



PROYECTO DE GRADO

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

CARACTERIZACIÓN DE PATRONES DE FLUJO MULTIFÁSICOS MEDIANTE MÁQUINAS DE VECTORES DE SOPORTE

Por

Br. Engemberth A. Brito T.

Tutor: Prof. Pablo Guillén.

Cotutor: Prof. Carlos Torres.

Noviembre de 2009.

©2009 Universidad de Los Andes Mérida, Venezuela

Capítulo 1

Introducción

En la industria para poder llevar a cabo los procesos de separación, transporte y medición de los diferentes compuestos, se debe conocer el patrón de flujo que circula por una tubería, los cuales básicamente se forman dependiendo de la cantidad de líquido y gas que contenga el fluido.

El enfoque usual consiste en coleccionar datos de flujo (densidad del gas, densidad del líquido, viscosidad del gas, viscosidad del líquido, velocidad superficial del gas, velocidad superficial del líquido, diámetro y ángulo de la tubería) para luego visualmente determinar los patrones de flujo a través de una sección transparente de tubería. Seguidamente los datos son representados en un diagrama 2D (velocidad superficial del gas V_g vs. velocidad superficial del líquido) lo que permite localizar fronteras de transición entre los patrones.

Por lo dicho anteriormente, el objetivo fundamental de este proyecto de grado consiste en identificar cada uno de los patrones de flujo que pueden circular por una tubería, haciendo uso de una máquina de aprendizaje supervisado basado en Máquinas de Vectores de Soporte (SVM), como una herramienta de diagnóstico automatizado para una mejor toma de decisión en el proceso de separación.

Para un mejor entendimiento de la problemática existente, se definirán en este capítulo los antecedentes en el área, así como también, el planteamiento del problema, la justificación, el objetivo general, los objetivos específicos y la metodología que encaminan el desarrollo de este proyecto, finalmente se dará una descripción de la estructura del documento.

1.1 Antecedentes

El estudio del flujo simultáneo de gas y de líquido a través de una tubería o conducto es una de las combinaciones de flujo más complejas que existen, debido a la gran variedad de configuraciones relacionadas con la distribución espacial y geométrica de las partículas de cada fase existente dentro de la tubería, estas configuraciones se conocen como patrones de flujo.

Según Shohan (2006) desde 1950 muchos han sido los esfuerzos dirigidos al desarrollo de modelos físicos que permiten la predicción y caracterización analítica de los patrones de flujo que se encuentran presentes en las mezclas multifásicas líquido – gas. La mayor parte del trabajo inicial se enfocó en el flujo horizontal o vertical. Estudios en flujo inclinado se iniciaron en 1970, llevando a un entendimiento completo de las transiciones de los patrones de flujo para todos los ángulos desde -90° a 90° .

El método comúnmente utilizado para determinar el patrón de flujo de dos fases es la inspección visual a través de tuberías transparentes. Usualmente los datos recolectados son registrados en un gráfico bidimensional para así determinar los límites entre los diferentes patrones de flujo, en estudios iniciales correlaciones empíricas han sido desarrolladas, sin embargo, ninguna base física ha sido sugerida para la selección de las coordenadas de dicho gráfico (Shohan O., 2006).

Por lo tanto, estos gráficos empíricos son confiables sólo para un pequeño rango de condiciones bajo las cuales los datos fueron adquiridos, y extenderlo a otras condiciones de flujo es incierto. También, diferentes clasificaciones y definiciones de patrones de flujo han sido sugeridas por varios investigadores, resultando en muchas contradicciones entre los mapas que fueron propuestos (Shohan O., 2006).

Debido a que las observaciones visuales son frecuentemente subjetivas y difíciles, especialmente a elevadas tasas de flujo, se han hecho esfuerzos dedicados al desarrollo de técnicas para la detección de los patrones de flujo que son objetivas y que también pueden ser utilizadas en tuberías opacas (Shohan O., 2006).

Muchos dispositivos han sido sugeridos, incluyendo el anemómetro de alambre caliente, rayos X, transductores de presión y capsulas de conducción (Shohan, O. 2006). Todos los esfuerzos hechos en estas aproximaciones han resultado solo con un éxito parcial ya que ninguna técnica por si sola puede distinguir confiablemente entre los distintos patrones de flujo bajo diversas condiciones.

Uno de los modelos analíticos establecido es el de Taitel y Dukler (1976) el cual es aplicable para flujo Newtoniano en estado estable y completamente desarrollado en tuberías ligeramente inclinadas ($\pm 10^\circ$). Este modelo fue puesto a prueba exitosamente contra los datos recolectados en tuberías de diámetros pequeños bajo condiciones de poca presión.

El punto de inicio del modelo es el equilibrio del flujo estratificado. Asumiendo que ocurra el flujo estratificado, las variables de flujo, incluyendo el nivel del líquido en la tubería son determinados. Un análisis de estabilidad se realiza para determinar si la configuración del flujo es estable o no. Si el flujo es estable, ocurre el flujo estratificado. Si el flujo no es estable, un cambio a flujo no estratificado ocurre, y el patrón de flujo resultante es determinado.

Luego que el modelo de Taitel y Dukler (1976) fue publicado, los datos experimentales estaban disponibles sólo para condiciones de flujo horizontal. Una comparación entre la

predicción del modelo y los datos experimentales para el flujo gas - líquido en condiciones estándar en tuberías horizontales y ligeramente inclinadas fue presentado inicialmente por Barnea et al. (1980) y luego por Shoham (1982).

También se han desarrollado metodologías para identificar patrones de flujo tanto de dos fases como multifásicos, utilizando redes neuronales con el algoritmo de backpropagation (El-Sayed 2004). Estos entrenamientos han arrojado excelentes resultados sobre todo cuando se trata del patrón de flujo anular, clasificando correctamente el 100% de los datos, mientras que en el caso del flujo estratificado se observó una clasificación del 98.6% en el estratificado liso y 94.7% en el estratificado ondulado, para realizar este proceso de clasificación se tomó en cuenta 199 datos experimentales sólo para tuberías horizontales (El-Sayed 2004).

Con la aplicación del modelo de máquina de aprendizaje supervisado como herramienta de diagnóstico automatizado, se busca tener una mejor toma de decisión en el proceso de separación y producción gas – líquido, el cual es de gran importancia en la producción de petróleo.

1.2 Justificación

Conocer el tipo de patrón de flujo que presenta un sistema de tuberías es de gran importancia en la industria, debido a que es un factor clave en el proceso de producción de petróleo, la metodología empleada actualmente para la identificación de patrones de flujo es muy subjetiva debido a que se realiza por medio de supervisión visual a través de una sección transparente de la tubería, es por ello que se desea desarrollar un modelo matemático que permita identificar y clasificar las diferentes configuraciones que se pueden presentar de manera rápida y precisa, con la finalidad de obtener una

herramienta de diagnóstico automatizado para una mejor toma de decisión en el proceso de separación, medición y transporte de fases, ya que éste es fundamental para la producción en la industria petrolera.

1.3 Planteamiento del problema

Debido a que la identificación de patrones de flujo se realiza de forma visual, ésta genera gran incertidumbre, lo que puede ocasionar un retraso en el proceso de producción, ya que si no se conocen con exactitud los patrones del flujo que circula por una tubería ó conducto, no se pueden llevar a cabo los procesos de separación, medición y transporte.

Por lo dicho anteriormente, se plantea desarrollar un modelo matemático que permita identificar y clasificar las configuraciones de los patrones de flujo existentes en tuberías horizontales, verticales e inclinadas. Este modelo está basado en una máquina de aprendizaje supervisado, empleando Máquinas de Vectores de Soporte (SVM) como técnica de clasificación, con la finalidad de obtener una herramienta de diagnóstico automatizado para una mejor toma de decisión en el proceso de separación, medición y transporte de fases.

1.4 Objetivos

1.4.1 Objetivo General

Clasificar patrones de flujo multifásicos en tuberías horizontales, verticales e inclinadas utilizando Máquinas de Vectores de Soporte.

1.4.2 Objetivos Específicos

- Analizar el procedimiento actualmente utilizado para identificar los patrones de flujo multifásicos.
- Realizar una revisión bibliográfica sobre el uso de las SVM en aplicaciones de predicción y clasificación.
- Seleccionar las variables físicas que caracterizan el comportamiento de los patrones de flujo multifásicos que se van a utilizar para entrenar y validar las SVM.
- Utilizar la metodología de las SVM para realizar la clasificación de los patrones de flujo multifásicos.
- Desarrollar e implementar una interface gráfica de visualización en QT4.

1.5 Metodología

- Revisión detallada de las bases teóricas y conceptos del tema a tratar, así como de las técnicas y procedimientos a utilizar para la construcción del modelo.
- Obtención de los datos pertenecientes a los patrones de flujo multifásicos que permitirán aplicar la técnica de análisis seleccionada.
- Análisis y evaluación de las SVM para los problemas de clasificación.
- Análisis de los parámetros involucrados en las SVM
- Análisis y evaluación de los resultados obtenidos al aplicar SVM para la clasificación de patrones de flujo multifásicos.

1.6 Estructura del documento

El presente documento está conformado por 5 capítulos que se encuentran divididos de la siguiente manera:

- En el Capítulo 1, Se define los antecedentes que son la base para la realización de esta tesis, así como también, el planteamiento del problema, la justificación, los objetivos y la metodología para su desarrollo.
- En el Capítulo 2, se describen los fundamentos teóricos básicos necesarios para el entendimiento y comprensión del proyecto.
- En el Capítulo 3, se exponen tanto los fundamentos teóricos, como los matemáticos, de las Máquinas de Vectores de Soporte.
- En el Capítulo 4, se presentan los resultados obtenidos por los modelos implantados de SVM.
- En el Capítulo 5, se describe las conclusiones generales del trabajo realizado.

Capítulo 2

Marco teórico

En este capítulo se describen los fundamentos teóricos necesarios para ayudar a la comprensión del problema que se desea resolver y que sirven de base para la realización de este proyecto. Se exponen conceptos de propiedades de los fluidos, flujos multifásicos, variables en flujos multifásicos, fenómenos fundamentales en flujos multifásicos, tipos de patrones de flujo, entre otros.

2.1 Definición de fluido

Un fluido es una sustancia que se deforma continuamente bajo la aplicación de un esfuerzo de corte, sin importar que tan pequeño pueda ser ese esfuerzo.

2.2 Propiedades de los fluidos

Dentro de las propiedades de los fluidos utilizadas en este trabajo se pueden mencionar las siguientes.

2.2.1 Densidad

La densidad de un fluido es su masa por unidad de volumen, cuando aumenta la temperatura se produce una ligera disminución de la densidad.

2.2.2 Viscosidad

La viscosidad de un fluido es la medida de su resistencia a los esfuerzos tangenciales o cortantes, dicha resistencia nace de la cohesión de las moléculas del fluido. Todos los fluidos reales tienen viscosidad aunque en distinto grado. La velocidad de deformación es proporcional a la variación de este esfuerzo.

2.2.3 Tensión superficial

La tensión superficial es la propiedad física que permite que una gota se sostenga colgando del grifo, tal fenómeno se debe a la cohesión molecular en la superficie de separación del líquido con otro líquido o gas inmiscible. Al igual que la densidad, la tensión superficial disminuye ligeramente con el aumento de la temperatura.

2.3 Flujo multifásico

El flujo multifásico consiste esencialmente en el flujo simultáneo de dos o más fases a través de una tubería. Básicamente, algunas de las diferencias principales entre el flujo monofásico y multifásico es que es producto de fenómenos tales como: el retraso del líquido, la fracción del vacío, la velocidad de deslizamiento entre las fases, entre otros.

