ESCUELA TÉCNICA SUPERIOR DE INGENIEROS INDUSTRIALES Y DE TELECOMUNICACIÓN

UNIVERSIDAD DE CANTABRIA

Trabajo Fin de Grado

SELECCIÓN DE LA ESTRATEGIA ÓPTIMA DE TRANSMISIÓN EN CANALES DE INTERFERENCIA MEDIANTE TÉCNICAS DE CLASIFICACIÓN

(Selection of the optimal transmission strategy in interference channels using classification techniques)

Para acceder al Título de

Graduado en Ingeniería de Tecnologías de Telecomunicación

Autor: Manuel Merino Izquierdo

Septiembre - 2014

GRADUADO EN INGENIERÍA DE TECNOLOGÍAS DE TELECOMUNICACIÓN

CALIFICACIÓN DEL TRABAJO FIN DE GRADO

Realizado por: **Manuel Merino Izquierdo**
Director del TFG: **Luis Ignacio Santamaría Caballero**
Óscar González Fernández
Título: "Selección de la estrategia óptima de transmisión en canales de interferencia mediante técnicas de clasificación"
Title: "Selection of the optimal transmission strategy in interference channels using classification techniques"

Presentado a examen el día:

para acceder al Título de

GRADUADO EN INGENIERÍA DE TECNOLOGÍAS DE TELECOMUNICACIÓN

Composición del Tribunal:
Presidente (Apellidos, Nombre): Luis Ignacio Santamaría Caballero
Secretario (Apellidos, Nombre): Jesús Ibáñez Díaz
Vocal (Apellidos, Nombre): Pedro Corcuera Miró Quesada

Este Tribunal ha resuelto otorgar la calificación de: .....

Fdo.: El Presidente

Fdo.: El Secretario

Fdo.: El Vocal

Fdo.: El Director del TFG
(sólo si es distinto del Secretario)

Vº Bº del Subdirector

Trabajo Fin de Grado Nº
(a asignar por Secretaría)

Agradecimientos

A los directores de este Trabajo Fin de Grado, Ignacio y Óscar, por ofrecerme la posibilidad de trabajar en este proyecto y por la atención, tiempo y ayuda que me han prestado a lo largo del mismo.

A todos los miembros del G.T.A.S., que han hecho que me sienta uno más desde el inicio y me han ayudado siempre que lo he necesitado.

A aquellos profesores que durante esta primera etapa universitaria me han contagiado su entusiasmo por las Telecomunicaciones y han hecho que hoy pueda estar escribiendo estas líneas.

Por supuesto, a toda mi familia, en particular a mis padres y mi hermana, por todo el ánimo, cariño y comprensión que siempre me han dado, sin ellos nada sería posible. Tampoco quiero olvidarme de todos mis abuelos, con los que me hubiese gustado compartir este momento y que espero que se sientan orgullosos de su nieto.

Y por último, pero no menos importante, a Ainara, por haber estado siempre a mi lado en lo bueno y en lo malo, porque sin ella todo hubiese sido mucho más difícil.

Gracias.

Índice

Introducción, motivación y objetivos 7

Notación 11

1 – Canal de interferencia y estrategias de transmisión 12

1.1 – El canal de interferencia MIMO 12

1.2 – Estrategias de transmisión 14

1.2.1 – *Spatial multiplexing (SM)* 14

1.2.1.1 - Descomposición en valores singulares (SVD) 16

1.2.1.2 - Caso particular: *dominant eigenmode transmission (DET)* 18

1.2.2 – *Successive decoding* 19

1.2.3 – *Interference alignment (IA)* 21

2 – Máquina de Vectores Soporte – Clasificación 24

2.1 – La máquina de vectores soporte (SVM) 24

2.2 – Multiclasificación 29

3 – Medidas experimentales 31

3.1 – Escenario planteado 31

3.2 – Características y consideraciones 32

3.3 – Procesos de estimación 33

3.4 – Generación de diferentes escenarios 36

3.5 – Características de los datos de entrada a la SVM 40

3.5.1 – Normalización 40

3.5.2 – Dimensionalidad 41

4 – Procedimiento, análisis y resultados 43

4.1 – Selección de estrategias definitivas 43

4.2 – Entrenamiento y clasificación de la SVM 46

4.3 – Evolución del sistema de clasificación respecto al tamaño del conjunto de entrenamiento 47

4.3.1 – Evolución del error 47

4.3.2 – Evolución del número de vectores soporte necesarios 49

4.3.3 – Análisis del gasto computacional 50

4.4 – Primeros resultados 52

4.5 – Clasificador híbrido propuesto 53

4.5.1 – Análisis del ruido en el vector de características 56

4.6 – Síntesis de resultados 58

5 – Conclusiones y líneas futuras 59

5.1 – Conclusiones 59

5.2 – Líneas futuras 60

Referencias 62

Índice de figuras y tablas 64

SELECTION OF THE OPTIMAL TRANSMISSION STRATEGY IN INTERFERENCE CHANNELS USING CLASSIFICATION TECHNIQUES

Selección de la estrategia óptima de transmisión en canales de interferencia mediante técnicas de clasificación

Palabras clave

Comunicaciones inalámbricas, sistemas MIMO, canal de interferencia, máquina de vectores soporte, machine learning, beamforming.

Introducción, motivación y objetivos

Durante los últimos años, el número de dispositivos inalámbricos en funcionamiento a nivel mundial ha crecido de manera exponencial. Este hecho viene provocado principalmente por su gran accesibilidad y el progresivo aumento de usuarios que quieren establecer comunicaciones de manera simultánea compartiendo el mismo medio. Además, a esto también se le añade que con el avance de la tecnología, los usuarios de estos sistemas quieren tener acceso tanto a mayores velocidades de transmisión/recepción como a continuas mejoras en la calidad del servicio. Es por todo esto que las interferencias juegan un papel fundamental en la gran mayoría de los sistemas de comunicación inalámbricos.

Para poder cubrir las demandas de los usuarios han de tenerse en cuenta dos desafíos que han marcado y siguen marcando el desarrollo de los sistemas de comunicación inalámbricos [1]:

- la limitación en el uso del espectro radioeléctrico, debido a la multitud de sistemas que deben compartirlo,
- la complejidad del entorno en el que va a trabajar el sistema.

Actualmente, la solución más implementada bajo estas circunstancias es la utilización de sistemas *multiple-input multiple-output (MIMO)*. Estos sistemas se diferencian de los *single-input single-output (SISO)* en que cuentan con varias antenas tanto en el transmisor (TX) como en el receptor (RX).

Uno de los grandes beneficios a destacar por el hecho de utilizar más de una antena en transmisión y recepción, es que se abre la posibilidad de utilizar el *espacio* como una dimensión sobre la que se puede multiplexar información, de manera similar a lo que se hace en el *tiempo* o en la *frecuencia*. Además, los sistemas MIMO se aprovechan del desvanecimiento multicamino que presentan las señales cuando viajan desde el TX al RX, obteniendo así las denominadas ganancias de multiplexado y diversidad, que proporcionan, respectivamente, la posibilidad de transmitir más flujos de datos en el mismo ancho de banda y mayor robustez en la comunicación.

