
Clasificación de puntos de operación de un sistema de bombeo con la ayuda de Máquinas de Soporte Vectorial.

**Master Thesis
Eduardo Manzanares Segovia.**

**Departamento de Mecánica de Fluidos y Turbomaquinaria.
Ingeniería Mecánica y de Procesos.**

**Supervisor:
Dipl.-Ing. Christian Licht**

June 10, 2013

1 Introducción

Este estudio trata de recopilar información sobre como funciona el método de clasificación de *Máquinas de Soporte Vectorial* para aprendizaje estadístico aplicado sobre una bomba que funciona en una instalación hidráulica. Las Máquinas de Soporte Vectorial, a partir de ahora SVM, es un método matemático que enseña a una máquina de aprendizaje como clasificar datos de un sistema bajo estudio. Dicho sistema, en este caso la bomba en su instalación hidráulica, es probada, medida y monitorizada en el banco de trabajo para una posterior clasificación de sus propiedades. Este método se encuentra en uso en infinidad de aplicaciones matemáticas, físicas y estadísticas debido a su capacidad predictiva a través de la *inteligencia artificial*, tal y cómo se explica a continuación.

La teoría de Máquinas de Soporte Vectorial contiene un algoritmo que vuelve a la máquina de aprendizaje (el ordenador) capaz de diferenciar valores concretos de un parámetro del sistema. En primera instancia, se monitorizan y miden las magnitudes del sistema de bombeo y a través de un acelerómetro (o sensor de vibración) se registran las vibraciones de cada *punto de operación*. Posteriormente, la máquina de aprendizaje es entrenada para reconocer las vibraciones y asociarlas con un valor concreto de las propiedades de sistema. Así, la máquina de aprendizaje puede predecir el valor de la propiedad que se desee, como por ejemplo, el caudal de agua o la velocidad de giro del rotor de la bomba entre otras.

La máquina de aprendizaje conoce de antemano los valores de las propiedades porque han sido medidos y grabados, y aprende de ellos. Es por esto por lo que pertenece al llamado *aprendizaje supervisado*. La precisión que la máquina entrega se obtiene comparando las predicciones con los valores reales observados en la monitorización, y serán representados a través de una herramienta visual denominada *matriz de confusión*.

El proyecto ha sido asistido por dos programas informáticos distintos. Primero, se ha utilizado LabView como interfaz con el sistema mediante los sensores y dispositivos fijos y posteriormente se ha utilizado Python con el algoritmo SVM implementado para clasificar los datos.

Es necesario alimentar a la maquina de aprendizaje con una serie temporal que la permita asociar los valores de las propiedades del sistema a la forma que adquiere dicha señal con cada uno de los distintos valores. Para esta tesis, se ha acoplado un sensor de vibración directamente a la bomba. Los sensores y dispositivos fijos en la instalación miden las propiedades del sistema de bombeo (conformando lo que se conoce como punto de operación) y paralelamente, el acelerómetro mide las vibraciones que se producen en la bomba. Se graba con la ayuda de LabView valores concretos de caudal y velocidad de rotacion del rotor que entregados por la instalación y tambien la señal que registra el acelerómetro en bucles

de 100 segundos. Así, para un punto de operación se tiene una grabación de 100 segundos de las vibraciones extraídas. Se van variando los puntos de operación y grabando a su vez las vibraciones con el objeto de establecer diferentes clases.

Después de la grabación de medidas, los datos obtenidos son utilizados como entrada en el programa de Python, que los clasifica. Las clasificaciones se hacen atendiendo a diferentes criterios y son analizados para extraer toda la información posible.

1.1 Motivación

El principal motivo por el cual se prueba la bondad del método SVM sobre la instalación hidráulica es comprobar si es posible monitorizar los puntos de funcionamiento simplemente usando un sensor, el acelerómetro. En lugar de incluir todos los sensores y dispositivos que requiere una instalación habitual para su medida y control, puede ser usado un solo sensor de vibración. Para este caso, se ha aplicado SVM en un aprendizaje estadístico supervisado, es decir, se conocen las clases de antemano, pero en futuros estudios se pretende clasificar a la vez que se miden las vibraciones, esto es, en tiempo real.