2.4 Variables en flujo multifásico

2.4.1 Caudal másico

Se refiere a la cantidad de masa que atraviesa una superficie normal por unidad de tiempo, por lo que se tiene caudal másico del líquido, caudal de flujo másico de gas y caudal de flujo másico total:

$$\dot{m} = \int_A \rho \vec{V} \cdot \vec{dA} \quad (2.1)$$

2.4.2 Caudal volumétrico

Se refiere al volumen por unidad de tiempo que atraviesa una superficie normal, por lo que se tiene caudal volumétrico del líquido, caudal volumétrico del gas y caudal volumétrico total:

$$Q = \int_A \vec{V} \cdot \vec{dA} \quad (2.2)$$

2.4.3 Velocidad en sitio de las fases

Se refiere a la velocidad de cada fase tomando en cuenta el área de sección transversal que la misma ocupa: (*l*: líquido; *g*:gas; *sl*: superficial del líquido; *sg*: superficial del gas)

$$V_l = (V_{sl} \cdot A)/A_l \quad (2.3)$$

$$V_g = (V_{sg} \cdot A)/A_g \quad (2.4)$$

2.4.4 Velocidad de deslizamiento

Se refiere a la velocidad relativa de las fases en función de las velocidades reales de las mismas:

$$\vec{V} = \vec{V}_g - \vec{V}_l \quad (2.5)$$

2.4.5 Retraso de líquido con deslizamiento

Se define como la fracción de un elemento de volumen ocupado por la fase líquida cuando existen deslizamientos entre las fases. La determinación del retraso del fluido es una de las complicaciones del flujo multifásico, ya que es extremadamente difícil de medir y calcular:

$$H_l = \frac{A_l}{A} \quad (2.6)$$

2.4.6 Retraso de líquido sin deslizamiento

Se define como la fracción de un elemento de volumen de líquido cuando existe deslizamiento:

$$\lambda = \frac{V_{sl}}{V_{sl} + V_{sg}} \quad (2.7)$$

2.5 Patrones de flujo

El término patrones de flujo se refiere a la configuración geométrica de las fases de gas y líquido en la tubería. Cuando el gas y el líquido fluyen simultáneamente en una tubería, las dos fases se pueden distribuir en una variedad de configuraciones de flujo. Las configuraciones de flujo difieren una de la otra en la distribución espacial de la interface,

resultando en diferentes características de flujo, tales como, la velocidad y distribuciones de estabilidad.

Los patrones de flujo existentes en un sistema de flujo de dos fases depende de los parámetros operacionales, tasas de flujo del gas y líquido, variables geométricas, incluyendo diámetro y ángulo de inclinación de la tubería, y las propiedades físicas de las dos fases (densidades, viscosidades y tensión superficial)

2.6 Clasificación de patrones de flujo

Debido a que existe una gran variedad de configuraciones y analizar cada una de ellas es extremadamente difícil, existe un agrupamiento de patrones dependiendo de la inclinación de la tubería que simplifica el estudio y análisis de los mismos, a continuación se muestra el agrupamiento de estos patrones de flujo.

2.6.1 Flujo Horizontal

Los patrones de flujo existentes en flujo horizontal se pueden clasificar como flujo estratificado, intermitente, anular y de burbujas dispersas. En la figura 2.1 se pueden observar estos patrones.

2.6.1.1 Flujo estratificado

Este patrón de flujo ocurre a tasas de flujo de gas y líquido bajas. Las dos fases son separadas por la gravedad, donde la fase líquida fluye en el fondo de la tubería y la fase de gas por encima.

Este tipo de patrón se subdivide en estratificado suave, donde la interfaz gas-líquido es suave, y estratificado ondulado, que ocurre a mayores tasas de gas, donde pequeñas olas estables se forman en la interfaz.

2.6.1.2 Flujo intermitente

Este tipo de patrón se da cuando ocurre un incremento en el caudal de gas haciendo que las burbujas crezcan y se unan formando así una sola burbuja, denominada burbuja de Taylor, que progresivamente aumenta el diámetro hasta alcanzar el diámetro de la tubería.

Estas burbujas están separadas de la pared del tubo por una película de líquido, la cuál puede ser ascendente o descendente dependiendo ésto de la orientación de la tubería y la dirección del flujo. Las burbujas están separadas por paquetes de líquido que en general llevan la misma dirección de las burbujas.

El patrón de flujo intermitente es usualmente subdividido en flujos de burbujas largas y flujo intermitente, básicamente estos patrones de flujo tienen la misma configuración con respecto a la distribución del gas y las interfaces del líquido.

En estos patrones de flujo, líneas de líquido son separadas por largas burbujas en forma de bala. En el flujo intermitente, puentes de líquido son aireados por pequeñas burbujas de gas, mientras que el patrón de burbujas largas es considerado el caso limitante del flujo slug cuando las tiras de líquido son liberadas de las burbujas entrelazadas.

2.6.1.3 Flujo anular

Este patrón es característico para velocidades de gas relativamente elevadas, las fases viajan separadas, el líquido se adhiere a las paredes de la tubería formando un anillo, con el gas viajando por el interior del mismo.

En la interfaz se forman constantemente olas de líquido las cuales se rompen y se fragmentan en pequeñas gotas que viajan suspendidas por el núcleo central de gas, las gotas fluyen separadamente y no se conglomeran, al igual que en el patrón de flujo

estratificado si ocurre un leve aumento de la velocidad del gas se puede observar un comportamiento tipo ola.

2.6.1.4 Flujo de burbujas dispersas

Al igual que el patrón de burbujas la fase gaseosa se encuentra inmersa en la fase líquida, pero en este caso, las fuerzas de dispersión turbulentas son dominantes ocasionando el rompimiento de las burbujas en burbujas más pequeñas y distribuyéndolas de manera más uniforme a lo largo de la fase líquida, este tipo de patrón usualmente aparece a altos caudales de líquido, sin importar el rango de inclinación de las tuberías.




Figura 2.1 Patrones de flujo en tuberías horizontales (Tomado de Shohan (2006)).

2.6.2 Flujo Vertical

En el flujo vertical, el régimen estratificado desaparece y se observa un nuevo patrón de flujo denominado flujo agitado. Usualmente, los patrones de flujo son más simétricos alrededor del eje de la tubería y menos dominados por la gravedad. Los patrones de flujo que se pueden encontrar en las tuberías verticales son el flujo de burbuja, flujo intermitente, flujo agitado, flujo anular y flujo de burbujas dispersas. En la figura 2.2 se pueden observar estos patrones de flujo.

2.6.2.1 Flujo de burbujas

En este tipo de flujo la fase de gas se ve dispersa en pequeñas burbujas que se mueven hacia arriba en un movimiento de zig - zag, dentro de una fase líquida continua. Para el flujo vertical, la distribución de las burbujas es aproximadamente homogénea a través de la sección transversal de la tubería. Este tipo de patrón ocurre a tasas de líquido relativamente bajas con poca turbulencia.

2.6.2.2 Flujo agitado

Este patrón de flujo se caracteriza por un movimiento oscilatorio en la fase líquida. El flujo agitado es similar al flujo intermitente pero se ve más desordenado, sin límites claros entre las dos fases.




Figura 2.2 Patrones de flujo en tuberías verticales (Tomado de Shohan (2006))

2.6.3 Flujo Inclinado

La figura 2.3 presenta los patrones de flujo para todos los ángulos de inclinación de manera unificada. Para el flujo inclinado hacia abajo, el patrón de flujo dominante es estratificado ondulado, ocurriendo en un amplio rango de ángulos desde 0° hasta -80° , y cubriendo un rango aun mayor de tasas de flujo de gas y líquido. Como se observa en flujo inclinado hacia arriba, el flujo de burbujas dispersas y anular ocurren a altas tasas de flujo de líquido y gas. Para el flujo vertical hacia abajo, el patrón de flujo estratificado desaparece y el régimen anular existe, también a bajas tasas de flujo de gas en la forma de una película que cae.




Figura 2.3 Patrones de flujo en tuberías inclinadas. (Tomado de Shohan (2006))

El patrón de flujo intermitente en flujo vertical hacia abajo es similar al que ocurre con el flujo hacia arriba, con la excepción que usualmente la burbuja de Taylor es inestable y se ubica excéntricamente fuera del eje de la tubería. La burbuja de Taylor puede elevarse o descender, dependiendo de las tasas de flujo en las fases de gas y líquido. Es por esto que cualquier intento de tener una solución general y única para los problemas de dos fases incluyendo todos los patrones de flujo es muy retadora. Sin embargo, para cada patrón de flujo existente, el comportamiento del flujo es muy similar, el flujo de dos fases se hace un poco más sencillo, ya que es posible analizar cada patrón de flujo por separado, así, el acercamiento general es primero predecir el patrón de flujo existente en la tubería.

2.7 Mecanismo de transición en patrones de flujo

Los patrones de flujo son configuraciones que pueden considerarse estables para cierto grupo de propiedades, pero al variar las mismas, se pierde la estabilidad traduciéndose ésto en un cambio de un patrón a otro, a continuación se mencionan las diferentes transiciones que pueden ocurrir en un patrón de flujo.

2.7.1 Transición de estratificado a no estratificado

Para tuberías horizontales y levemente inclinadas Taitel & Dukler (1976) sugirieron que la transición de equilibrio desde el flujo estratificado es debido a la inestabilidad de Kelvin – Helmholtz. Ellos consideraban que una onda sobre el flujo estratificado tiende a crecer debido a la caída de presión en la fase gaseosa debido al efecto Bernoulli. Por otra parte, la fuerza de la gravedad que actúa sobre la onda tiende a causar decaída.

2.7.2 Transición de burbujas dispersas a anular

El criterio para esta transición es descrito cuando las tasas de flujo del gas y el líquido son elevadas, la estructura se vuelve inestable, y la transición de flujo estratificado a no estratificado ocurre. Bajo condiciones de flujo inestables, a bajas tasas de flujo de gas y altas de líquido, el nivel del líquido en la tubería es alto y las olas crecientes tienen suficiente suministro de líquido, eventualmente bloqueando el área de la sección transversal de la tubería. Sin embargo a bajas tasas de flujo de líquido y altas de gas, el nivel del líquido en la tubería es bajo. Para este caso la ola en la interfaz es llevada alrededor del tubo por la alta velocidad del gas resultando así una transición a flujo anular.

2.7.3 Transición de estratificado liso a estratificado ondulado

Esta transición ocurre cuando la velocidad de la fase de gas es, por un lado, lo suficientemente alta como para causar la formación de olas en la interfaz, pero por el otro, es menor a la velocidad necesaria para causar la inestabilidad y la transición a flujo no estratificado. En general, las olas se desarrollan en la interfaz de una configuración de flujo estratificado cuando la presión y las fuerzas ejercidas por la fase de gas superan las fuerzas de disipación viscosa en la fase del líquido.

2.7.4 Transición de intermitente a burbujas dispersas

Esta transición ocurre a altas tasas de flujo de líquido. Para estas condiciones, el nivel de equilibrio en la tubería es alto y se aproxima a la pared superior del tubo.

La fase de gas ocurre en la forma de una pequeña bolsa de gas en la parte superior de la tubería, cuando hay suficiente velocidad en el líquido, la bolsa de gas se rompe en pequeñas burbujas que se mezclan con la fase líquida. Por lo tanto, ocurre la transición a flujo de burbuja dispersa cuando las fluctuaciones turbulentas en la fase líquida son lo

suficientemente fuertes que tienden a retener el gas como una bolsa en la parte superior de la tubería.

2.8 Mapas de patrón de flujo

El primer acercamiento para predecir patrones de flujo ha sido el acercamiento empírico, la determinación de los patrones de flujo se realiza principalmente por observaciones visuales, usualmente los datos de patrones de flujo se representan en un gráfico de dos dimensiones, y los límites de transición entre los diferentes patrones son determinados. Tal mapa es llamado Mapa de Patrón de Flujo.

Los mapas de patrones de flujo son la representación gráfica de la topología, propiedades y mezclas de las diferentes configuraciones en función de las velocidades superficiales de las fases (V_{sl} vs V_{sg}) manteniendo constantes las demás propiedades, estos mapas representan los patrones como áreas, y sus coordenadas pueden ser generalizadas para un cierto grupo de propiedades previamente identificadas.

La tendencia actual es hacia el uso de los modelos mecánicos, modelando así los fenómenos físicos involucrados, los mapas así obtenidos son más exactos y aplicables en un mayor rango de operaciones.

Es importante destacar que la representación de cada una de las configuraciones en mapas de patrones de flujo depende del ángulo de inclinación de la tubería. A continuación en las figuras 2.4, 2.5, 2.6 y 2.7, se observan los mapas para diferentes ángulos de inclinación, tanto para flujo ascendente como para flujo descendente.




Figura 2.4 Mapa de patrones para ángulos de inclinación $\beta = 0^\circ$ y $\beta = 1^\circ$ Tomado de Barnea (1986)




Figura 2.5 Mapa de patrones para ángulos de inclinación $\beta = 30^\circ$ y $\beta = 90^\circ$ Tomado de Barnea (1986)




Figura 2.6 Mapa de patrones para ángulos de inclinación $\beta = -1^\circ$ y $\beta = -30^\circ$ Tomado de Barnea (1986)




Figura 2.7 Mapa de patrones para ángulos de inclinación $\beta = -90^\circ$ Tomado de Barnea (1986)

2.9 Teorema de Vaschy-Buckingham

Este teorema mejor conocido como “*Teorema Pi* (π)” permite cambiar el conjunto original de los parámetros de entrada dimensionales de un problema físico por otro conjunto de parámetros de entrada adimensionales más reducido, con la finalidad de simplificar el estudio de cualquier fenómeno físico, disminuyendo el número de variables independientes para así obtener resultados compactos que pueden ser aplicados a otras situaciones similares. Los parámetros adimensionales se obtienen mediante combinaciones adecuadas de los parámetros dimensionales y debe existir un número mínimo necesario para estudiar cada sistema. De este modo, al obtener uno de estos conjuntos de tamaño mínimo se consigue analizar con mayor facilidad el sistema objeto de estudio y reducir drásticamente el número de ensayos que debe realizarse para averiguar el comportamiento o respuesta del sistema.