No obstante, cabe destacar que en lo que se refiere a este proyecto, la cualidad de los sistemas MIMO que más interés despierta es la protección que ofrece frente a la interferencia, ya que ésta en particular, y las características del enlace en general,

siguen siendo los factores clave a tener en cuenta a la hora de elegir cómo realizar una comunicación inalámbrica.

Time division multiple access (TDMA) y *frequency division multiple access (FDMA)* son dos de las técnicas más extendidas en el mundo de los sistemas inalámbricos para la multiplexación de comunicaciones y gestión de interferencias. Así, ambas se basan, fundamentalmente, en la división de los recursos disponibles, temporales o frecuenciales, entre los distintos usuarios del sistema.

Sin embargo, el estudio llevado a cabo en este proyecto se centra en el canal de interferencia MIMO, en el que habitualmente se emplean técnicas que, al contrario que las anteriores, permiten que los usuarios puedan compartir simultáneamente el total de los recursos de los que se dispone, tanto temporal como frecuencialmente, sin que esto perjudique a sus comunicaciones. Esto es así gracias a la multiplexación *espacial* de los usuarios y a la existencia de múltiples estrategias de transmisión que actúan sobre las interferencias, reduciendo sus efectos perjudiciales y permitiendo al usuario obtener el máximo rendimiento de su comunicación. De entre todas las posibles estrategias, este proyecto se ha centrado esencialmente en tres, que nos permiten obtener una visión general de los principales casos interferentes ante los que nos podemos encontrar y de las acciones que se llevan a cabo para cada uno de ellos. Así, en función del nivel de la señal interferente respecto al de la deseada, las interferencias serán: tratadas como ruido, decodificadas o alineadas.

A continuación, en la Figura 0.1, se puede ver una representación general del canal de interferencia MIMO.

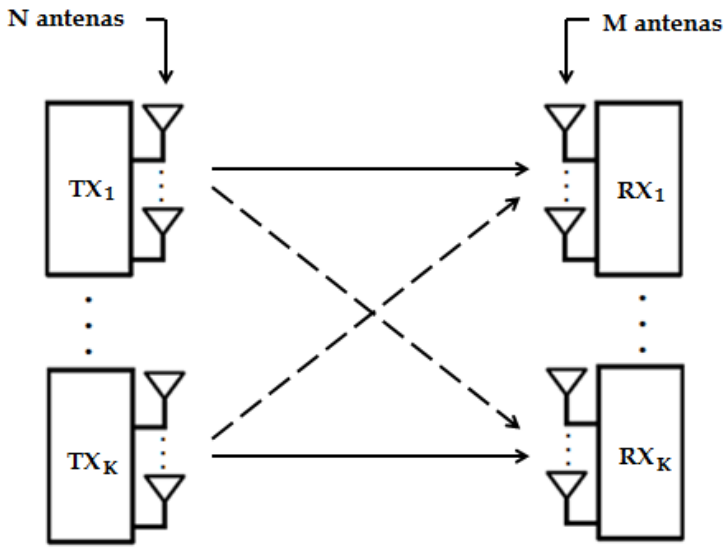

Figura 0.1. Modelo general del canal de interferencia MIMO, en el que hay K usuarios transmitiendo, equipados con N antenas cada uno, y K usuarios recibiendo, equipados a su vez con M antenas. Con líneas discontinuas se muestran los canales interferentes, mientras que con líneas continuas se hace referencia a los canales directos.

La principal finalidad de este proyecto es construir una herramienta automática, basada en técnicas de clasificación y *machine learning*, que en función de medidas de canal, le indique al usuario o a un conjunto de usuarios la estrategia de transmisión que se debería emplear para tratar de alcanzar el máximo *rate* o *sum rate*[1] en su comunicación. De esta manera, en la Figura 0.2 se puede observar como esta herramienta automática ejercería de ente central, recibiendo las medidas de canal realizadas por los usuarios y respondiendo a éstos con la estrategia que deberían aplicar.

A su vez, en la Figura 0.3 se puede ver de manera general y esquemática, cual es el proceso seguido desde la obtención de las medidas de canal hasta la elección de la estrategia a utilizar.

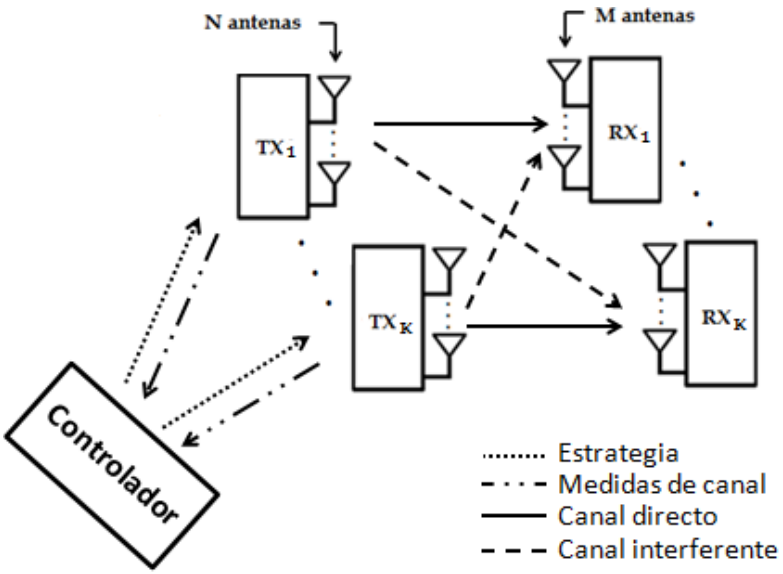

Figura 0.2. Modelo simplificado de la función que el ente central tiene como controlador de las estrategias que los usuarios deben aplicar en función de las medidas de canal que recibe.

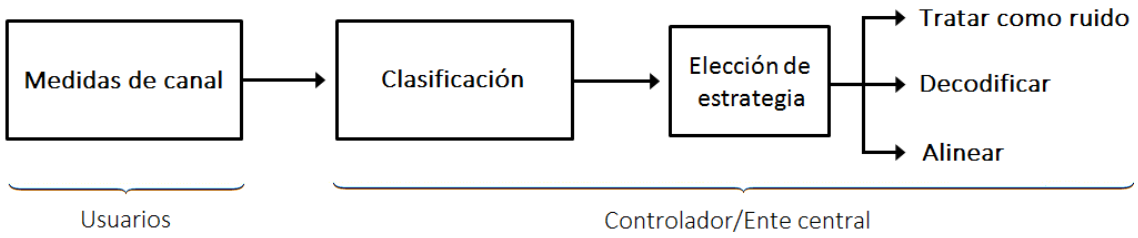

Figura 0.3. Modelo a nivel de bloques del proceso seguido desde la obtención de las medidas de canal hasta la elección de la estrategia a utilizar. También se muestra quién es el encargado de realizar cada una de las tareas a lo largo del proceso.

