform and artificial neural network methods. *Mechanical Systems and Signal Processing*, 66–67:875 – 892, 2016.

[29] Ji-Hyun Yoon, In-Hyung Yang, Jae-Eun Jeong, Sang-Gil Park, and Jae-Eung Oh. Reliability improvement of a sound quality index for a vehicle {HVAC} system using a regression and neural network model. *Applied Acoustics*, 73(11):1099 – 1103, 2012.