Para llevar a cabo la reducción de las variables dimensionales a variables adimensionales se debe realizar lo siguiente:

- Contar el número de variables dimensionales (n) y el número de unidades básicas como longitud, tiempo, masa, temperatura (m).
- Determinar el número de grupos adimensionales. ($n - m$).
- Hacer que cada grupo adimensional dependa de ($n - m$) variables fijas.
- Cada grupo se pone como un producto de las variables que lo determinan elevadas a una potencia desconocida.
- Se debe garantizar la adimensionalidad hallando todos los valores de los exponentes para que se cancelen todas las dimensiones implicadas.

Los parámetros adimensionales que más se utilizan para el estudio de los fluidos son los siguientes:

1. Número de Reynolds: es uno de los números adimensionales más utilizados.

La importancia radica en que nos habla del régimen con que fluye un fluido, lo que es fundamental para el estudio del mismo, relaciona las propiedades físicas del fluido, su velocidad y la geometría del ducto por el que fluye y está dado por:

$$Re = \frac{D \cdot v \cdot \rho}{\mu} \quad (2.8)$$

Donde:

Re = Número de Reynolds

D = Diámetro del ducto

v = Velocidad promedio del líquido

ρ = Densidad del líquido

μ = Viscosidad del líquido

2. Número de Froude: es un número adimensional que relaciona el efecto de la fuerza de inercia y la fuerza de gravedad que actúan sobre un fluido. La fuerza de inercia, en base al segundo principio de la dinámica, se define como el producto entre la masa y la aceleración, pero en el caso de un fluido se tiene la masa como densidad por volumen. El número de Froude está dado por:

$$Fr = \frac{v^2}{\sqrt{g \cdot l}} \quad (2.9)$$

Donde:

Fr = Número de Froude

v = Parámetro de velocidad

g = Fuerza de gravedad

l = Parámetro de longitud

3. Número de Weber: es un número adimensional utilizado en mecánica de fluidos ya que es útil para analizar flujos en donde existe una superficie entre dos fluidos diferentes. Es una medida de la importancia relativa de la inercia del fluido comparada con su tensión superficial. Este número está dado por:

$$We = \frac{\rho \cdot v^2 \cdot l}{\sigma} \quad (2.10)$$

Donde:

We = Número de Weber

l = longitud característica

v = Velocidad del fluido

ρ = Densidad del fluido

σ = Tensión superficial

Capítulo 3

Máquinas de Vectores de Soporte, SVM

Este capítulo pretende destacar algunas de las características más importantes de las Máquinas de Vectores de Soporte, explicando tanto fundamentos teóricos como matemáticos esenciales para el entendimiento de dicha técnica.

3.1 Introducción a las SVM

Las Máquinas de Vectores de Soporte (SVM), 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 SVM 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 SVM 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 como rostros y categorización de textos, mientras que las aplicaciones de regresión incluyen predicción de series de tiempo y problemas de inversión en general.

Las SVM 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 SVM 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.

Las SVM “pertenecen a la familia de clasificadores lineales puesto que inducen separadores lineales o hiperplanos en espacios de características de muy alta dimensionalidad (introducidas por funciones núcleo o kernel) con un sesgo inductivo muy particular (maximización del margen)”, (Carreras, Márquez y Romero, 2004).

Sin embargo, 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.

Principalmente las SVM se utilizan como clasificador binario, pero también se pueden utilizar como clasificador multiclase, utilizando los métodos “uno contra todos” ó “uno

contra uno”, donde el primero consiste en comparar cada clase con todas las demás, mientras que en el segundo cada clase se compara con las restantes individualmente.

Es importante destacar que el objetivo fundamental de las SVM para clasificación es encontrar un hiperplano óptimo que separe las clases.

3.2 Ventajas de las SVM

Las SVM 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 SVM 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 SVM 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 SVM 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 SVM con una mayor habilidad para generalizar, es decir, tener una alta capacidad de pronóstico para nuevas observaciones.

Otras de las características de las SVM 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 SVM 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 SVM

Para poder comprender a cabalidad el funcionamiento teórico y matemático de las SVM 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 SVM, 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 SVM más complejas.

En la figura 3.1 se muestra geométricamente 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 SVM para el caso lineal

Las SVM 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 b 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:

$$\text{Maximizar } \frac{1}{\|\omega\|} \quad (3.1)$$

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

$$1 \leq i \leq N$$

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

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

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

3.5 SVM 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 SVM 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 SVM 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 SVM 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 SVM 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 SVM 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 sigmoidal, 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 SVM 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 $\mathfrak{H}$.

Núcleo o Kernel	Función	Parámetros a ajustar
Lineal	$k(x, y) = y$	Ninguno
RBF	$k(x, y) = e^{-\gamma \ x-y\ ^2}$	γ : Gamma
Sigmoidal	$k(x, y) = \tanh(s \langle x, y \rangle + r)$	$s, r \in \Re$
Polinomial	$k(x, y) = (y + 1)^d$	d: grado del polinomio

Tabla 3.1. Funciones kernel.

Una vez definida la función núcleo y de conocer cual es su objetivo se procede a especificar el problema de optimización a resolver para las SVM 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 SVM con margen blando

Las SVM 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 SVM 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 SVM con margen máximo.

Las SVM con margen blando introducen variables de holgura al modelo, permitiendo que ciertos datos violen con cierto margen las restricciones, pero a su vez tienda 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 SVM. 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 SVM con margen máximo.

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

3.6 SVM para el caso multiclase

En principio, las SVM han sido propuestas para clasificación binaria, pero luego este método se extendió a clasificaciones multiclase, en la cual se emplean combinaciones de SVM binarias con la finalidad de considerar todas las clases a la vez.

Uno de los métodos para abordar el problema multiclase es el denominado uno contra uno, en el cual cada clase se compara con las restantes de manera separada. En este método el modelo SVM entrenado es construido para el uso de uno de los dos grupos. Este método construye un total de $K(K-1)/2$ clasificadores.

Esto es implementado en la biblioteca LIBSVM el cual resuelve el siguiente problema de clasificación binaria (Chang & Lin., 2001).

$$\begin{aligned}
& \min_{\omega_{kl}, b_{kl}, \xi_{kl}} \frac{1}{2} \|\omega_{kl}\|^2 + C \sum_{t=1}^m \xi_{klt} \\
& \omega_{kl}^t \phi(x_t) + b_{kl} \geq 1 - \xi_{klt} \quad \text{si } y_t = k \\
& \omega_{kl}^t \phi(x_t) + b_{kl} \leq -1 + \xi_{klt} \quad \text{si } y_t = l \\
& \xi_{klt} \geq 0, \quad t = 1, \dots, m
\end{aligned} \tag{3.5}$$

Cuando los datos de entrenamiento están a partir del k -ésimo y l -ésimo grupo. Habrá $K(K-1)/2$ clasificadores a ser construidos con la función de decisión:

$$C_g(x_i) = \begin{cases} k, \omega_{kl}^t \phi(x_t) + b_{kl} \geq 0, \\ l, \text{ en otro caso} \end{cases} \\ g = 1, \dots, k(k-1)/2$$

Un ejemplo x_i en la muestra de prueba se clasifica dentro de la clase y_i por mayoría de votos, es decir:

$$\hat{y}_i = \underset{k}{\operatorname{argmax}} \left\{ \sum_{g=1}^{k(k-1)/2} I[C_g(x_i) = k], k = 1, \dots, k \right\}$$

Cuando I es un indicador de función. Si los dos grupos tienen votos idénticos, LIBSVM selecciona uno con índice más pequeño.

3.7 Biblioteca LIBSVM

La investigación que se presenta en esta tesis aplica Máquinas de Vectores de Soporte, con la finalidad de obtener un modelo computacional eficiente, que logre identificar y caracterizar correctamente patrones de flujo multifásicos. Para aplicar dicha técnica, se utilizará el software correspondiente a la biblioteca LIBSVM (Chang & Lin., 2001). Este es un software de libre distribución creado por Chih-Jen Lin y Chih-Chung Chang de la Universidad de Taiwán, el cual requiere de los siguientes pasos:

1. Dividir el conjunto de datos en dos, un conjunto de datos para entrenar y otro para validar.
2. Ajustar la función Núcleo o Kernel. Para este estudio se utilizarán las funciones núcleo lineales, polinómicas y de base radial.
3. Ajustar el parámetro C (parámetro de regularización), el cual penaliza aquellos valores que violan a la clasificación.
4. Realizar el entrenamiento de la máquina con las muestras y parámetros seleccionados. Al realizar el entrenamiento de la máquina, se determina el modelo que se va a utilizar, es decir, se establecen los parámetros correspondientes para el conjunto de entrenamiento y se identifican el número de vectores de soporte.
5. Realizar las pruebas para medir el desempeño tanto para la clasificación como para medir la capacidad de pronóstico. Una vez obtenido los dos modelos con los datos suministrados, se procederá al diseño y desarrollo del programa donde estos son implantados, dicho programa será implantado en el lenguaje de programación QT4.

3.8 Fases para multclasificación con SVM

Los problemas de multclasificación pueden ser resueltos a través de una serie de pasos utilizando software especiales para ésto, entre los cuales se encuentran: SVM^{light}, LIBSVM, diferentes toolbox de Matlab, Spider, WEKA, entre muchos más.

La utilización de los programas para llevar a cabo multclasificación y biclasificación facilitan el uso de SVM, ya que sin ellos sería bastante complejo la aplicación de esta técnica. A continuación se explican, de manera general, pasos fundamentales para efectuar clasificación utilizando SVM a través de un programa diseñado para ese fin. Cabe

destacar que éstos pasos pueden variar, entre otras cosas, del software que se esté utilizando y de la complejidad de los datos con los que se esté trabajando.

3.9 Selección de las muestras

El primer paso fundamental para llevar a cabo clasificaciones con SVM, al igual que con otras técnicas, se refiere a la selección de la 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 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 la etiqueta de la clase, 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 SVM. La tarea de clasificación involucra tanto entrenamiento como validación de instancias de datos. Cada instancia en el conjunto de entrenamiento debe contener un valor objetivo o etiqueta de clase, es decir, la clase a la cual pertenece dicha instancia. 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 SVM para que ellas “aprendan” a clasificar correctamente las instancias con el menor error de clasificación posible.

3.12 Validación

La última fase de las SVM consiste en realizar las respectivas validaciones al clasificador seleccionado para medir su desempeño, esta fase es la que permite medir la capacidad de clasificación 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 SVM. Uno de los factores que se observa en esta etapa es la habilidad de los modelos probados para clasificar correctamente instancias desconocidas. En otras palabras, lo que se hace es evaluar la efectividad de los parámetros seleccionados para producir clasificaciones 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 SVM incluye la identificación del error de clasificación que se tiene con el modelo seleccionado, las clases establecidas por dicho modelo, entre otros. En muchos casos, la interpretación incluirá comparaciones con otras técnicas estudiadas con la intención de verificar la capacidad predictiva de las SVM.

www.bdigital.ula.ve

Capítulo 4

Resultados

Este capítulo explica detalladamente en que consistió la experimentación y los resultados obtenidos en la misma. Esta fase es la que permite medir la capacidad de generalización de las SVM, es decir, la capacidad de clasificación para nuevas observaciones, siendo ésta una de las características más atractivas de dicha técnica. De este modo, el objetivo que se persigue es producir un modelo que permita clasificar correctamente la clase a la que pertenece cada instancia y evaluar la efectividad de los parámetros seleccionados para producir clasificaciones acertadas. Posteriormente, se realiza la interpretación de los resultados obtenidos a través de las SVM.

Es importante destacar que en esta etapa se obtendrán dos modelos, uno que permitirá clasificar patrones de flujo con variables dimensionales y otro que permitirá patrones de flujo con variables adimensionales.

4.1 Recopilación de los datos

El proceso de clasificación de patrones de flujo se lleva a cabo en 2 fases, en la primera, Fase I, se busca el modelo que genere buenos resultados con variables dimensionales, para este caso se emplearon 9028 datos, con 8 variables cada uno, los cuales se dividieron en dos grupos, 4514 para entrenar y 4514 para validar. En la tabla 4.1 se muestran las variables que se tienen en cuenta para esta fase I.