[1]Por *rate* y *sum rate* se entiende el número de bits por segundo y hertzio (bit/s/Hz) que puede transmitir/recibir cada usuario y un conjunto de usuarios, respectivamente.

La memoria de este proyecto se estructura en cinco capítulos:

El primer capítulo es una introducción al canal de interferencia MIMO, en el que se explican sus características generales y se describen las principales estrategias de transmisión que se utilizan en este escenario.

El segundo capítulo se centra en la máquina de vectores soporte (SVM), de la que se presentan sus fundamentos y principales características. Por otro lado, dado que con la SVM se quiere construir un clasificador, en este capítulo también se describen las principales técnicas de clasificación múltiple que existen.

En el tercer capítulo se detallan, principalmente, el escenario concreto en el que se han llevado a cabo las medidas experimentales y los procesos seguidos para la obtención de la información que más tarde se utilizará en la construcción de la herramienta automática de clasificación que persigue este proyecto.

El cuarto capítulo está dedicado a la exposición de los análisis y procedimientos particulares llevados a cabo a lo largo del proyecto, así como a la presentación de los resultados que se pueden obtener a partir de los mismos.

En el quinto y último capítulo se destacan las principales conclusiones alcanzadas y se dejan entrever futuras líneas de investigación que pueden surgir a partir de los resultados mostrados en este proyecto.

❖ Notación

Las letras en negrita indicarán vectores (en minúscula) o matrices (en mayúscula).

$\mathbf{A}^T$	Matriz traspuesta de **A**.
$\mathbf{A}^H$	Matriz hermítica de **A**, es decir, su traspuesta y conjugada.
tr(**A**)	Traza de la matriz cuadrada **A**.
|a|	Valor absoluto de a.
$\|\|\boldsymbol{x}\|\|$	Norma-2 de $\boldsymbol{x}$.
$\|\|\boldsymbol{A}\|\|_F$	Norma Frobenius de $\boldsymbol{A}$.
$\mathbf{I}_M$	Matriz identidad de tamaño MxM.
$\mathbb{E}$	Esperanza matemática.
$\mathbb{R}$	Conjunto de los números reales.
std(·)	Desviación típica.
min(x,y)	Valor mínimo entre dos números (ej.: x e y).
$\mathbf{H}_{lk}$	Matriz compleja de tamaño MxN que modela cada uno de los enlaces que hay entre las M antenas del nodo RX_l y las N antenas del nodo TX_k. Cuando l=k, se hablará de enlaces directos, mientras que cuando l≠k se estará hablando de enlaces interferentes (l,k = 1,…,K, siendo K el número total de parejas transmisor-receptor del sistema).
$h_{m,\mathrm{n}}^{lk}$	Valor complejo que hace referencia a cada uno de los elementos que forman $\mathbf{H}_{lk}$ y que representa el canal banda estrecha no selectivo en frecuencia que hay entre la antena n-ésima (n = 1,…, N) del nodo TX_k y la m-ésima (m = 1,…, M) del RX_l. Estos valores se consideran incorrelados, independientes e idénticamente distribuidos (i.i.d.), siguiendo una distribución gaussiana compleja de media cero y varianza unidad.
$\mathbf{s}_k$	Vector complejo de tamaño Nx1 que representa las señales transmitidas por cada una de las N antenas del nodo TX_k.
$\mathbf{Q}_k$	Matriz de covarianza de transmisión del nodo TX_k ($\mathbf{Q}_k = \mathbb{E}(\boldsymbol{s}_k \mathbf{s}_k^H)$).
$\mathbf{x}_l$	Vector complejo de tamaño Mx1 que hace referencia a las señales recibidas en cada una de las M antenas del nodo RX_l.
n	Vector complejo de tamaño Mx1 que representa el ruido blanco, gaussiano complejo y aditivo, con media 0 y varianza σ^2, que se ha estimado para cada una de las M antenas de los nodos receptores.
$\mathbf{\Sigma}_k$	Matriz diagonal real de tamaño MxM que contiene las varianzas de ruido estimadas en cada una de las M antenas receptoras del enlace directo entre los nodos TX_k y RX_l, siendo l=k.
P	Potencia total disponible en cada nodo transmisor.

Capítulo 1

Canal de interferencia y estrategias de transmisión

En este capítulo se describe el canal de interferencia *multiple-input multiple-output (MIMO)*, así como las principales estrategias de transmisión que existen para el mismo.

1.1 El canal de interferencia MIMO

Como se comentó brevemente en la introducción del proyecto, los sistemas MIMO han supuesto una enorme mejora en las comunicaciones gracias a las ventajas que se obtienen por el hecho de utilizar varias antenas en transmisión y recepción (ej.: posibilidad de multiplexar señales en el *espacio*). Como contrapartida, provocado en parte por este tipo de avances, el número de usuarios de sistemas inalámbricos ha ido creciendo exponencialmente durante los últimos años, algo que ha hecho que las interferencias que unos generan sobre otros jueguen un papel fundamental y se consideren como uno de los principales cuellos de botella que limitan el *rate* que los usuarios puede alcanzar [2]. Debido a esto, la búsqueda de técnicas para combatir las interferencias y sacar el máximo partido al escenario en el que los usuarios se encuentran, se ha convertido en uno de los temas de investigación que más atención acaparan hoy en día. Tradicionalmente, las principales técnicas utilizadas para la gestión de interferencias han sido *time division multiple access (TDMA)* y *frequency division multiple access (FDMA)*. Sin embargo, se ha demostrado que éstas hacen un uso ineficiente de los recursos, algo que ha hecho que otras alternativas, como las que se analizan en este proyecto, hayan tomado una mayor relevancia en este ámbito.

Un escenario idóneo para llevar a cabo este tipo de análisis es el canal de interferencia MIMO, ya que con él se modela una red de comunicaciones simultáneas entre parejas de nodos. En este escenario, cada nodo transmisor se comunica a través de múltiples *streams* de datos con su respectivo nodo receptor, que a la vez observa señales interferentes procedentes de otros nodos de la red. Un modelo esquemático de este escenario se presenta en la Figura 1.1, en la que se muestran los canales existentes

cuando K nodos transmisores, equipados con N antenas cada uno, se comunican con K nodos receptores, equipados a su vez con M antenas.