En el caso de que SVM sea desarrollado y mejorado para el uso en bombas, puede significar un ahorro económico y de tiempo por el uso de un único sensor. La instalación será más simple, reduciendo la posibilidad de averías debido a la menor cantidad de dispositivos instalados. Sin embargo, esta deducción no es por el momento aplicable en corto plazo aunque intentará ser demostrada y aplicada tras la investigación.

1.2 Objetivos

El principal propósito del estudio es evaluar cómo funciona el método de SVM para clasificar *puntos de operación* en sistemas de bombeo. Inicialmente, no es sabido si el método es aplicable o no sobre bombas y por ello, se tratará de comprobar si existe una tendencia que muestre que es un método aplicable y a continuación se analizarán los resultados. De esta manera, se puede decir que la finalidad es aprender lo máximo posible en primera aproximación.

Por otro lado, se quiere comprobar si el sensor de vibración o acelerómetro es una buena herramienta para tomar una señal temporal procedente del sistema y poder realizar las clasificaciones a través de dicha señal. Es importante recordar que el método SVM está basado en una serie temporal, y la elegida en este caso es la amplitud de las vibraciones de que se producen en la bomba. Se quiere probar si es este tipo de sensor el que obtiene los mejores resultados o por el contrario puede existir otro tipo de sensor que actúe en mejor

medida.

2 Estado del arte

2.1 Puntos de operación de bombas

La actuación de una bomba se basa en sus *curvas características*, que describen su comportamiento bajo determinadas circunstancias. Para hallar el punto de operación dos curvas han de ser trazadas: la altura total entregada por la bomba $H_r.v.s.Q$ y la curva característica de la instalación $H_r.v.s.Q$. Ambas curvas son dibujadas como función del caudal instantáneo de agua a una velocidad de giro del rotor constante. El punto de operación se encuentra en la intersección de ambas curvas. Leyendo este punto es fácil conocer el caudal y la altura de operación.




Figure 1: Punto de operación.

El punto de operación de un sistema de bombeo debe estar lo más próximo posible al punto de máxima eficiencia. Que el punto de operación se encuentre alejado del punto de máxima eficiencia significa que la bomba seleccionada no es adecuada para las condiciones y características del sistema de bombeo. Además, es recomendable que el sistema funcione lo más cerca posible del punto de operación. Como aproximación, el caudal no ha de disminuir más de un 25% ni aumentar más de un 10% con respecto al caudal del punto de operación.

2.2 Análisis de Series Temporales: Modelos Autorregresivos (AR)

La señal procedente del sensor de vibración ha de ser procesada para que sea manejable por el programa de Python que contiene el algoritmo de SVM. El estudio de series temporales tiene el propósito de analizar la evolución de una variable en el tiempo. La diferencia con el análisis de series no temporales es que el orden de las observaciones si tiene importancia. Las series temporales son representadas en un gráfico que muestra su evolución en el tiempo, de la que se pueden extraer varias características: *tendencia*, *variabilidad* y *periodicidad*.

Una serie es *estacionaria* si satisface los siguientes criterios: es homocedástica, no periódica, la estructura de dependencia permanece constante y la influencia de las observaciones en las siguientes disminuye con el tiempo.

La señal temporal bajo estudio es considerada estacionaria por cumplir las propiedades arriba descritas. Existen varios modelos de procesamiento de series temporales, y de entre ellos se han estudiado tres escogiendose el más apropiado de ellos, el modelo autorregresivo.

Los *modelos autorregresivos* forman una familia de procesos tales que una observación depende de las observaciones pasadas. Dichos modelos se caracterizan por su orden, así, un proceso autorregresivo de cualquier orden $AR(p)$, sigue la siguiente ecuación:

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + \epsilon_t$$

Esto significa que la observación z_t esta influida directamente por las p observaciones previas z_{t-i} a través de sus coeficientes ϕ_i . Por otro lado, ϵ_t representa ruido blanco. El camino matemático para calcular los coeficientes es el sistema matricial de ecuaciones de *Yule-Walker*.

Se escogió el modelo autorregresivo para caracterizar la señal en lugar de un *modelo de media móvil* o de la *transformada rápida de Fourier* por la no-periodicidad de la señal, por los buenos resultados obtenidos y sobre todo porque los coeficientes ϕ_i definen claramente el comportamiento de las vibraciones para trabajar posteriormente en Python. La señal procesada en el laboratorio tiene un orden de 50 (50 coeficientes).