Variable	Símbolo	Unidades fundamentales
Densidad del gas	ρ_g	Kg/m ³ ; M/L ³
Densidad del líquido	ρ_l	Kg/m ³ ; M/L ³
Viscosidad del gas	μ_g	Pa.s; M/(t.L)
Viscosidad del líquido	μ_l	Pa.s; M/(t.L)
Diámetro del tubo	d	m; L
Ángulo de inclinación	θ	rad
Velocidad Superficial del gas	V_{sg}	m/s; L/t
Velocidad superficial del líquido	V_{sl}	m/s; L/t

Tabla 4.1. Variables en la fase I.

En la segunda fase, Fase II, se trabaja con variables adimensionales donde se reduce la cantidad de variables, no se reduce la cantidad de datos en estudio, esto es debido a que se aplica el Teorema Pi (π). Como en la primera fase se tienen 8 variables y 3 unidades fundamentales (masa, longitud y tiempo), según este teorema son 5 grupos de variables adimensionales los que se pueden formar, X, Y, T, F y K. En las siguientes ecuaciones se muestra como se hallan estas variables.

$$X^2 = \frac{dp/dx|_{sl}}{dp/dx|_{sg}} \quad (4.1)$$

$$Y = \frac{(\rho_l - \rho_g) \cdot g \cdot \sin \theta}{-dp/dx|_{sg}} \quad (4.2)$$

$$T^2 = \frac{dp/dx|_{sl}}{(\rho_l - \rho_g) \cdot g \cdot \cos \theta} \quad (4.3)$$

$$F^2 = \frac{\rho_l V_{sg}^2}{(\rho_l - \rho_g) \cdot g \cdot d \cdot \cos \theta} \quad (4.4)$$

$$K = F^2 \cdot Res_l \quad (4.5)$$

Donde:

$$Res_l = \frac{\rho_l \cdot d \cdot V_{sl}}{\mu_l} \quad (4.6)$$

$$Res_g = \frac{\rho_g \cdot d \cdot V_{sg}}{\mu_g} \quad (4.7)$$

$$\frac{dp}{dx} |_{sl} = 4 \cdot C_l \cdot Res_l^{-n} \cdot \frac{\rho_l \cdot V_{sl}^2}{2} \quad (4.8)$$

$$\frac{dp}{dx} |_{sg} = 4 \cdot C_g \cdot Res_g^{-m} \cdot \frac{\rho_g \cdot V_{sg}^2}{2} \quad (4.9)$$

Para calcular los valores mencionados anteriormente se debe tener en cuenta las siguientes condiciones.

$$Res_l < 2300 \begin{cases} C_l = 16 \\ n = 1 \end{cases}$$

$$Res_l \geq 2300 \begin{cases} C_l = 0.046 \\ n = 0.2 \end{cases}$$

(4.10)

$$Res_g < 2300 \begin{cases} C_g = 16 \\ m = 1 \end{cases}$$

$$Res_g \geq 2300 \begin{cases} C_g = 0.046 \\ m = 0.2 \end{cases}$$

En ambas fases el proceso de clasificación se realiza con 5 patrones de flujo, a cada patrón se le asigna un número identificativo de clase, obteniendo así 5 clases, a continuación se muestra en la tabla 4.2 los patrones que se estudian con su correspondiente número de identificación.

Clase	Patrón de Flujo	Cantidad de Datos
1	Burbujas Dispersas	408
2	Estratificado	837
3	Anular	832
4	Intermitente	2361
5	Burbujas	76

Tabla 4.2. Identificación de cada clase con su respectiva cantidad de datos.

El software empleado para el entrenamiento de las SVM en los experimentos es LIBSVM. Este implementa la solución multiclase uno contra uno, lo que en este caso implica entrenar y usar $(5)*(4)/2=10$ SVM binarias para obtener el modelo de ambas fases.

4.2 Selección del kernel

La selección del modelo consiste en determinar el kernel que se utilizará y los valores de los parámetros del mismo. En este momento se hace oportuno tener claro cuáles son los kernels que se pueden utilizar, los cuales varían dependiendo del software que se haya decidido manipular. Además, es necesario conocer cuáles son los parámetros que pueden variar en cada kernel, los cuales dependen directamente de su tipo, pues cada uno posee diferentes parámetros asociados a él.

Aunque existen varios tipos de kernels comunes, es necesario decidir cuál de ellos se probará primero. Esta es una etapa fundamental por cuanto la obtención de resultados acertados dependerá, en gran parte, de la selección de un kernel adecuado y, por supuesto, de apropiados valores de los parámetros del mismo. Para poder identificar de manera precisa los patrones de flujo multifásico se utilizarán los kernel función de base radial, polinómico y lineal.

4.3 Ajuste del parámetro C

Uno de los parámetros cuyo valor es necesario determinar es el conocido como C, que se refiere al parámetro de penalidad para el error. En otras palabras, es el que va a permitir la holgura para tener cierto error de clasificación a cambio de tener una mejor generalización de los datos. Sin embargo, el valor de este parámetro varía de acuerdo a los datos que se desean clasificar, por lo tanto, se recomienda que se haga una búsqueda exhaustiva de un valor adecuado que permita clasificar correctamente la mayor cantidad de instancias desconocidas como sea posible.

Es importante tener en cuenta que con un valor muy elevado de C se tiene una alta penalización para puntos no separables y se tiende a tener muchos vectores de soporte, lo que puede llevar al sobreajuste y, con esto, a la mala generalización. Por otra parte, un valor muy pequeño de C hace que el modelo sea muy rígido, lo que puede conducir a un subajuste.

Tomando esto en cuenta, los valores de C que se utilizaron para medir el desempeño de ambos modelos varían entre 0,01 y 1000, mientras que el valor de γ se varió entre 0,01 y 0,2.

4.4 Pruebas y análisis de los resultados

La fase de clasificación con SVM consiste en realizar las respectivas pruebas al clasificador seleccionado para medir su desempeño. A la herramienta se le suministró un conjunto de datos para la validación compuesto de instancias diferentes a las incluidas en la muestra de entrenamiento.

4.4.1 Resultados primera Fase: Variables dimensionales

Las tablas que se presentan a continuación muestran los resultados de las diferentes configuraciones propuestas al variar los parámetros de los kernel lineal, RBF y polinomial, con la finalidad de observar su efecto sobre el número de clasificaciones correctas de instancias desconocidas y de este modo determinar el mejor modelo para clasificar patrones de flujo con variables dimensionales, como se mencionó anteriormente en esta fase se tienen 5 patrones de flujo y 8 variables que caracterizan cada patrón.

En la Tabla 4.3 se puede observar que la configuración que arroja mejores resultados para el kernel lineal es la número 2 con un valor del parámetro $C=0.01$, obteniendo un 67.72% de instancias desconocidas clasificadas correctamente.

La Tabla 4.4 muestra los resultados de las 13 configuraciones realizadas con el kernel RBF, donde la mejor clasificación 64.07% se obtuvo en la configuración número 13 con valores de C y γ de 1000 y 1.5 respectivamente.

La Tabla 4.5 muestra los resultados de las configuraciones realizadas con el kernel polinomial de grado 2, donde la mejor clasificación de instancias desconocidas es de 66.46% que se obtuvo en la configuración número 3 con valores de C , γ y r de 0.01, 0.001 y 0.001 respectivamente.

Configuración	C	Instancias clasificadas correctamente
1	0.001	63.78% (2879/4514)
2	0.01	67.72% (3057/4514)
3	0.1	60.94% (2751/4514)
4	1	56.23% (2538/4514)
5	10	61.1653% (2761/4514)
6	100	55.91% (2524/4514)

Tabla 4.3. Resultados de las configuraciones propuestas para el kernel lineal.
5 patrones 8 variables

Configuración	C	γ	Instancias clasificadas correctamente
1	0.1	0.01	62.74% (2832/4514)
2	0.1	0.1	63.56% (2869/4514)
3	1	0.01	62.76% (2833/4514)
4	1	0.1	61.34% (2769/4514)
5	1	1	59.48% (2685/4514)
6	10	0.01	59.08% (2667/4514)
7	10	1	60.37% (2725/4514)
8	10	1.5	61.28% (2766/4514)
9	100	1	63.78% (2879/4514)
10	100	1.5	63.51% (2867/4514)
11	100	2	63.07% (2847/4514)
12	1000	1	63.20% (2853/4514)
13	1000	1.5	64.07% (2892/4514)

Tabla 4.4. Resultados de las configuraciones propuestas para el kernel RBF.
5 patrones 8 variables

Configuración	C	γ	R	Instancias clasificadas correctamente
1	0.01	0.01	0.01	58.95%(2661/4514)
2	0.01	0.0001	0.0001	58.99%(2663/4514)
3	0.01	0.001	0.001	66.46%(3000/4515)
4	0.01	1	1	57.22%(2583/4514)
5	0.01	0.1	0.1	58.51%(2641/4514)
6	0.01	10	10	58.37%(2635/4514)
7	0.1	0.01	0.01	60.68%(2739/4514)
8	1	0.01	0.01	59.90%(2704/4514)
9	10	0.01	0.01	58.26%(2630/4514)
10	100	0.01	0.01	60.61%(2736/4514)
11	100	0.001	0.001	56.93%(2570/4514)
12	1000	0.01	0.01	61.87%(2793/4514)
13	1000	0.0001	0.0001	60.61%(2736/4514)

**Tabla 4.5. Resultados de las configuraciones propuestas para el kernel polinomial.
5 patrones 8 variables**

Con el propósito de obtener un mejor porcentaje de clasificación se realizaron nuevas pruebas, para así determinar cuáles son los patrones de flujo que causan conflicto al momento de realizar la clasificación. Para realizar tal identificación se realizaron 10 clasificaciones binarias y 9 clasificaciones multiclase con los tres kernel propuestos, en las siguientes tablas se muestran los mejores resultados obtenidos para cada configuración.

En la tabla 4.6 se observan los resultados del kernel lineal, donde los patrones de flujo de menos porcentaje de clasificación se tiene entre el patrón estratificado (clase 2) y el patrón anular (clase 3) con el parámetro $C=0.01$ obteniendo 72.92% de instancias clasificadas correctamente. Mientras que entre el patrón de flujo anular (clase 3) y burbujas (clase 5) se obtuvo el 100% de instancias clasificadas con el parámetro $C=1$.

Configuración	C	Instancias clasificadas correctamente
1-2	1	94.06% (1171/1245)
1-3	0.1	94.68% (1174/1240)
1-4	0.1	93.10% (2578/2769)
1-5	0.01	95.04% (460/484)
2-3	0.01	72.92% (1217/1669)
2-4	0.1	78.61% (2514/3198)
2-5	0.01	99.67% (909/912)
3-4	0.01	87.75% (2802/3193)
3-5	1	100%
4-5	0.01	96.88% (2361/2437)

Tabla 4.6. Resultados de las combinaciones binarias propuestas para el kernel lineal.

Para el kernel polinomial de grado 2 el mínimo porcentaje de clasificación no alcanza el 70% donde nuevamente son los patrones de flujo estratificado (clase 2) y anular (clase 3) con menor porcentaje de instancias clasificadas correctamente, 69.74%, este resultado se logró con los parámetros C, gamma y r de valores 10, 0.1 y 10 respectivamente.

Por otra parte, se logró clasificar correctamente el 100% de las instancias desconocidas entre los patrones de flujo estratificado (clase 2) y burbujas (clase 5) con los valores de los parámetros C, gamma y r de 0.1, 0.0125 y 1000, respectivamente. En la tabla 4.7 se observan estos resultados.

Finalmente, para las combinaciones binarias se utilizó el kernel RBF llegando a la misma conclusión de los dos kernel mostrados anteriormente, sólo se logró clasificar el 75.25% de las instancias de los patrones de flujo estratificado (clase 2) y anular (clase 3), mientras que con los patrones de flujo estratificado (clase 2) y burbujas (clase 5) se logró clasificar correctamente el 100% de las instancias. La tabla 4.8 muestra estos resultados.

Configuración	C	γ	r	Instancias clasificadas correctamente
1-2	100	0.01	100	95.58%(1190/1245)
1-3	1	0.0150	10	92.42%(1146/1240)
1-4	1000	0.01	100	91.91%(2545/2769)
1-5	0.1	0.1	1000	84.71%(410/484)
2-3	10	0.1	10	69.74%(1164/1669)
2-4	1000	0.0125	0.1	81.93%(2620/3198)
2-5	0.1	0.0125	1000	100%(912/912)
3-4	100	0.0150	10	88.88%(2838/3193)
3-5	0.1	0.01	100	97.68%(887/908)
4-5	0.1	0.0150	1000	87.94%(2143/2437)

Tabla 4.7. Resultados de las combinaciones binarias propuestas para el kernel polinomial.

Con estas pruebas se logra identificar que al momento de que la SVM realiza el proceso de clasificación de los 5 patrones de flujo el conflicto más notorio es cuando intenta clasificar los datos del patrón de flujo estratificado y del patrón de flujo anular.