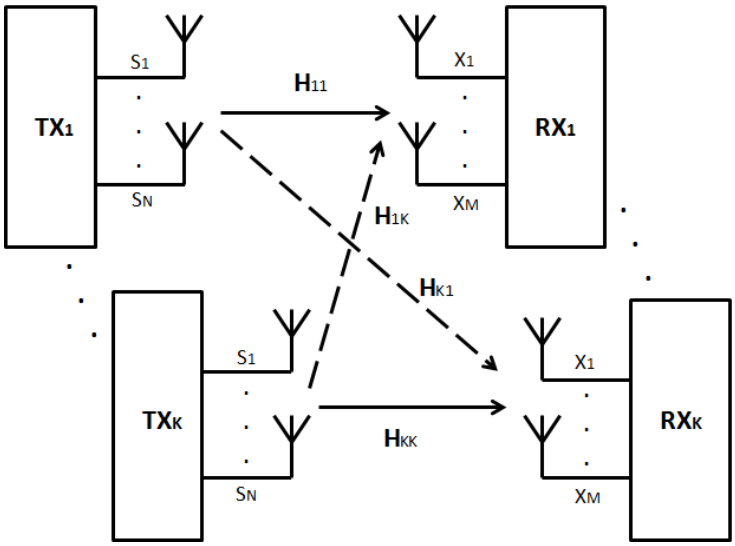

Figura 1.1. Ejemplo general del canal de interferencia MIMO, en el que K usuarios, equipados con N antenas, transmiten simultáneamente, provocando la presencia de canales interferentes (líneas discontinuas) que afectan a los K-1 nodos receptores con los que no pretenden comunicarse. También se muestran los canales directos (líneas continuas) y los nodos receptores provistos de M antenas.

Observando la Figura 1.1, podemos escribir como sería la señal banda base recibida en cada nodo RX, en función de las señales transmitidas por los nodos TX, los canales correspondientes por los que viajan las señales hasta el receptor y el ruido:

$$\boldsymbol{x}_l = \sum_{k=1}^{K} \boldsymbol{H}_{lk}\boldsymbol{s}_k + \boldsymbol{n}, \tag{1.1}$$

donde l,k = 1,…,K, siendo K el número total de parejas transmisor-receptor presentes en el escenario de canal de interferencia MIMO. Por lo tanto, como se puede apreciar en (1.1), la señal recibida en un nodo RX no solo es la señal deseada, ya que ésta llega combinada con las interferencias del resto de usuarios.

Además, a partir del esquema mostrado en la Figura 1.1 se va a introducir la notación que de ahora en adelante se utilizará para hacer referencia al modelo general de canal de interferencia MIMO representado. Así, este modelo se pasará a denotar como $(MxN,d)^K$, donde M son las antenas con las que está equipado cada nodo RX, N hace referencia al número de antenas de cada nodo TX, d representa el número de *streams* (flujos de datos) que transmite cada nodo y K indica el número de usuarios que simultáneamente mantienen una comunicación con sus correspondientes nodos receptores.

1.2 Estrategias de transmisión

En la actualidad, en lo referente al canal de interferencia MIMO, existen diversas estrategias de transmisión que permiten llevar a cabo una multiplexación espacial de los usuarios y con las que se pretende mitigar el efecto que las interferencias tienen sobre éstos. Dada su importancia y haciendo referencia al objetivo principal de este proyecto, en los siguientes subapartados se tratarán varias de las estrategias que más relevancia tienen en este ámbito.

Por otro lado, cabe destacar que el *rate* y el *sum rate* son las figuras de mérito habituales que se utilizan para la evaluación del rendimiento de una red de comunicaciones. Por lo tanto, en este capítulo, a lo largo de la presentación de las estrategias antes mencionadas, se irán mostrando las expresiones matemáticas que hacen referencia al cálculo de estos parámetros.

1.2.1 *Spatial multiplexing (SM)*

La primera estrategia de transmisión que se va a abordar es *spatial multiplexing (SM)*. Esta estrategia se engloba dentro del caso en el que el nivel de interferencia es mucho menor que el de la señal deseada. De esta manera, en los nodos receptores las interferencias del resto de usuarios son tratadas como ruido, mientras que en los nodos transmisores lo que se hace es dividir la información en múltiples *streams* paralelos (en este caso *d streams*) y enviar cada uno por una dimensión espacial diferente [3]. De este modo, SM se beneficia de la ganancia de multiplexado espacial que ofrece el canal MIMO.

Cuando se habla de SM, se pueden distinguir dos situaciones diferentes, dependiendo de si los nodos que quieren comunicarse disponen de información sobre la matriz de canal $\mathbf{H}_{lk}$ o, si por el contrario, solo el nodo receptor tiene esta información. En función de ante qué situación nos encontremos, la potencia disponible en los nodos TX se distribuirá de una forma u otra entre los *streams* de datos a transmitir.

El primer caso que se va a exponer es aquel en el que existe conocimiento del canal por parte de ambos extremos de la comunicación. En esta situación, tal y como se explica en [4], la opción óptima es seguir el procedimiento conocido como *waterfilling*. El principio de esta técnica se basa en comenzar a distribuir la mayor parte de la potencia disponible por aquellos modos de excitación del canal que mayor ganancia proporcionan e ir gradualmente repartiendo el resto por los menos favorables a medida que la *relación-señal-a-ruido* (*SNR*) aumente.

Así, a continuación, se puede ver cuál sería el *rate* que cada usuario alcanzaría en su enlace directo utilizando *waterfilling*:

$$R = \sum_{i=1}^{d} log_2\left(1 + \frac{P_i \lambda_i^2}{\sigma^2}\right), \tag{1.2}$$

donde P_i es la potencia asignada al modo de excitación i-ésimo, λ_i es la ganancia asociada al modo de excitación i-ésimo y σ^2 es la varianza de ruido. Nótese que *d* es menor o igual que el número total de modos disponibles *r* (más detalles en 1.3.1.1).

Por otro lado, el segundo caso que se va describir brevemente es aquel en el que el nodo transmisor no dispone de información sobre el canal. En este caso, la acción que se lleva a cabo en cada nodo TX es la distribución equitativa de la potencia disponible entre las N antenas con las que está equipado. De esta manera, la transmisión es isótropa y, por lo tanto, la matriz de covarianza en el nodo TX_k se puede expresar como:

$$\boldsymbol{Q}_k = \frac{P}{N}\boldsymbol{I}_N. \tag{1.3}$$

En este caso, el *rate* que cada usuario conseguiría alcanzar a través de su canal directo $\mathbf{H}_{lk}$ (siendo k=l), se puede expresar de la siguiente manera:

$$R = log_2 \det\left[\boldsymbol{I}_N + \frac{P}{N\,\sigma^2}\boldsymbol{H}_{lk}\boldsymbol{H}_{lk}^H\right]. \tag{1.4}$$

Así, de manera general, teniendo en cuenta todo lo previamente comentado, con la siguiente ecuación se presenta el *sum rate* que los usuarios conseguirían utilizando la estrategia SM en el canal de interferencia MIMO y asumiendo una transmisión/recepción óptimas:

$$SR = \sum_{l=1}^{K} log_2 \det\left[\boldsymbol{I}_M + \left(\boldsymbol{\Sigma}_l + \sum_{k\neq l}^{K}\boldsymbol{H}_{lk}\boldsymbol{Q}_k\boldsymbol{H}_{lk}^H\right)^{-1}\boldsymbol{H}_{ll}\boldsymbol{Q}_l\boldsymbol{H}_{ll}^H\right], \tag{1.5}$$

donde M hace referencia al número de antenas con el que está equipado cada nodo receptor. En vista de (1.5) hay que recordar que en esta estrategia la interferencia se trata como ruido.