2.3 Máquinas de Soporte Vectorial

Una *máquina de soporte vectorial* es un sistema capaz de aprender la decisión de separar dos o más clases distintas de un conjunto de puntos de entrada, conocido como *conjunto de entrenamiento*. Puede formar una frontera de decisión alrededor de un dominio de puntos con poco o ningún conocimiento de los puntos que quedan fuera de la frontera, de

esta manera, etiqueta las clases y entrena a la SVM para que prediga la clase de una nueva muestra.

En otras palabras, una SVM construye un hiperplano en un espacio de dimensionalidad muy alta (o incluso infinita) que puede ser utilizado en problemas de clasificación o regresión. Una buena separación entre las clases permitirá una clasificación correcta. Los datos de entrada (los puntos) se tratan como un vector n -dimensional (para n puntos), así, al vector formado por los puntos más cercanos al hiperplano se le llama *vector de soporte*.

La teoría de SVM se basa en el *aprendizaje estadístico*, es decir, en un proceso donde una máquina de aprendizaje adquiere una función a través de la información extraída de un ambiente determinado mediante entrenamiento. En el entrenamiento, la máquina de aprendizaje busca en el espacio todas las posibles soluciones y elige una solución óptima en relación con ciertos criterios computacionales.

En la teoría de SVM se tienen los vectores de entrada, y las clases (la salida) son conocidas de antemano. Así, el objetivo es descubrir la relación entre estos dos vectores y valorar el porcentaje de acierto. Este tipo de enfoque matemático se denomina *aprendizaje supervisado*.

La teoría de SVM se basa en la idea de *minimización de riesgo estructural*, esto es, tratará de separar las clases por un margen lo más amplio posible. El hiperplano que lo hace, se llama *clasificador de margen máximo*. Maximizar el margen constituye un problema de programación n -dimensional que puede ser resuelto mediante multiplicadores de Lagrange.

2.3.1 Caso separable linealmente

Dado un conjunto de puntos de entrada, dos clases son linealmente separables si existe un hiperplano lineal tal que puede separar espacialmente y clasificar el conjunto de puntos en las dos clases existentes.

2.3.2 Caso separable no linealmente: El truco del Kernel

Si existen más de dos clases o hay dos pero no son linealmente separables se utiliza el truco del Kernel para obtener el hiperplano clasificador de margen máximo. Un hiperplano Kernel lleva los puntos a una dimensión espacial superior, llamado *espacio característico*, en la que la máquina de soporte vectorial busca la máxima separación posible entre clases de manera lineal. De esta manera, cuando el hiperplano Kernel es trazado de vuelta en el espacio dimensional original, puede separar todos los puntos en clases. Cada clase representa un grupo separado.

3 Procedimiento: Secuencia de tareas

A continuación se adjunta una lista de tareas de cada una de las tres partes en las que se dividía el proyecto. Las dos primeras partes son llevadas a cabo en el laboratorio y la última fue realizada por ordenador.

1. Puesta a punto del laboratorio y del banco de pruebas. Las siguientes tareas se efectuaban para poner en funcionamiento las dependencias eléctricas del laboratorio y para establecer el bucle hidráulico del banco de trabajo. Se realizaban al comienzo al día, y en el sentido contrario al final del día cuando había que abandonar el laboratorio.

N	Tarea	Descripción
1	Ajustar la red eléctrica	Encender el convertidor de frecuencia y seleccionar las opciones del motor:380kV, 13.8A y 75kW de potencia.
2	Abrir el circuito hidráulico	Aflojar la válvula sobre la bomba para permitir el paso de agua sólo en la bomba testada.
3	Abrir el depósito de aire comprimido	Abrir la válvula localizada al final del circuito de retorno.
4	Encender el amplificador	El acelerómetro requiere un amplificador de señal que ha de ser encendido.

2. Grabación de las vibraciones de la bomba en diferentes puntos de funcionamiento usando LabView.

N	Tarea	Descripción
1	Programa de grabación	Mediante el ordenador, abrir LabView para controlar el banco de trabajo.
2	Elegir las opciones de grabación	Nombrar los archivos, ajustar el tiempo del bucle y el paso para el caudal entre otros.
3	Grabar y comprobar	Grabar el bucle de 100 segundos y comprobar si el archivo obtenido es correcto.