Para corroborar dicho conflicto y verificar el comportamiento de la SVM al momento que se le van agregando patrones de flujo para que realice la clasificación correspondiente, se procede a realizar combinaciones de tres clases para cada kernel seleccionado.

En el caso del kernel lineal el mínimo porcentaje de clasificación es de 70.65%, con un parámetro $C=0.1$, entre los patrones de flujo estratificado (clase 2), anular (clase 3) e intermitente (clase 4), el mejor porcentaje de instancias desconocidas clasificadas correctamente es un 93.49% tal clasificación se da entre los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2) y burbujas (clase 5) con un parámetro $C=0.01$. Estos resultados se pueden observar en la tabla 4.9.

Configuración	C	γ	Instancias clasificadas correctamente
1-2	0.1	0.0175	95.26%(1186/1245)
1-3	10	0.01	87.5%(1085/1240)
1-4	1000	0.01	93.97%(2602/2769)
1-5	0.1	0.0175	95.87%(464/484)
2-3	1000	0.0175	75.25%(1256/1669)
2-4	1000	0.0175	83.43%(2668/3198)
2-5	1	0.01	100%(912/912)
3-4	10	0.0125	88.73%(2833/3193)
3-5	1	0.0175	83.04%(754/908)
4-5	0.1	0.01	96.88%(2361/2437)

Tabla 4.8. Resultados de las combinaciones binarias propuestas para el kernel RBF.

Configuración	C	Instancias clasificadas correctamente
1-2-3	0.1	74.48%(1547/2077)
1-2-4	0.1	76.34%(2753/3606)
1-2-5	0.01	93.49%(1235/1321)
1-3-4	10	84.25%(3034/3601)
2-3-4	0.1	70.65%(2847/4030)
2-3-5	0.01	73.93%(1290/1745)
3-4-5	0.01	85.71%(2802/3269)

Tabla 4.9. Resultados de las combinaciones de tres clases propuestas para el kernel lineal.

Configuración	C	γ	r	Instancias clasificadas correctamente
1-2-3	1000	0.1	10	78.57%(1632/2077)
1-2-4	1000	0.0125	0.1	78.28%(2823/3606)
1-2-5	100	0.01	100	90.31%(1193/1321)
1-3-4	1000	0.01	100	83.81%(3018/3601)
2-3-4	100	0.0150	10	71.12%(2866/4030)
2-3-5	1	0.1	10	71.52%(1248/1745)
3-4-5	10	0.0150	10	78.98%(2582/3269)

Tabla 4.10. Resultados de las combinaciones de tres clases propuestas para el kernel polinomial.

En la tabla 4.10 se observa que para el kernel polinomial de grado 2 el mínimo porcentaje de clasificación es de 71.12%, con los parámetros $C=100$, $\gamma=0.0150$ y $r=10$, los patrones de flujo que obtuvieron dicho porcentaje de clasificación fueron estratificado (clase 2), anular (clase 3) e intermitente (clase 4).

Al realizar la combinación de los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2) y burbujas (clase 5) se obtuvo el mejor resultado con un porcentaje de 93.49% de instancias clasificadas correctamente con los parámetros $C=100$, $\gamma=0.01$ y $r=100$.

Para el kernel RBF se observó el mismo comportamiento que en los kernel polinomial y lineal donde nuevamente se observa que el mínimo porcentaje de clasificación se obtuvo con los patrones de flujo estratificado (clase 2), anular (clase 3) e intermitente (clase 4) con un 71.36% con los parámetros $C=10$, $\gamma=0.0175$, y el mejor porcentaje de clasificación se dio con los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2) y burbujas (clase 5) de 93.64% de instancias clasificadas correctamente con los parámetros $C=1$, $\gamma=0.0175$. En la tabla 4.11 se observan estos resultados.

Configuración	C	γ	Instancias clasificadas correctamente
1-2-3	1000	0.0175	76.69%(1593/2077)
1-2-4	1000	0.0125	79.76%(2876/3606)
1-2-5	1	0.0175	93.64%(1237/1321)
1-3-4	10	0.01	83.81%(3018/3601)
2-3-4	10	0.0175	71.36%(2876/4030)
2-3-5	1000	0.0125	77.36%(1350/1745)
3-4-5	0.1	0.01	83.48%(2729/3269)

Tabla 4.11. Resultados de las combinaciones de tres clases propuestas para el kernel RBF.

Finalmente, se realiza una prueba con configuraciones de cuatro patrones de flujo para cada uno de los kernel, en la tabla 4.12 se puede observar los resultados obtenidos para el kernel lineal donde el mejor porcentaje de clasificación es de 75.01% con los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2), anular (clase 3) y burbujas (clase 5), teniendo un parámetro $C=0.01$.

Configuración	C	Instancias clasificadas correctamente
1-2-3-4	0.1	69.54%(3086/4438)
1-2-3-5	0.01	75.01%(1615/2153)
2-3-4-5	0.01	69.31%(2846/4106)

Tabla 4.12. Resultados de las combinaciones de cuatro clases propuestas para el kernel lineal.

En la tabla 4.13 se observan los resultados obtenidos para el kernel RBF, donde nuevamente el mejor porcentaje de clasificación se da con los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2), anular (clase 3) y burbujas (clase 5),

obteniendo 74.13% de instancias clasificadas correctamente con los parámetros $C=1000$ y $\gamma=0.0175$.

Configuración	C	γ	Instancias clasificadas correctamente
1-2-3-4	10	0.0175	68.93%(3059/4438)
1-2-3-5	1000	0.0175	74.13%(1596/2153)
2-3-4-5	0.1	0.0150	66.34%(2724/4106)

Tabla 4.13. Resultados de las combinaciones de cuatro clases propuestas para el kernel RBF.

En la tabla 4.14 se observa como los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2), anular (clase 3) y burbujas (clase 5), obtienen el mejor resultado de clasificación para el kernel polinomial con un 70.83% de instancias clasificadas correctamente con los parámetros $C=100$, $\gamma=0.0150$ y $r=10$.

Configuración	C	γ	R	Instancias clasificadas correctamente
1-2-3-4	100	0.0150	10	69.13%(3068/4438)
1-2-3-5	10	0.01	100	70.83%(1525/2153)
2-3-4-5	10	0.0150	10	63.76%(2618/4106)

Tabla 4.14. Resultados de las combinaciones de cuatro clases propuestas para el kernel polinomial.

Luego de realizar todas las pruebas anteriores se observa claramente como al ir agregando patrones de flujo al proceso de clasificación el porcentaje de instancias clasificadas correctamente disminuye, esto es debido a que los datos experimentales no están bien correlacionados ya que son tomados visualmente a través de una sección transparente de la tubería. Debido a que en la industria petrolera los patrones de flujo intermitente y burbujas pueden empaquetarse en un solo patrón de flujo, se decide

realizar este agrupamiento con el fin de verificar si se puede obtener un mejor porcentaje de clasificación, a continuación en la tabla 4.15 se observan las nuevas clases para realizar las pruebas de clasificación correspondientes.

Clase	Patrón de Flujo	Cantidad de datos
1	Burbujas dispersas	408
2	Estratificado	837
3	Anular	832
4	Intermitente + Burbujas	2437

Tabla 4.15. Identificación de las nuevas clases con su respectiva cantidad de datos.

La tabla 4.17 muestra los resultados obtenidos para el kernel lineal con los 4 patrones mencionados anteriormente, obteniendo un porcentaje de 70.25% de instancias clasificadas correctamente con un parámetro $C=1$.

Configuración	C	Instancias clasificadas correctamente
1	0.01	68.52%(3093/4514)
2	0.1	69.87%(3154/4514)
3	1	70.25%(3171/4514)
4	10	68.69%(3101/4514)
5	100	68.23%(3080/4514)
6	1000	70.16%(3167/4514)

Tabla 4.17. Resultados obtenidos para el kernel lineal con cuatro patrones de flujo.

La tabla 4.18 muestra los resultados obtenidos de las 20 configuraciones propuestas para el kernel RBF donde se obtuvo un porcentaje de 69.36% de instancias clasificadas

correctamente, este resultado se observa con la configuración número 11 con un parámetro $C=10$ y $\gamma=0.0150$.

Configuración	C	γ	Instancias clasificadas correctamente
1	0.1	0.01	64.42%(2908/4514)
2	0.1	0.0125	64.44%(2909/4514)
3	0.1	0.0150	64.51%(2912/4514)
4	0.1	0.0175	64.53%(2913/4514)
5	1	0.01	65.37%(2951/4514)
6	1	0.0125	65.68%(2965/4514)
7	1	0.0150	65.91%(2975/4514)
8	1	0.0175	66.11%(2984/4514)
9	10	0.01	68.61%(3097/4514)
10	10	0.0125	69.07%(3118/4514)
11	10	0.0150	69.36%(3131/4514)
12	10	0.0175	69.29%(3128/4514)
13	100	0.01	66.26%(2991/4514)
14	100	0.0125	67.06%(3027/4514)
15	100	0.0150	68.16%(3077/4514)
16	100	0.0175	67.99%(3069/4514)
17	1000	0.01	66.88%(3019/4514)
18	1000	0.0125	68.23%(3080/4514)
19	1000	0.0150	68.63%(3098/4514)
20	1000	0.0175	68.74%(3103/4514)

Tabla 4.18. Resultados obtenidos para el kernel RBF con cuatro patrones de flujo.

Para el kernel polinomial de grado 2 se tienen 19 configuraciones donde se obtuvo un porcentaje de 69.43% de instancias clasificadas correctamente con los parámetros $C=1000$, $\gamma=0.01$ y $r=100$, en la configuración número 17. Estos resultados se pueden observar en la tabla 4.19.

Configuración	C	γ	R	Instancias clasificadas correctamente
1	0.1	0.01	100	68.81%(3106/4514)
2	0.1	0.0125	1000	68.92%(3111/4514)
3	0.1	0.0150	1000	65.84%(2972/4514)
4	0.1	0.1	1000	66.15%(2986/4514)
5	1	0.01	100	68.89%(3110/4514)
6	1	0.0125	1000	66.37%(2996/4514)
7	1	0.0150	10	66.42%(2998/4514)
8	1	0.1	10	68.56%(3095/4514)
9	10	0.01	100	68.85%(3108/4514)
10	10	0.0125	1000	68.78%(3105/4514)
11	10	0.0150	10	68.61%(3097/4514)
12	10	0.1	10	68.56%(3095/4514)
13	100	0.01	100	69.07%(3118/4514)
14	100	0.0125	1000	68.98%(3114/4514)
15	100	0.0150	10	68.08%(3073/4514)
16	100	0.1	10	69.07%(3118/4514)
17	1000	0.01	100	69.43%(3134/4514)
18	1000	0.0125	0.1	67.41%(3043/4514)
19	1000	0.0150	10	68.92%(3111/4514)

Tabla 4.19. Resultados obtenidos para el kernel polinomial con cuatro patrones de flujo.

Se puede observar claramente como el kernel lineal es el que arroja un mejor porcentaje de clasificación con los nuevos cuatro patrones de flujo, al igual que cuando se estudiaron los cinco patrones de flujo, se procede a realizar 6 pruebas binarias y 4 pruebas con tres clases, con el propósito de obtener mejores porcentajes de clasificación, de igual forma con la realización de estas pruebas se busca determinar cuál es el patrón de flujo que causa conflicto al momento de realizar el proceso de clasificación, en las tablas se muestran los mejores resultados obtenidos para cada configuración.

En la tabla 4.20 se observan los resultados obtenidos para el kernel lineal con configuraciones binarias donde el mejor resultado es de 95% de instancias clasificadas correctamente con los patrones de flujo burbujas dispersas (clase 1) y anular (clase 3), dicha clasificación se obtuvo con un parámetro $C=1$, mientras que entre los patrones de flujo estratificado (clase 2) y anular (clase 3) sólo se alcanzó un 72.92% de instancias clasificadas correctamente.

Configuración	C	Instancias clasificadas correctamente
1-2	0.01	93.49%(1164/1245)
1-3	1	95%(1178/1240)
1-4	0.01	93.22%(2652/2845)
2-3	0.01	72.92%(1217/1669)
2-4	100	80.48%(2635/3274)
3-4	1	89.11%(2913/3269)

Tabla 4.20. Resultados obtenidos para las configuraciones binarias con el kernel lineal.

Para el kernel polinomial de grado 2 el mínimo porcentaje de clasificación obtenido nuevamente corresponde a los patrones de flujo estratificado (clase 2) y anular (clase 3) con un porcentaje de instancias clasificadas correctamente de 69.98%, este resultado se logró con los parámetros C, gamma y r de valores 100, 0.01 y 100 respectivamente.