Debido a que la descomposición en valores singulares (del inglés *singular value descomposition*, SVD) es una de las herramientas más utilizadas en estrategias como SM para encontrar las dimensiones espaciales paralelas y ortogonales por las que

enviar la información, en la siguiente subsección se analiza de manera concisa los principales fundamentos de la SVD.

Posteriormente, en el Subapartado 1.3.1.2, se tratará un caso particular de la estrategia SM, en el que se considera un único flujo de datos a transmitir.

1.2.1.1 Descomposición en valores singulares (SVD)

En este subapartado se va a analizar en qué se basa la descomposición en valores singulares (SVD), ya que esto servirá como apoyo a las explicaciones sobre la estrategia SM y al caso particular de la misma que se tratará más adelante, permitiéndonos entender mejor el funcionamiento de ambas.

La SVD es una herramienta algebraica con numerosas aplicaciones [5], aunque en lo que a este proyecto respecta, una de las principales utilidades que tiene en el ámbito del canal de interferencia MIMO es que, gracias a ella, las matrices de canal de los enlaces directos se pueden descomponer, de manera que un canal MIMO directo puede representarse como varios canales *single-input single-output (SISO)*, que funcionan en paralelo sin interferirse.

Por simplicidad y para facilitar el entendimiento de la SVD, a lo largo de este subapartado nos centraremos en una única comunicación entre una pareja de nodos TX y RX, donde **H** se utilizará para hacer referencia a la matriz de canal. De esta manera, como ya se demostró en [6], **H** se puede descomponer de la siguiente forma:

$$\boldsymbol{H} = \boldsymbol{U}\boldsymbol{D}\boldsymbol{V}^{H}, \tag{1.6}$$

donde

- **D** es una matriz rxr diagonal, en la que cada elemento es un valor singular de **H**. Además, *r* es el rango de **H**, que se calcula como r = min(M,N) en el caso de que la matriz de canal sea de rango completo. Por lo tanto, una vez dicho esto, es evidente que la matriz **D** tendrá *r* valores no negativos en su diagonal, que se denotan como $\lambda_i, i = 1, \dots, r$ y que representan las ganancias de los diferentes modos de excitación ortogonales e independientes de **H**.
- **U** y **V** son matrices de tamaño Mxr y Nxr, respectivamente, que cumplen la condición $\mathbf{U}^H\mathbf{U} = \mathbf{V}^H\mathbf{V} = \mathbf{I}_r$. Sus columnas se denominan vectores singulares por la izquierda y derecha de **H**.

Con el objetivo de explotar los modos del canal, apoyándonos en la SVD de **H**, en el nodo transmisor y receptor se lleva a cabo una fase de precodificación y decodificación

de la señal transmitida y recibida, respectivamente. Así, lo primero que se hace en el nodo TX es aplicar un precodificado a los *streams* de datos que el usuario quiere transmitir, tal y como se ve en la siguiente ecuación:

$$\boldsymbol{s} = \boldsymbol{V}\boldsymbol{s}', \tag{1.7}$$

donde **V** es la matriz de precodificación obtenida en la SVD de **H** y **s'** es un vector de tamaño rx1 que hace referencia a los *streams* independientes que se transmiten. A continuación, la información transmitida viaja por el canal y es recibida por las antenas del nodo receptor, donde, teniendo en cuenta (1.6), la señal recibida se puede expresar de un modo similar a lo que se vio en (1.1):

$$\boldsymbol{x} = (\boldsymbol{U}\boldsymbol{D}\boldsymbol{V}^H)\,\boldsymbol{s} + \boldsymbol{n}. \tag{1.8}$$

Por lo tanto, ahora, para poder obtener la información que fue enviada por el transmisor, la señal recibida debe ser decodificada de la siguiente manera:

$$\boldsymbol{U}^H\boldsymbol{x} = \boldsymbol{U}^H(\boldsymbol{U}\boldsymbol{D}\boldsymbol{V}^H)\,\boldsymbol{s} + \boldsymbol{U}^H\boldsymbol{n}, \tag{1.9}$$

donde $\boldsymbol{U}^H$ es la matriz de decodificación obtenida en la SVD de **H**. Así, finalmente, teniendo en cuenta (1.7) y (1.9), podemos llegar a la siguiente expresión:

$$\boldsymbol{x}' = \boldsymbol{D}\,\boldsymbol{s}' + \boldsymbol{n}', \tag{1.10}$$

donde **x'** es un vector columna de tamaño rx1 que contiene los *streams* de datos recibidos.

Una vez que la fase de decodificación ha concluido, cada flujo de datos recibido puede expresarse como:

$$x'_m = \lambda_m\, s'_m + n'_m, \quad m = 1, \dots, r. \tag{1.11}$$

Con las ecuaciones (1.10) y (1.11) se puede observar que gracias a la SVD de la matriz de canal **H**, si se aplica una matriz de precodificación (**V**) a los *streams* de datos que se quieren transmitir en el nodo TX y una matriz de decodificación ($\mathbf{U}^{\mathrm{H}}$) a la señal **x** recibida en el nodo RX, el canal MIMO directo se comportaría como *r* canales desacoplados que no interfieren entre sí, pudiéndose recuperar los *streams* transmitidos sin mayor problema [4].

Para finalizar este subapartado, con las Figuras 1.2 y 1.3 se pretende mostrar un esquema visual de lo que se ha realizado con las ecuaciones anteriores, buscando un mejor entendimiento de las mismas.

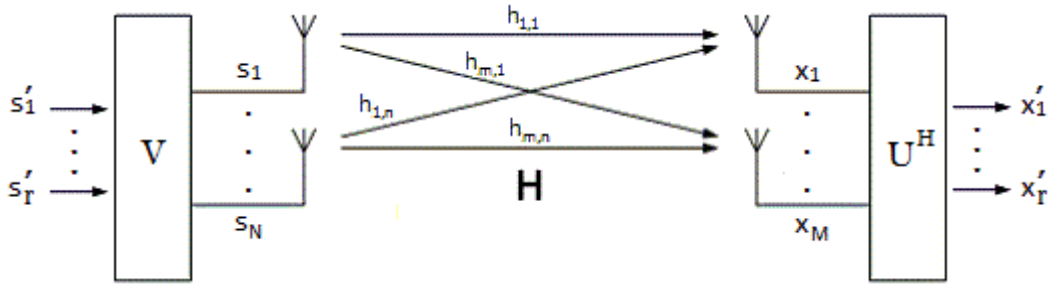

Figura 1.2. Esquema general de la precodificación y decodificación, basadas en la SVD, de la señal transmitida entre una pareja de nodos TX y RX.