3. Clasificación de las propiedades de los puntos de operación utilizando el algoritmo en Python.

N	Tarea	Descripción
1	Agrupar los archivos	Usando un segundo programa en LabView, los archivos se ordenan en carpetas siguiendo un criterio específico de clases.
2	Elegir el modo	Ya en Python, especificar las carpetas a clasificar y elegir el modo de trabajo.
3	Ejecutar	Correr el programa para obtener los resultados en la ventana de salida.
4	Presentar los resultados	Hacer tablas intuitivas en Excel usando la salida de Python.

4 Resultados

Se han llevado a cabo 14 clasificaciones atendiendo a distintos criterios. En la primera columna se especifica la magnitud a clasificar y en la segunda los datos que se han introducido para que sean clasificados. Por ejemplo, en la primera clasificación, se ha tratado de predecir el caudal volumétrico de todas las medidas que se hubiesen tomado cuando el motor giraba a 2900 rpm.

-	Datos	Clases	Prec.	Kernel	C	γ	d	Tol.
Q	2900 rpm	25	0.87	RBF	1000	1	3	0.001
	2500 rpm	20	0.9	RBF	1000	1	3	0.001
	2000 rpm	16	0.95	RBF	100	1	3	0.001
	Todos	25	0.89	RBF	10000	1	3	0.001
n	Todos	3	1	RBF	10	1	3	0.001
SP	2000 rpm	2	1	RBF	10	1	3	0.001
	2500 rpm	2	1	RBF	10	1	3	0.001
	2000 rpm	3	1	RBF	10	1	3	0.001
	Todos	3	1	RBF	10	1	3	0.001
Fecha	Todos	11	0.99	RBF	10000	1	3	0.001
Q	SP1	25	0.9	RBF	10000	1	3	0.001
	SP2	24	0.86	RBF	100	1	3	0.001
	SP3	24	0.91	RBF	1000	1	3	0.001
Q, n	Todos	60	0.9	RBF	1000	1	3	0.001

La primera observación a tratar es la disposición de las *matrices de confusión*. En todas las clasificaciones existe una tendencia que muestra que el método SVM es aplicable. Los fallos de clasificación se concentran en las magnitudes intermedias de la matriz, dejando una

clasificación con más exactitud en los valores más altos. La posible causa de éste fenómeno es la variabilidad de las vibraciones en los distintos caudales, que parece tener un comportamiento más estable a altos valores del caudal volumétrico y es más fácil de clasificar para la máquina de aprendizaje.

Otro punto a analizar son las precisiones obtenidas. Se pueden diferenciar dos tipos de clasificaciones atendiendo a su precisión: aquellas que rondan el 90% de precisión y las que son perfectamente clasificadas. Las del primer tipo se observa que pertenecen a la clasificaciones de caudal volumétrico. Este tipo es más difícil de predecir debido a la gran cantidad de clases que se han incluido (hasta 25) y debido a la problemática de diferenciar caudales con un valor intermedio. Es lógico pensar que es más sencillo crear un hiperplano que separe 3 clases que uno que separe 25. El coeficiente C para estas clasificaciones es habitualmente grande, en ocasiones produce sobreajuste,

El otro tipo de clasificaciones (velocidad de giro, fecha y posición del sensor) tiene un 100% de precisión aparentemente debido a la cantidad de clases que se manejan; 3, 11 y 3, respectivamente. Para este tipo el factor C es menor, 10, quizás debido a que con solo 3 clases no se necesita ajustar demasiado el hiperplano.

De cualquier manera, el efecto de cambiar la velocidad de giro o la posición del sensor en la vibración parece más claro que efecto de variar el caudal, y por lo tanto, más fácil de clasificar.

La tercera observación trata sobre los hiperplanos clasificadores, los Kernels. En el primer grupo de resultados, los de precisión cercana al 90% el hiperplano Kernel obtenido es Gaussiano de base radial con $\gamma = 1$, $d = 3$ y $tol = 0.001$ para todos los casos. Esto se debe a que se clasifica una gran cantidad de clases para el caudal y no es posible hacerlo mediante un hiperplano lineal, lo que parece lógico. En el segundo grupo de resultados, la cantidad menor de clases que nos encontramos es 3, por lo tanto tampoco es posible separarlas mediante un hiperplano lineal.