Por otra parte se logró clasificar correctamente el 93.49% de las instancias desconocidas entre los patrones de flujo burbujas dispersas (clase 1) y estratificado (clase 2) con los valores de los parámetros C , γ y r de 1, 0.0125 y 1000, respectivamente. Tales resultados se pueden observar en la tabla 4.21.

Finalmente, para las combinaciones binarias se utilizó el kernel RBF llegando a la misma conclusión que en el kernel polinomial, ya que el mejor resultado se obtuvo entre los patrones de flujo burbujas dispersas (clase 1) y estratificado (clase 2) con un 95.26% de instancias clasificadas correctamente con los parámetros $C=0.1$ y $\gamma=0.0175$, mientras que se sigue observando que los patrones de flujo estratificado (clase 2) y anular (clase 3) son los que arrojan menor porcentaje de clasificación con un 74.89% con los parámetros $C=1000$ y $\gamma=0.0175$. En la tabla 4.22 se observan estos resultados.

Configuración	C	γ	R	Instancias clasificadas correctamente
1-2	1	0.0125	1000	93.49%(1164/1245)
1-3	0.1	0.0150	1000	92.90%(1152/1240)
1-4	1000	0.01	100	92.72%(2638/2845)
2-3	100	0.01	100	69.98%(1168/1669)
2-4	100	0.01	100	81.67%(2674/3274)
3-4	100	0.1	10	89.23%(2917/3269)

Tabla 4.21. Resultados de las combinaciones binarias propuestas para el kernel polinomial.

Con estas pruebas se logra verificar que al momento de que la SVM realiza el proceso de clasificación de los 4 patrones de flujo el conflicto más notorio es cuando intenta clasificar los datos del patrón de flujo estratificado y del patrón de flujo anular.

Configuración	C	γ	Instancias clasificadas correctamente
1-2	0.1	0.0175	95.26%(1186/1245)
1-3	10	0.01	87.5%(1085/1240)
1-4	1000	0.01	93.71%(2666/2845)
2-3	1000	0.0175	74.89%(1250/1669)
2-4	1000	0.0175	83.63%(2738/3274)
3-4	10	0.0125	88.98%(2909/3269)

Tabla 4.22. Resultados de las combinaciones binarias propuestas para el kernel RBF.

Para verificar el comportamiento de la SVM al agregarle patrones de flujo para realizar el proceso de clasificación se realizan pruebas con tres patrones y cada uno de los kernel seleccionados, en las tablas siguientes se muestran los mejores resultados de las diferentes configuraciones para cada kernel.

En el caso del kernel lineal el mínimo porcentaje de clasificación es de 71.87%, con un parámetro $C=1$, entre los patrones de flujo estratificado (clase 2), anular (clase 3) e intermitente más burbujas (clase 4), el mejor porcentaje de instancias desconocidas clasificadas correctamente es del 84.12% tal clasificación se da entre los patrones de flujo burbujas dispersas (clase 1), anular (clase 3) e intermitente más burbujas (clase 4) con un parámetro $C=0.01$. Estos resultados se pueden observar en la tabla 4.23.

Configuración	C	Instancias clasificadas correctamente
1-2-3	0.1	74.48%(1544/2073)
1-2-4	10	77.43%(2851/3682)
1-3-4	0.01	84.12%(3093/3677)
2-3-4	1	71.87%(2951/4106)

Tabla 4.23. Resultados de las combinaciones de tres clases propuestas para el kernel lineal.

En la tabla 4.24 se observa que para el kernel polinomial de grado 2 el mínimo porcentaje de clasificación es de 71.53%, con los parámetros $C=1000$, $\gamma=0.0150$ y $r=10$, los patrones de flujo que obtuvieron dicho porcentaje de clasificación fueron estratificado (clase 2), anular (clase 3) e intermitente (clase 4).

Al realizar la combinación de los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2) e intermitente más burbujas (clase 4) se obtuvo el mejor resultado con un porcentaje de 83.98% de instancias clasificadas correctamente con los parámetros $C=100$, $\gamma=0.0125$ y $r=1000$.

Configuración	C	γ	R	Instancias clasificadas correctamente
1-2-3	100	0.01	100	72.07%(1494/2073)
1-2-4	1000	0.01	100	78.06%(2874/3682)
1-3-4	100	0.0125	1000	83.98%(3088/3677)
2-3-4	1000	0.0150	10	71.53%(2937/4106)

Tabla 4.24. Resultados de las combinaciones de tres clases propuestas para el kernel polinomial.

Para el kernel RBF se observó el mismo comportamiento que en los kernel polinomial y lineal donde nuevamente se observa que el mínimo porcentaje de clasificación se obtuvo con los patrones de flujo estratificado (clase 2), anular (clase 3) e intermitente + burbujas (clase 4) con un 71.75% con los parámetros $C=10$, $\gamma=0.0175$, y el mejor porcentaje de clasificación se dio con los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2) e intermitente más burbujas (clase 4) de 84.15% de instancias clasificadas correctamente con los parámetros $C=10$, $\gamma=0.01$. En la tabla 4.25 se observan estos resultados.

Configuración	C	γ	Instancias clasificadas correctamente
1-2-3	1000	0.0175	76.36%(1583/2073)
1-2-4	1000	0.0175	80.09%(2949/3682)
1-3-4	10	0.01	84.15%(3094/3677)
2-3-4	10	0.0175	71.75%(2946/4106)

Tabla 4.25. Resultados de las combinaciones de tres clases propuestas para el kernel RBF.

Luego de realizar las pruebas correspondientes se verifica nuevamente que al agregar patrones de flujo al proceso de clasificación el porcentaje de instancias clasificadas correctamente disminuye, aunque se realizó el agrupamiento del patrón de flujo intermitente más burbujas la cantidad de instancias clasificadas correctamente es del 70.25% (ver tabla 4.17), es por ello que se decide realizar un agrupamiento más radical y obtener solamente 3 patrones de flujo, tal agrupamiento se observa en la tabla 4.26.

Clase	Patrón de Flujo	Cantidad de datos
1	Burbujas dispersas	408
2	Estratificado + Anular	1669
3	Intermitente + Burbujas	2437

Tabla 4.26. Identificación de las nuevas clases con su respectiva cantidad de datos.

Configuración	C	Instancias clasificadas correctamente
1	0.01	75.92%(3427/4514)
2	0.1	79.44%(3586/4514)
3	1	76.92%(3472/4514)
4	10	78.31%(3535/4514)
5	100	77.85%(3514/4514)
6	1000	77.89%(3516/4514)

Tabla 4.27. Resultados obtenidos para el kernel lineal con tres patrones de flujo.

La tabla 4.27 muestra los resultados obtenidos para el kernel lineal con los 3 patrones mencionados anteriormente, obteniendo un porcentaje de 79.44% de instancias clasificadas correctamente con un parámetro $C=0.1$, se puede observar que al realizar el agrupamiento los resultados mejoran.

Configuración	C	γ	Instancias clasificadas correctamente
1	0.1	0.01	68.38%(3087/4514)
2	0.1	0.0125	68.43%(3089/4514)
3	0.1	0.0150	68.47%(3091/4514)
4	0.1	0.0175	68.49%(3092/4514)
5	1	0.01	69.54%(3139/4514)
6	1	0.0125	69.81%(3151/4514)
7	1	0.0150	69.96%(3158/4514)
8	1	0.0175	70.05%(3162/4514)
9	10	0.01	76.76%(3465/4514)
10	10	0.0125	76.94%(3473/4514)
11	10	0.0150	77.32%(3490/4514)
12	10	0.0175	77.34%(3491/4514)
13	100	0.01	79.88%(3606/4514)
14	100	0.0125	79.62%(3594/4514)
15	100	0.0150	78.59%(3548/4514)
16	100	0.0175	78.11%(3526/4514)
17	1000	0.01	79.82%(3603/4514)
18	1000	0.0125	77.74%(3509/4514)
19	1000	0.0150	77.36%(3492/4514)
20	1000	0.0175	76.67%(3461/4514)

Tabla 4.28. Resultados obtenidos para el kernel RBF con tres patrones de flujo.

La tabla 4.28 muestra los resultados obtenidos de las 20 configuraciones propuestas para el kernel RBF donde se obtuvo un porcentaje de 79.88% de instancias clasificadas correctamente, este resultado se observa con la configuración número 13 con un parámetro $C=100$ y $\gamma=0.01$.

Configuración	C	γ	R	Instancias clasificadas correctamente
1	0.1	0.01	100	79.04%(3568/4514)
2	0.1	0.0125	1000	77.67%(3506/4514)
3	0.1	0.0150	1000	76.25%(3442/4514)
4	0.1	0.1	1000	75.58%(3412/4514)
5	1	0.01	100	76.38%(3448/4514)
6	1	0.0125	1000	76.61%(3458/4514)
7	1	0.0150	10	76.27%(3443/4514)
8	1	0.1	10	78.78%(3556/4514)
9	10	0.01	10	76.25%(3440/4514)
10	10	0.0125	1000	77.58%(3502/4514)
11	10	0.0150	10	76.76%(3465/4514)
12	10	0.1	10	78.22%(3531/4514)
13	100	0.01	100	76.38%(3448/4514)
14	100	0.0125	1000	77.51%(3499/4514)
15	100	0.0150	10	76.67%(3461/4514)
16	100	0.1	10	78.13%(3527/4514)
17	1000	0.01	100	77.85%(3514/4514)
18	1000	0.0125	0.1	78.18%(3529/4514)
19	1000	0.0150	10	76.69%(3462/4514)

Tabla 4.29. Resultados obtenidos para el kernel polinomial con tres patrones de flujo.

Para el kernel polinomial de grado 2 se tienen 19 configuraciones donde se obtuvo un porcentaje de 79.04% de instancias clasificadas correctamente con los parámetros $C=0.1$, $\gamma=0.01$ y $r=100$, en la configuración número 1, estos resultados se observan en la tabla 4.29.

Se puede observar claramente como el kernel polinomial es el que arroja un mejor porcentaje de clasificación con los nuevos tres patrones de flujo, al igual que cuando se estudiaron los cinco patrones de flujo y los cuatro patrones de flujo, realizan 3 pruebas binarias para determinar cuáles son los patrones que presentan problema al momento de realizar la clasificación.

En la tabla 4.30 se observan los resultados obtenidos para el kernel lineal con configuraciones binarias donde el mejor resultado es de 96.44%, el cual corresponde a los patrones de flujo burbujas dispersas (clase 1) y estratificado más anular (clase 2), dicha clasificación se obtuvo con un parámetro $C=1$.

Configuración	C	Instancias clasificadas correctamente
1-2	1	96.44%(2003/2077)
1-3	0.01	93.21%(2651/2844)
2-3	0.1	83.09%(3412/4106)

Tabla 4.30. Resultados obtenidos para las configuraciones binarias con el kernel lineal.

En la tabla 4.31 se observan los resultados obtenidos para el kernel RBF con configuraciones binarias donde el mejor resultado es de 97.06%, donde nuevamente corresponde a los patrones de flujo burbujas dispersas (clase 1) y estratificado más anular (clase 2), dicha clasificación se obtuvo con un parámetro $C=0.1$ y $\gamma=0.0150$.

Configuración	C	γ	Instancias clasificadas correctamente
1-2	0.1	0.0150	97.06%(2016/2077)
1-3	1000	0.01	93.71%(2665/2844)
2-3	100	0.0125	82.34%(3381/4106)

Tabla 4.31. Resultados obtenidos para las configuraciones binarias con el kernel RBF.

En la tabla 4.32 se observan los resultados obtenidos para el kernel polinomial con configuraciones binarias donde el mejor resultado es de 96.10%, al igual que el kernel lineal y RBF este resultado se obtuvo con los patrones de flujo burbujas dispersas (clase 1) y estratificado más anular (clase 2), dicha clasificación se obtuvo con un parámetro $C=1$, $\gamma=0.0125$ y $r=1000$.

Configuración	C	γ	r	Instancias clasificadas correctamente
1-2	1	0.0125	1000	96.10%(1996/2077)
1-3	1000	0.01	100	92.72%(2637/2844)
2-3	1	0.1	10	82.54%(3389/4106)

Tabla 4.32. Resultados obtenidos para las configuraciones binarias con el kernel polinomial.

Luego de realizar las diferentes pruebas de clasificación binaria se decide realizar un estudio más radical tomando en cuenta sólo tuberías horizontales, en la tabla 4.33 se muestran los patrones de flujo con los que se realizan las nuevas clasificaciones.

Clase	Patrón de Flujo	Cantidad de datos
1	Burbujas dispersas	52
2	Estratificado	158
3	Anular	119
4	Intermitente	434

Tabla 4.33. Identificación de las nuevas clases con su respectiva cantidad de datos.