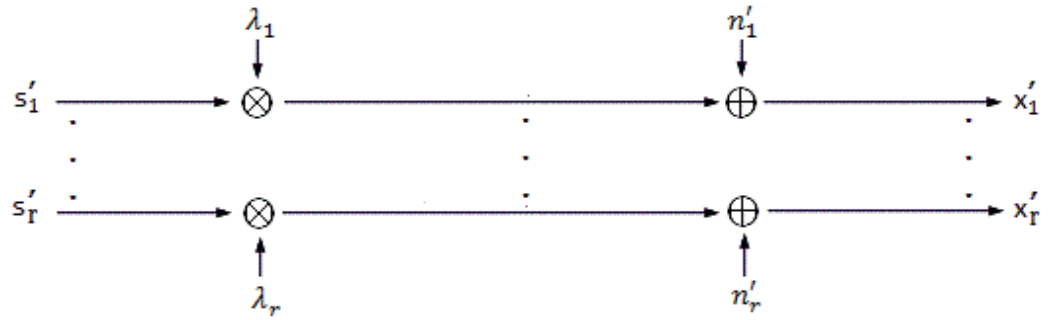

Figura 1.3. División del canal MIMO **H** en varios SISO independientes gracias a la aplicación de la SVD.

1.2.1.2 Caso particular: *dominant eigenmode transmission* (DET)

En este subapartado se va a describir en qué consiste la estrategia de transmisión *dominant eigenmode transmission (DET)*. Como indica el título de esta subsección y como ya se había adelantado previamente, esta estrategia es un caso particular del SM en el que se considera un único *stream* de datos a transmitir (d = 1), es decir, sólo se utilizará un modo de los *r* disponibles, por lo que en este caso las matrices de precodificación y decodificación se reducen a *beamformers* (vectores de pesos para cada una de las antenas).

La SVD de las matrices de canal se utiliza, como se ha visto anteriormente, para hallar los modos de excitación ortogonales e independientes de los canales directos. Estos modos pueden ser utilizados para la transmisión de varios *streams* de datos independientes, como se ha explicado en SM, o para explotar la diversidad espacial del canal transmitiendo por el mayor de los modos [7], como se explicará en esta subsección. Para ello hay que tener en cuenta que una condición que debe cumplirse es que el canal $\mathbf{H}_{lk}$ debe ser conocido tanto en el transmisor como en el receptor.

Así, partiendo de este conocimiento, lo que se plantea en esta estrategia es aplicar *beamformers* tanto en los nodos TX ($\mathbf{w}_{tx}$) como en los RX ($\mathbf{w}_{rx}$), con los que se pretende maximizar la SNR de los enlaces y, por lo tanto, el *sum rate* que se puede conseguir.

Según lo visto en 1.3.1.1, los *beamformers* que deben aplicarse en este caso son aquellos que se correspondan con el mayor modo de excitación [6]. De tal manera que, haciendo referencia a la SVD y suponiendo que los elementos de la matriz diagonal **D** están ordenados tal que $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq \ldots \geq \lambda_r$, lo que se tiene que hacer es:

$$\boldsymbol{w}_{tx} = \boldsymbol{v}_1; \quad \boldsymbol{w}_{rx} = \boldsymbol{u}_1, \tag{1.12}$$

donde $\mathbf{v}_1$ y $\mathbf{u}_1$ se corresponden con la primera fila de **V** y la primera columna de **U**, respectivamente. Por tanto y por comodidad, desde este momento a los *beamformers* $\boldsymbol{w}_{tx}$ y $\boldsymbol{w}_{rx}$ los pasaremos a llamar simplemente **v** y **u**, respectivamente.

De este modo, al transmitir por el máximo modo de excitación (λ_1) y fijándonos en lo obtenido en (1.11), la SNR que se consigue es proporcional a λ_1^2. Así, teniendo en cuenta todo lo comentado previamente, podemos calcular cuál sería el *sum rate* que se obtendría aplicando esta estrategia en el canal de interferencia MIMO que nos concierne:

$$SR = \sum_{l=1}^{K} log_2\left(1 + \frac{||\boldsymbol{u}_l^H \boldsymbol{H}_{ll} \boldsymbol{v}_l||^2}{\boldsymbol{u}_l^H \boldsymbol{\Sigma}_l \boldsymbol{u}_l + \sum_{k\neq l}^{K} ||\boldsymbol{u}_l^H \boldsymbol{H}_{lk} \boldsymbol{v}_k||^2}\right), \tag{1.13}$$

donde $\mathbf{u}_l$ y $\mathbf{v}_k$ son los vectores complejos de tamaño Mx1 y Nx1 que se aplican como *beamformers* en los nodos RX_l y TX_k, respectivamente.

Como conclusión a este subapartado, hay que mencionar que en la estrategia DET los nodos receptores tratan las interferencias del resto de usuarios como ruido, tal y como se hace en SM. Por lo tanto, tendrá sentido aplicarla y que se obtenga beneficio de ella cuando estemos en un escenario en el que las interferencias no sean predominantes y estén en un rango similar al del ruido.

1.2.2 *Successive decoding*

En este apartado se van a definir los fundamentos de la estrategia de transmisión conocida como *successive decoding*. Ésta es una estrategia ampliamente conocida y utilizada, que se aplica en situaciones en las que el nivel de las interferencias es bastante superior al de la señal deseada. Así, en líneas generales, lo que se trata de conseguir aplicando esta estrategia en el canal de interferencia MIMO, es decodificar las interferencias y recuperar la señal deseada libre de ellas.

Para ello, normalmente, el primer paso es implementar un receptor lineal *minimum mean square error (MMSE)* en cada nodo RX, con el que trata de minimizar el error cuadrático medio entre la señal recibida y la señal deseada. Después, al receptor MMSE se le añade un proceso de decodificación sucesiva, como el que se muestra en la Figura 1.4, con el que se consigue decodificar las interferencias y eliminarlas [4].

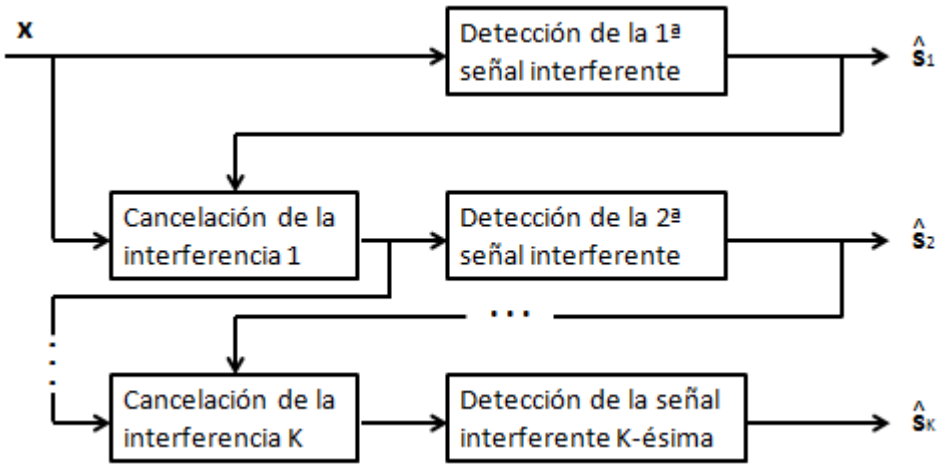

Figura 1.4. Esquema simplificado del proceso de decodificación sucesiva que se lleva a cabo en la estrategia de transmisión *successive decoding* en el canal de interferencia MIMO.