La quinta observación, y quizás más importante esta relacionada con la posición del sensor de vibración. Se han testado 3 posiciones diferentes y los resultados son similares en todos los casos. Pueden tomarse un par de anotaciones al respecto:

- Las precisiones obtenidas para las tres posiciones son similares, aunque la segunda posición parece entregar una precisión ligeramente inferior.
- La segunda posición posee una cantidad considerablemente menor de medidas que las otras dos y quizás por ello la precisión es la menor de las tres.

5 Conclusiones

Primeramente, es importante remarcar que el método SVM para clasificar es aplicable en sistemas de bombeo, y que los resultados son satisfactorios con una precisión de aproximadamente el 90%. Clasificar los caudales volumétricos de fluido es el punto más complicado para la máquina de aprendizaje debido a la gran cantidad de clases que se han incluido y porque es posible que a ciertas frecuencias de vibración se produzca algún fenómeno de interferencia que haya complicado la predicción de los valores intermedios.

Es importante resaltar ciertas conclusiones sobre los Kernels clasificadores:

- Los Kernels que mejor separan las clases en todas las clasificaciones son del tipo RBF debido a que la cantidad de clases existente hace que el resto de tipos de Kernel no sean aplicables.
- El valor del parámetro γ es siempre el máximo, $\gamma = 1$, lo que no permite extraer conclusiones de ello.
- El factor C expresa dos comportamientos distintos. Por un lado, cuando es pequeño, representa una superficie de decisión grande y suavizada para el conjunto de puntos, lo que representa un fenómeno llamado subajuste. El subajuste ocurre en las clasificaciones con 100% de precisión y significa que el error se da en el entrenamiento del Kernel.
- Cuando el factor C es grande, como ocurre en las clasificaciones de caudal, se llama sobreajuste y significa que la superficie de decisión es muy ajustada y los errores se han cometido en la prueba del Kernel y no en el entrenamiento.

Otra de las conclusiones que querían ser extraídas era acerca del sensor de vibración y su posición. Se puede concluir que la posición no es relevante ni influye en el resultado. Solo la segunda posición presenta unos resultados ligeramente inferiores y es debido a que solo el 15% de las medidas fueron tomadas con el sensor en esta posición.

Para pruebas futuras se pueden tomar una serie de medidas aprendidas de este estudio y que garantizarán un mejor resultado y en resumen, que la aplicación real de este estudio sea cada vez más posible. Por ejemplo, se considera recomendable estudiar más valores de velocidad de giro del motor, es decir, más clases, para comprobar hasta que punto la máquina de aprendizaje puede clasificar correctamente este parámetro y por qué. Por otro lado, el sensor se colocaría siempre en la misma posición sobre la bomba para que la máquina de aprendizaje sea alimentada siempre con información procedente del mismo sitio. También,

sería interesante estudiar la misma bomba en un entorno para evaluar la influencia del laboratorio en las vibraciones registradas. Además, sería interesante incluir valores mayores de γ en el bucle de programación en Python y comprobar si pueden obtenerse mejores resultados con ello.

Por otro lado, es altamente recomendable colocar un *filtro* tras el amplificador de señal situado después del acelerómetro. De esta manera, un futuro proyecto que siga estas recomendaciones podrá obtener nueva información sobre el comportamiento de SVM en bombas hidráulicas y acercar un poco más el estudio a una aplicación comercial.

6 Información adicional

Este Proyecto Final de Carrera ha sido realizado por Eduardo Manzanares Segovia en el departamento de Mecánica de Fluidos y Turbomaquinaria de la Universidad Técnica de Kaiserslautern (Alemania) en la titulación de Ingeniería Mecánica y de Procesos bajo la supervisión del profesor Dipl.-Ing.Christian Licht. La tesis fué defendida frente a un tribunal el día 26/03/2.012 y el tribunal estaba compuesto por los profesores Dipl.-Ing.Christian Licht y Dr.-Ing.Harald Roclawski, y el profesor jefe de departamento Prof.Dr.-Ing.Martin Böhle con una calificación obtenida de 1.3 en el sistema alemán de calificaciones.

En la Universidad Carlos III de Madrid, la responsabilidad de coordinador académico y cotutor recae en Miguel Ángel Moscoso Castro, profesor del departamento de Matemáticas, como se indica en los correspondientes Anexo I y Anexo II.