La tabla 4.34 muestra los resultados obtenidos para el kernel lineal con los 4 patrones mencionados anteriormente, obteniendo un porcentaje de 72,35% de instancias clasificadas correctamente con un parámetro $C=100$.

Configuración	C	Instancias clasificadas correctamente
1	0.01	63.04% (481/763)
2	0.1	71.56%(546/763)
3	1	72.35%(552/763)
4	10	70.51%(538/763)
5	100	72.35%(552/763)
6	1000	71.04%(542/763)

Tabla 4.34. Resultados obtenidos para el kernel lineal con cuatro patrones de flujo, variables dimensionales.

La tabla 4.35 muestra los resultados obtenidos de las 8 configuraciones propuestas para el kernel RBF donde se obtuvo un porcentaje de 56.88% de instancias clasificadas correctamente, este resultado se observa con la configuración número 1 con un parámetro $C=0.01$ y $\gamma=0.2$.

Para el kernel polinomial de grado 2 se tienen 7 configuraciones donde se obtuvo un porcentaje de 77.98% de instancias clasificadas correctamente con los parámetros $C=10$, $\gamma=0.1$ y $r=0.1$, en la tabla 4.36 se observan estos resultados.

Se puede observar como el kernel polinomial es el que arroja un mejor porcentaje de clasificación con los cuatro patrones de flujo en tuberías horizontales.

Configuración	C	γ	Instancias clasificadas correctamente
1	0.01	0.2	56.88%(434/763)
2	0.01	0.3	56.88%(434/763)
3	0.1	1	40.10%(306/763)
4	0.1	1.5	43.25%(330/763)
5	0.1	2	44.30%(338/763)
6	10	2	27.26%(208/763)
7	100	2	27.79%(212/763)
8	1000	2	27.39%(209/763)

Tabla 4.35. Resultados obtenidos para el kernel RBF con cuatro patrones de flujo, variables dimensionales.

Configuración	C	γ	r	Instancias clasificadas correctamente
1	0.01	0.01	0.01	72.87%(556/763)
2	0.1	0.01	0.01	68.54%(523/763)
3	1	0.01	0.01	69.20%(528/763)
4	10	0.01	0.01	76.54%(584/763)
5	10	0.1	0.1	77.98%(595/763)
6	100	0.01	0.01	72.35%(552/763)
7	1000	0.01	0.01	71.56%(546/763)

Tabla 4.36. Resultados obtenidos para el kernel polinomial con cuatro patrones de flujo, dimensionales.

4.4.2 Resultados Fase II: Variables adimensionales

Como se mencionó anteriormente se realiza la reducción de variables para proceder a realizar el proceso de clasificación con variables adimensionales, se toman en cuenta los cinco patrones de flujo: burbujas dispersas, estratificado, anular, intermitente y burbujas.

Configuración	C	γ	Instancias clasificadas correctamente
1	0.1	0.01	51.88% (2342/4514)
2	0.1	0.0125	51.91% (2343/4514)
3	0.1	0.0150	51.93% (2344/4514)
4	0.1	0.0175	51.93% (2344/4514)
5	1	0.01	53.41% (2411/4514)
6	1	0.0125	53.32% (2407/4514)
7	1	0.0150	53.30% (2406/4514)
8	1	0.0175	53.19% (2401/4514)
9	10	0.01	53.92% (2434/4514)
10	10	0.0125	53.88% (2432/4514)
11	10	0.0150	53.90% (2433/4514)
12	10	0.0175	53.79% (2428/4514)
13	100	0.01	54.32% (2452/4514)
14	100	0.0125	54.23% (2448/4514)
15	100	0.0150	54.12% (2443/4514)
16	100	0.0175	53.99% (2437/4514)
17	1000	0.01	54.30% (2451/4514)
18	1000	0.0125	54.21% (2447/4514)
19	1000	0.0150	54.03% (2439/4514)

Tabla 4.37. Resultados obtenidos para el kernel lineal con variables adimensionales.

Se realizan las pruebas con el kernel RBF y los resultados no superan el 60% de instancias clasificadas correctamente, en la tabla 4.37 se muestran las 19 configuraciones propuestas donde el mejor resultado es 54.32%, el cual se obtuvo en la configuración número 13 con los parámetros $C=100$ y $\gamma=0.01$.

Nuevamente con el propósito de obtener mejores resultados de clasificación se decide realizar una reducción más radical donde solamente se toman en cuenta los patrones de flujo para tuberías horizontales con tres variables adimensionales, en la tabla 4.38 se muestran los patrones de flujo con los que se realizan las nuevas clasificaciones.

Clase	Patrón de Flujo	Cantidad de datos
1	Burbujas dispersas	52
2	Estratificado	158
3	Anular	149
4	Intermitente	434

Tabla 4.38. Identificación de las nuevas clases con su respectiva cantidad de datos.

Configuración	C	Instancias clasificadas correctamente
1	0.01	55.70%(425/763)
2	0.1	57.14%(436/763)
3	1	59.63%(455/763)
4	10	60.03%(458/763)
5	100	66.32%(506/763)
6	1000	69.98%(534/763)

Tabla 4.39. Resultados obtenidos para el kernel lineal con cuatro patrones de flujo, variables adimensionales.

La tabla 4.39 muestra los resultados obtenidos para el kernel lineal con los 4 patrones mencionados anteriormente, obteniendo un porcentaje de 69.98% de instancias clasificadas correctamente con un parámetro $C=1000$.

Configuración	C	γ	Instancias clasificadas correctamente
1	0.1	0.1	63.04%(481/763)
2	0.1	0.2	65.66%(501/763)
3	0.1	0.33	73.92%(564/763)
4	0.1	0.4	74.44%(568/763)
5	1	0.1	74.71%(570/763)
6	1	0.2	74.18%(566/763)
7	1	0.33	73.26%(559/763)
8	1	0.4	73.00%(557/763)
9	10	0.1	74.05%(565/763)
10	10	0.2	74.84%(571/763)
11	10	0.33	74.71%(570/763)
12	10	0.4	74.71%(570/763)
13	100	0.1	75.88%(579/763)
14	100	0.2	74.71%(570/763)
15	100	0.33	74.18%(566/763)
16	100	0.4	74.44%(568/763)
17	1000	0.1	75.36%(575/763)
18	1000	0.2	75.23%(574/763)
19	1000	0.33	74.71%(570/763)
20	1000	0.4	74.71%(570/763)

Tabla 4.40. Resultados obtenidos para el kernel RBF con cuatro patrones de flujo, variables adimensionales.

La tabla 4.40 muestra los resultados obtenidos de las 20 configuraciones propuestas para el kernel RBF donde se obtuvo un porcentaje de 75.88% de instancias clasificadas correctamente, este resultado se observa con la configuración número 13 con un parámetro $C=100$ y $\gamma=0.1$.

Configuración	C	γ	r	Instancias clasificadas correctamente
1	0.1	0.1	100	62.25%(475/763)
2	0.1	0.2	1000	66.05%(504/763)
3	0.1	0.33	1000	67.49%(515/763)
4	0.1	0.4	1000	67.36%(514/763)
5	1	0.1	100	65.79%(502/763)
6	1	0.2	1000	71.16%(543/763)
7	1	0.33	10	71.16%(543/763)
8	1	0.4	10	71.43%(545/763)
9	10	0.1	100	71.95%(549/763)
10	10	0.2	1000	72.08%(550/763)
11	10	0.33	10	70.64%(539/763)
12	10	0.4	10	71.43%(545/763)
13	100	0.1	100	73.26%(559/763)
14	100	0.2	1000	68.55%(523/763)
15	100	0.33	10	72.87%(556/763)
16	100	0.4	10	73.66%(562/763)
17	1000	0.1	100	73.00%(557/763)
18	1000	0.2	0.1	73.13%(558/763)
19	1000	0.33	10	74.84%(571/763)
20	1000	0.4	10	76.02%(580/763)

Tabla 4.41. Resultados obtenidos para el kernel polinomial con cuatro patrones de flujo, variables adimensionales.

Para el kernel polinomial de grado 2 se obtuvo un porcentaje de 76.02% de instancias clasificadas correctamente con los parámetros $C=1000$, $\gamma=0.4$ y $r=10$, en la tabla 4.41 se observan estos resultados.

Se puede observar como el kernel polinomial es el que arroja un mejor porcentaje de clasificación con los cuatro patrones de flujo y tres variables adimensionales, de igual forma para verificar cuales patrones de flujo causan conflicto al momento de la clasificación se realizan 6 pruebas binarias y 4 pruebas con tres clases, estas pruebas se realizan con el propósito de obtener una mejor clasificación, en las tablas siguientes se muestran los mejores resultados obtenidos para cada configuración.

En la tabla 4.42 se observan los resultados obtenidos para el kernel lineal con configuraciones binarias donde el mejor resultado es de 100% de instancias clasificadas correctamente con los patrones de flujo burbujas dispersas (clase 1) y estratificado (clase 2), dicha clasificación se obtuvo con un parámetro $C=1$, mientras que entre los patrones de flujo estratificado (clase 2) y anular (clase 3) sólo se alcanzo un 81.23% de instancias clasificadas correctamente.

Configuración	C	Instancias clasificadas correctamente
1-2	100	100%(210/210)
1-3	0.01	99.42%(170/171)
1-4	1	87.65%(426/486)
2-3	1000	81.23%(225/277)
2-4	1000	90.88%(538/592)
3-4	1000	87.16%(482/553)

Tabla 4.42. Resultados obtenidos para las configuraciones binarias con el kernel lineal.

Para el kernel polinomial de grado 2 el menor porcentaje de instancias clasificadas correctamente es de 87.65% este resultado se logró con los parámetros C, gamma y r de valores 0.1, 0.1 y 100, respectivamente, entre los patrones de flujo burbujas dispersas e intermitente.

Por otra parte se logró clasificar correctamente el 100% de las instancias desconocidas entre los patrones de flujo burbujas dispersas (clase 1) y estratificado (clase 2) con los valores de los parámetros C, gamma y r de 0.1, 0.33 y 1000, respectivamente. Tales resultados se pueden observar en la tabla 4.43.

Configuración	C	γ	r	Instancias clasificadas correctamente
1-2	0.1	0.33	1000	100%(210/210)
1-3	1000	0.2	0.1	98.25%(168/171)
1-4	0.1	0.1	100	87.65%(426/486)
2-3	1000	0.33	10	90.97%(252/277)
2-4	1000	0.4	10	92.91%(550/592)
3-4	1000	0.4	10	89.15%(493/553)

Tabla 4.43. Resultados de las combinaciones binarias propuestas para el kernel polinomial.

Configuración	C	γ	Instancias clasificadas correctamente
1-2	0.1	0.1	98.57%(207/210)
1-3	10	0.2	97.07%(166/171)
1-4	0.1	0.33	89.30%(434/486)
2-3	100	0.1	87.00%(241/277)
2-4	1000	0.4	92.23%(546/592)
3-4	1000	0.2	90.24%(499/553)

Tabla 4.44. Resultados de las combinaciones binarias propuestas para el kernel RBF.

Finalmente para las combinaciones binarias se utilizó el kernel RBF nuevamente el mejor resultado se obtuvo entre los patrones de flujo burbujas dispersas (clase 1) y estratificado (clase 2) con un 98.57% de instancias clasificadas correctamente con los parámetros $C=0.1$ y $\gamma=0.1$, mientras que el menor porcentaje se da entre los patrones de flujo estratificado (clase 2) y anular (clase 3) con un 74.89% con los parámetros $C=1000$ y $\gamma=0.0175$. En la tabla 4.44 se observan estos resultados.

Con estas pruebas se logra verificar que al momento de que la SVM realiza el proceso de clasificación de los 4 patrones de flujo el conflicto más notorio es cuando intenta clasificar los datos del patrón de flujo estratificado y del patrón de flujo anular.

Para verificar el comportamiento de la SVM al agregarle patrones de flujo para realizar el proceso de clasificación se realizan pruebas con tres patrones y cada uno de los kernel seleccionados, en las tablas siguientes se muestran los mejores resultados de las diferentes configuraciones para cada kernel.

Configuración	C	Instancias clasificadas correctamente
1-2-3	1000	83.28%(274/329)
1-2-4	1000	79.50%(512/644)
1-3-4	1000	75.37%(456/605)
2-3-4	1000	78.76%(560/711)

Tabla 4.45. Resultados de las combinaciones de tres clases propuestas para el kernel lineal.

En el caso del kernel lineal el mínimo porcentaje de clasificación es de 75.37%, con un parámetro $C=1000$, entre los patrones de flujo burbujas dispersas (clase 1), anular (clase 3) e intermitente (clase 4), el mejor porcentaje de instancias desconocidas clasificadas correctamente es de un 83.28% tal clasificación se da entre los patrones de

flujo burbujas dispersas (clase 1), estratificado (clase 2) y anular (clase 3) $C=1000$. Estos resultados se pueden observar en la tabla 4.45.