Para explicar el funcionamiento de la estrategia *successive decoding* en el canal de interferencia MIMO, vamos a hacer referencia al esquema mostrado en la Figura 1.4. En él, se puede ver como en cada nodo receptor l lo primero que se hace es detectar la primera señal interferente. Así, asumiendo una detección y conocimiento del canal interferente $\mathbf{H}_{l1}$ perfectos, esta interferencia puede ser cancelada de la señal recibida $\mathbf{x}_l$. De esta forma, haciendo referencia a la ecuación (1.1), podemos escribir la siguiente expresión:

$$\boldsymbol{x}_l - \boldsymbol{H}_{l1}\boldsymbol{s}_1 = \sum_{k=2}^{K} \boldsymbol{H}_{lk}\boldsymbol{s}_k + \boldsymbol{n}. \qquad (1.14)$$

Así, una vez que la primera señal interferente ha sido cancelada, la segunda puede ser detectada sin la contribución de la primera. De este modo, como se observa en la Figura 1.4, procediendo de manera similar, se puede ir decodificando y cancelando sucesivamente el resto de interferencias. Por lo tanto, al final todas las interferencias habrán sido canceladas y la decodificación de la señal deseada se hará únicamente en presencia de ruido.

De igual forma que en apartados anteriores, a continuación se presenta el *sum rate* que los usuarios del canal de interferencia MIMO obtendrían aplicando *successive decoding* como estrategia de transmisión:

$$SR = \sum_{l=1}^{K} log_2\left(1 + \frac{||\boldsymbol{u}_l^H \boldsymbol{H}_{ll} \boldsymbol{v}_l||^2}{\boldsymbol{u}_l^H \boldsymbol{\Sigma}_l \boldsymbol{u}_l}\right), \tag{1.15}$$

donde $\mathbf{u}_l$ y $\mathbf{v}_k$ son los vectores complejos de tamaño Mx1 y Nx1 que se aplican como *beamformers* en los nodos RX_l y TX_k, respectivamente, ya que en esta estrategia también se trata de maximizar la diversidad espacial utilizando la SVD y transmitiendo por el mayor modo de excitación.

Como conclusión a la explicación de *successive decoding*, hay que recordar que en esta estrategia los nodos receptores tratan de decodificar las interferencias, por tanto, el escenario idóneo para que los usuarios se beneficien de su aplicación, es aquel en el que predominan las interferencias con un nivel bastante superior al de la señal deseada.

1.2.3 *Interference alignment (IA)*

La última estrategia de transmisión que vamos a tratar en este capítulo es *interference alignment (IA)*. Esta estrategia es actualmente una de las más estudiadas e investigadas, ya que supone un cambio sustancial en la manera de tratar las interferencias respecto a las técnicas que habitualmente se vienen utilizando y a que con ella se pueden obtener grandes beneficios cuando el nivel de las señales interferentes es comparable con el de la señal deseada. En esta situación, habitualmente, las interferencias se evitan ortogonalizando el acceso al canal con técnicas como TDMA o FDMA, que dividen el espectro entre los usuarios del sistema, asignando a cada uno una porción del mismo. Sin embargo, debido este fraccionamiento, el *rate* que cada usuario puede conseguir se ve limitado, ya que cuantas más particiones se hagan del espectro, menor será la porción del mismo de la que dispone para transmitir.

Es por esto por lo que IA se presenta como una novedosa alternativa, ya que con la aplicación de esta estrategia, sorprendentemente, cada usuario podría transmitir utilizando la mitad de los recursos disponibles. Esto se consigue gracias al confinamiento de las interferencias en la mitad del espacio de señal recibida en cada nodo receptor, con lo que la otra mitad queda disponible y libre de interferencias para

la señal deseada [8]. De esta manera, con IA se obtienen resultados muy positivos, algo que ha despertado un enorme interés por esta estrategia en los últimos tiempos.

Para la posterior descripción de esta estrategia decir que, por simplicidad, nos restringiremos al uso de la dimensión espacial para llevar a cabo el alineado de interferencias, lo que se conoce como *spatial IA*. Además, nos restringiremos a un *stream* por usuario (d = 1).

La clave del funcionamiento de IA en los canales de interferencia MIMO reside en que utilizando el conocimiento que tanto transmisor como receptor tienen de todos los enlaces interferentes, ambos son capaces de aplicar los *beamformers* adecuados, de manera que los receptores sean capaces de *alinear* las interferencias en un espacio de menor dimensión. Así, después, proyectando la señal recibida sobre un espacio ortogonal respecto del espacio en el que se encuentran alineadas las interferencias, se puede obtener la información deseada libre de interferencias.

A continuación, en la Figura 1.5 se muestra de manera esquemática el funcionamiento de la estrategia IA, con un sencillo ejemplo en el que se puede observar cómo se produce la alineación de las señales interferentes en un subespacio distinto al de la señal deseada.

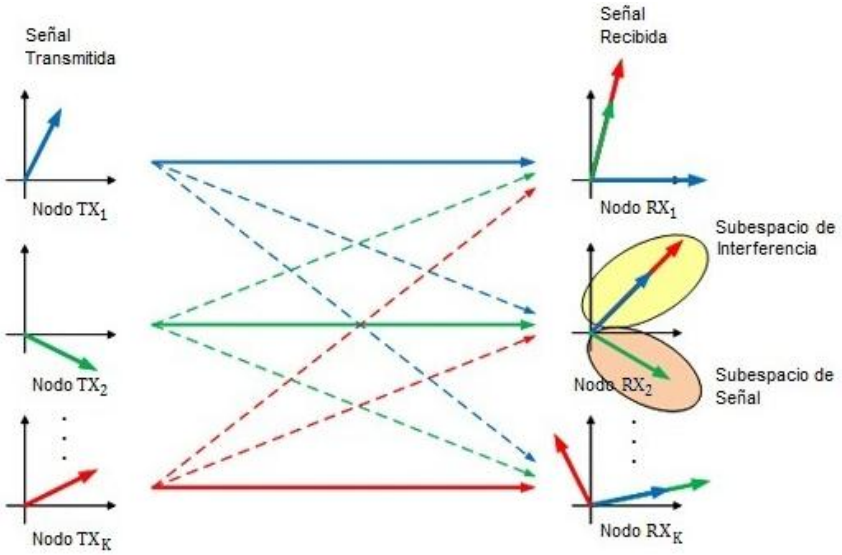

Figura 1.5. Ejemplo de la alineación de interferencias llevada a cabo por la estrategia IA en un escenario general de canal de interferencia MIMO, en el que hay K parejas de nodos transmisor-receptor.

Llevar a cabo *spatial IA* no es sencillo, ya que requiere un conocimiento completo del escenario por parte de los nodos implicados, pero tal y como se trata en [8; 9], para un escenario de canal de interferencia MIMO se pueden obtener de manera analítica los

beamformers que hay que aplicar en cada nodo TX_k ($\mathbf{v}_k$) y RX_l ($\mathbf{u}_l$), bajo las siguientes condiciones:

$$\boldsymbol{u}_l^H \boldsymbol{H}_{lk} \boldsymbol{v}_k = 0, \qquad \forall k \neq l \tag{1.16}$$

$$\boldsymbol{u}_l^H \boldsymbol{H}_{ll} \boldsymbol{v}_l \neq 0. \tag{1.17}$$

Con estas dos condiciones se fuerza a la aplicación de unos *beamformers* $\mathbf{u}_l$ y $\mathbf{v}_k$ adecuados, con el objetivo de que en el nodo receptor las interferencias sean anuladas, gracias a su proyección en un espacio ortogonal al que se encuentran, y únicamente se reciban las señales deseadas.