En la tabla 4.46 se observa que para el kernel polinomial de grado 2 el mínimo porcentaje de clasificación es de 81.48%, con los parámetros $C=0.1$, $\gamma=0.4$ y $r=1000$, los patrones de flujo que obtuvieron dicho porcentaje de clasificación fueron burbujas dispersas (clase 1), anular (clase 3) e intermitente (clase 4).

Al realizar la combinación de los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2) y anular (clase 3) se obtuvo el mejor resultado con un porcentaje de 91.49% de instancias clasificadas correctamente con los parámetros $C=1000$, $\gamma=0.33$ y $r=10$.

Configuración	C	γ	R	Instancias clasificadas correctamente
1-2-3	1000	0.33	10	91.49%(301/329)
1-2-4	1000	0.4	10	82.14%(529/644)
1-3-4	0.1	0.4	1000	81.48%(493/605)
2-3-4	1000	0.4	10	84.53%(601/711)

Tabla 4.46. Resultados de las combinaciones de tres clases propuestas para el kernel polinomial.

Para el kernel RBF se observa que el mínimo porcentaje de clasificación se obtuvo con los patrones de flujo burbujas dispersas (clase 1), anular (clase 3) e intermitente (clase 4) con un 81.48% con los parámetros $C=0.1$, $\gamma=0.4$, y el mejor porcentaje de clasificación se dio con los patrones de flujo burbujas dispersas (clase 1), estratificado (clase 2) y anular (clase 3) con un 87.54% de instancias clasificadas correctamente con los parámetros $C=100$, $\gamma=0.1$. En la tabla 4.47 se observan estos resultados.

Configuración	C	γ	Instancias clasificadas correctamente
1-2-3	100	0.1	87.54%(288/329)
1-2-4	100	0.1	81.52%(525/644)
1-3-4	0.1	0.4	81.48%(493/605)
2-3-4	1000	0.2	84.67%(602/711)

Tabla 4.47. Resultados de las combinaciones de tres clases propuestas para el kernel RBF.

Luego de realizar todas estas pruebas tanto para variables adimensionales como para variables dimensionales se puede concluir que los patrones de flujo que presentan mayor conflicto al momento de realizar el proceso de clasificación son el patrón de flujo estratificado y el patrón de flujo anular. Una vez obtenidos los resultados del proceso de clasificación de patrones de flujo se procede a comparar dichos resultados con los obtenidos del modelo físico, el cual fue la base para realizar este estudio. En la figura 4.1 se observa el modelo físico para tuberías horizontales con variables dimensionales




Figura 5.1. Mapa de patrones de Flujo para tuberías horizontales variables dimensionales con datos de agua y aire, diámetro de la tubería de 2.54 c.m, tuberías horizontales.

En la figura 4.2 se comprueba lo mencionado anteriormente ya que los patrones de flujo que causan conflicto al momento de realizar la clasificación con las variables dimensionales son el patrón de flujo estratificado y el patrón de flujo anular ya que en la frontera de ambos patrones existen puntos difíciles de identificar.




Figura 4.2. Patrón de flujo estratificado y anular para tuberías horizontales variables dimensionales.

Luego de realizar el proceso de clasificación con variables dimensionales se realizan las gráficas correspondientes a cada uno de los patrones de flujo, con los datos de validación y los datos identificados por las SVM, para así verificar cuales puntos fueron clasificados correctamente, en las figuras 4.3, 4.4, 4.5 y 4.6 se observan dichas gráficas.




Figura 4.3. Patrón de flujo burbujas dispersas para tuberías horizontales variables dimensionales.




Figura 4.4. Patrón de flujo anular para tuberías horizontales variables dimensionales.




Figura 4.5. Patron de flujo estratificado para tuberías horizontales variables dimensionales.




Figura 4.6. Patron de flujo intermitente para tuberías horizontales variables dimensionales.

Adicionalmente, en la figura 4.7 se observa el mapa de patrones de flujo para variables adimensionales obtenido del modelo físico.




Figura 4.7. Mapa de patrones de flujo variables adimensionales tuberías horizontales.

Análogamente, se realiza la gráfica correspondiente a los resultados obtenidos de la clasificación con las SVM, donde se logra observar que los datos utilizados para dicha clasificación no corresponden con el modelo físico, lo que genera una inconsistencia al momento de realizar el estudio, siendo esta la causa de que no se tenga un mejor porcentaje de clasificación. Ver figura 4.8.




Figura 4.8. Resultado de la clasificación de patrones de flujo variables adimensionales.

Capítulo 5

Conclusiones

El estudio realizado permitió diseñar una herramienta computacional para clasificar patrones de flujo multifásicos, utilizando una Máquina de Vectores de Soporte como técnica de clasificación, para la implementación de dicha herramienta se utilizó el lenguaje de programación C++ para el desarrollo de las funciones y QT4 para la visualización de los resultados, la interfaz diseñada es sencilla y de fácil manejo para el usuario.

El proceso de clasificación de patrones de flujo multifásicos se realizó en 2 fases, en la Fase I se utilizaron variables dimensionales asociadas a cada patrón, en esta fase se tienen 5 patrones de flujo a identificar los cuales son, burbujas dispersas, anular, intermitente, estratificado y burbujas. El mejor resultado alcanzó un 67.72% de instancias desconocidas clasificadas correctamente.

Con el propósito de obtener un mejor porcentaje de clasificación e identificar cuales patrones de flujo causaron conflicto al momento de realizar la identificación se realizaron clasificaciones binarias y multiclase (3 y 4 clases). En el caso de las clasificaciones binarias se alcanzó un 100% de clasificación entre el patrón de flujo anular y el patrón de flujo burbujas, en la combinación de 3 clases se alcanzó un 93.64% de clasificación entre los patrones de flujo burbujas dispersas, estratificado y burbujas, y en las combinaciones de 4

clases se alcanzó un 75.01% de clasificación entre los patrones burbujas dispersas, estratificado, anular y burbujas.

Para verificar si se podía obtener un mejor porcentaje de clasificación se realizó un empaquetamiento de los patrones de flujo intermitente y burbujas, esto se realizó ya que sus propiedades físicas lo permiten, también se realizaron combinaciones binarias y multiclase donde se obtuvieron los siguientes resultados, en combinaciones binarias se alcanzó un 95.26% de clasificación entre los patrones de flujo burbujas dispersas y estratificado, en las combinaciones de 3 clases se obtuvo un 84.15% de clasificación entre los patrones de flujo burbujas dispersas, anular e intermitente más burbujas y en la combinación de 4 clases se obtuvo un 70.25% de clasificación.

Para la obtención de mejores resultados de clasificación se realizó un empaquetamiento de los patrones de flujo intermitente más burbujas y estratificado más anular, se realizaron combinaciones binarias y multiclase obteniéndose en combinaciones binarias un 97.06% de clasificación entre los patrones de flujo burbujas dispersas y estratificado mas anular, y en las combinaciones de 3 clases se obtuvo un 79.88% de clasificación.

En la Fase II se utilizaron variables adimensionales asociadas a cada patrón, en esta fase se utilizaron los mismos patrones que en la Fase I. El mejor resultado de clasificación alcanzó un 54.32% de instancias desconocidas clasificadas correctamente.

Con el propósito de obtener un mejor porcentaje de clasificación se realizó una reducción donde sólo se tomó en cuenta patrones de flujo en tuberías horizontales, los patrones presentes en la Fase II son: burbujas dispersas, estratificado, anular e intermitente, se realizaron clasificaciones binarias y multiclase (3 y 4 clases). En el caso de las clasificaciones binarias se alcanzó un 100% de clasificación entre el patrón de flujo burbujas dispersas y patrón de flujo estratificado, en la combinación de 3 clases se alcanzó

un 91.49% de clasificación entre los patrones de flujo burbujas dispersas, estratificado y anular, y en las combinaciones de 4 clases se alcanzó un 76.02% de instancias clasificadas correctamente.

La Máquina de Vectores de Soporte implantada en esta investigación adicionalmente a la clasificación, logró identificar que el patrón de flujo anular y el patrón de flujo estratificado son los que causan conflicto al momento de realizar la clasificación. Cabe destacar también la eficiencia y eficacia que tienen las SVM como método de clasificación multiclase, ya que a pesar de que los datos utilizados para la realización de este estudio no están bien correlacionados por lo que son recolectados de manera visual a través de una sección transparente de la tubería los resultados obtenidos fueron satisfactorios.

La investigación de este trabajo de grado fue aceptada en un artículo para el X Congreso Internacional de Métodos Numéricos en Ingeniería y Ciencias Aplicadas (CIMENICS).

www.bdigital.ula.ve

Bibliografía

Arirachakaran, S. (1991). *Intelligent utilization of a unified flow pattern prediction model in production system optimization.*, Society of Petroleum Engineers 22869.

Barnea, D. (1986). *A unified model for predicting flow – pattern transitions for whole range of pipe inclinations.* Faculty of Engineering, Department of Fluid Mechanics and Heat Transfer, Tel-Aviv University, Ramat-Aviv 69978, Israel.

Chang, C.C & Lin, C. J (2001). *Libsvm: a library for Support Vector Machines.* Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.

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

El-Sayed, O. (2004). *Artificial neural networks models for identifying flow regimes and predicting liquid holdup in horizontal multiphase flow.* Society of Petroleum Engineers 86910.

Mi, Y. Tsoukalas, L.H. (1998). *Vertical two-phase flow identification using advanced instrumentation and neural networks.* Nuclear Engineering and Design 184.

Mi, Y. Tsoukalas, L.H. (2000). *Flow regime identification methodology with neural networks and two-phase flow models*. Nuclear Engineering and Design 204.

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

Pereyra, E. & Mata, C. (2001). *Algoritmo para predecir las transiciones entre patrones de flujo gas - líquido en tubería horizontal.*, Informe Técnico. INT-8783. Intevep. PDVSA.

Shoham, O (2006). *Mechanistic modeling of gas – liquid two – phases flow in pipes*. Society of Petroleum Engineers. United States of America.

Taitel, Y. & Duker, T. (1976). *A modelo for predicting flow regime transitions in horizontal and near horizontal gas-liquid flow*. University of Houston.

Apéndice

Manual del Usuario

En este capítulo se desarrolla un manual para el manejo de la herramienta computacional donde fueron implantados los métodos para la clasificación de patrones de flujo, dando una descripción detallada de la interface que le da vida a esta herramienta, la cual ayudará al analista para poder realizar la clasificación, logrando identificar la clase a la que pertenece cada patrón. Por esto, es de vital importancia la elaboración de un breve tutorial que oriente y ayude al usuario en el manejo correcto y eficiente del programa, para que así obtenga los mejores resultados y beneficios.

A.1 Requerimientos Básicos

Una computadora que trabaje en entorno Linux y que posea:

1. Lenguaje C++
2. SVM
3. QT4

A.2 Pasos para el manejo de la interfaz

Una vez copiada la carpeta en el computador, al abrirla se encontrará un icono como el que se muestra en la Figura A.1. Al hacer doble clic sobre él, aparecerá una ventana que mostrará una breve introducción del programa y una descripción de los pasos que se deben seguir para obtener un buen manejo del mismo.

La herramienta está compuesta básicamente por tres ventanas, la primera de ellas muestra una breve introducción de la herramienta, en la segunda, se lleva a cabo la clasificación de patrones de flujo con variables dimensionales, mientras que en la tercera se realiza la clasificación de patrones de flujo con variables adimensionales.



Figura A.1. Ícono de inicio de la herramienta para la clasificación de patrones de flujo

En la parte inferior derecha de cada una de estas ventanas se tienen tres botones: “Anterior, Siguiente y Cancelar”, los cuales permiten desplazarse por cada una de las ventanas y terminar el proceso de clasificación cuando se desee. En la figura A.2 se muestra la interfaz de bienvenida, para llevar a cabo el proceso de de clasificación se debe hacer clic en el botón siguiente donde se despliega el listado de variables dimensionales que el usuario debe ingresar para luego presionar el botón clasificación con SVM para que la herramienta indique a que patrón de flujo corresponde el conjunto de

características físicas ingresadas (ver figura A.3 y figura A.4). Para realizar el proceso de clasificación de patrones de flujo con variables dimensionales se realiza el mismo procedimiento. Ver figura A.5 y figura A.6.




Figura A2. Interfaz de bienvenida a la herramienta patrones de flujo.




Figura A3. Interfaz para realizar la clasificación de patrones de flujo con variables dimensionales




Figura A4. Resultado de la clasificación con SVM variables dimensionales.




Figura A.5. Interfaz para la clasificación de patrones de flujo con variables adimensionales.




Figura A.6. Resultado de la clasificación con SVM variables adimensionales.