A continuación se muestra la expresión que representa el *sum rate* que conseguiría el conjunto de usuarios de un canal de interferencia MIMO aplicando IA:

$$SR = \sum_{l=1}^{K} log_2 \left(1 + \frac{||\boldsymbol{u}_l^H \boldsymbol{H}_{ll} \boldsymbol{v}_l||^2}{\boldsymbol{u}_l^H \boldsymbol{\Sigma}_l \boldsymbol{u}_l} \right), \tag{1.18}$$

donde $\mathbf{u}_l$ y $\mathbf{v}_l$ son los vectores complejos de tamaño Mx1 y Nx1 óptimos que se aplican como *beamformers* en los nodos RX_l y TX_l, respectivamente.

Como se puede apreciar, en (1.18) no se hace referencia a los canales interferentes, ya que con IA una vez las interferencias han sido alineadas y proyectadas en un espacio ortogonal al que se encuentran (1.16), éstas no intervienen en el cálculo del *sum rate* que los usuarios pueden alcanzar.

Para concluir este subapartado, hay que recordar que IA es, actualmente, una de las estrategias de transmisión más investigadas en el ámbito del canal de interferencia MIMO, debido a su novedad en la forma de tratar las interferencias y a los beneficios que se pueden obtener cuando se aplica en escenarios en los que las señales interferentes se encuentran en un rango similar al de las señales deseadas.

Capítulo 2

Máquina de Vectores Soporte – Clasificación

En este nuevo capítulo se presentan los fundamentos de la máquina de vectores soporte (del inglés *support vector machine*, SVM) como herramienta de clasificación, así como las principales técnicas de multiclasificación que existen.

2.1 La máquina de vectores soporte (SVM)

Este apartado está dedicado a la introducción de nociones básicas sobre la SVM, que nos permitan entender las bases teóricas de la misma.

En general, se puede decir que la SVM es una herramienta que podemos encuadrar dentro del ámbito de la clasificación y el mundo del *machine learning*, ya que tiene como principal característica la capacidad de aprender a clasificar diversos conjuntos de datos pertenecientes a diferentes *clases*. Es por esto, por lo que actualmente la SVM es una herramienta muy utilizada y que ha alcanzado cierta notoriedad en los últimos años.

Como es habitual en el mundo de la clasificación, en este capítulo se hablará de dos tipos de conjuntos de datos, los de entrenamiento y los de test. Por un lado, la finalidad de los datos de entrenamiento es proporcionar la información necesaria a la SVM para que pueda aprender a clasificar, es decir, para que pueda extraer los parámetros más relevantes de cada clase y en posteriores clasificaciones sea capaz de identificarlas correctamente. Por otro lado, con los datos de test lo que se pretende es cuantificar cómo de bien se ha hecho el entrenamiento y si se está clasificando correctamente. Además, también se hará referencia a la probabilidad de acierto, calculada a partir del conjunto de test, como un indicador global del rendimiento obtenido en la clasificación.

El principio básico que hay detrás de las SVM es la realización de un mapeo no lineal ($x \rightarrow \phi(x)$) del conjunto de entrenamiento que se encuentra en un espacio de dimensión *n* (conocido como el *espacio de entrada*), a un espacio de dimensión N, con

N > n, denominado como el *espacio de características*. Básicamente, lo que la SVM hace en este nuevo espacio es construir una superficie de decisión con las características necesarias que permitan un aprendizaje generalizado para posteriores clasificaciones.

A partir de esto último, como se estudia en [10], puede darse el caso en el que la SVM sea capaz de separar completamente los conjuntos de entrenamiento sin problemas, encontrando así el hiperplano de separación óptimo, o puede que no sea capaz y por lo tanto haya que construir el conocido como *soft margin hyperplane*. Este último tipo de clasificación se diferencia principalmente del óptimo en que permite que haya errores en el entrenamiento, aunque, como se verá más adelante, esto no implica que la probabilidad de acierto en la clasificación se vea muy perjudicada.

Así, para generalizar el estudio y dado que la clasificación *soft margin hyperplane* es la más habitual, debido a los enormes y diversos conjuntos de patrones de entrada que normalmente se pretenden clasificar, a continuación vamos a contemplar la matemática que hay detrás de ella.

A pesar de que la SVM construye el hiperplano en el *espacio de características*, para simplificar la explicación, las siguientes ecuaciones planteadas lo calculan en el *espacio de entrada*, pudiéndose extrapolar más tarde sin problemas al *espacio de características*.

Para realizar la clasificación de cada patrón de entrada, las condiciones que deben cumplirse son:

$$\boldsymbol{w}^T\boldsymbol{x}_i + b \geq +1 - \xi_i, \qquad y_i = +1, \qquad i = 1, \dots, l \tag{2.1}$$

$$\boldsymbol{w}^T\boldsymbol{x}_i + b \leq -1 + \xi_i, \qquad y_i = -1, \qquad i = 1, \dots, l \tag{2.2}$$

$$\xi_i \geq 0, \qquad i = 1, \dots, l \tag{2.3}$$

donde

- $\boldsymbol{x}_i \in \mathbb{R}^n$ es el patrón de entrenamiento i-ésimo perteneciente al *espacio de entrada*.
- $y_i \in \{1,-1\}$ es la etiqueta que identifica a que clase pertenece el patrón $\boldsymbol{x}_i$.
- $\boldsymbol{w}$ es el vector normal al hiperplano de separación en el *espacio de entrada*.
- ξ_i es una variable que si es mayor que la unidad indica que se ha producido un error en la clasificación del patrón $\boldsymbol{x}_i$. Así, $\sum_i \xi_i$ nos da la idea del límite superior de errores que se pueden cometer.
- b es una constante denominada *bias*, donde $\frac{|b|}{||\boldsymbol{w}||}$ indica la distancia que hay desde el hiperplano al origen.
- l hace referencia al número total de patrones utilizados.

Debido a que lo que se pretende es separar las dos clases lo máximo posible para que la clasificación durante el entrenamiento cometa pocos errores, lo que se plantea es maximizar el margen entre ellas (calculado como $2/||\boldsymbol{w}||$), minimizando:

$$\frac{1}{2}||\boldsymbol{w}||^2 + C \cdot \left(\sum_{i=1}^{l} \xi_i\right)^2, \tag{2.4}$$

bajo las condiciones (2.1) - (2.3), donde C es una constante con la que se penalizará más o menos los errores cometidos.

Siguiendo [10; 11] se concluye que el hiperplano solución, ya en el *espacio de características*, se puede escribir como:

$$\boldsymbol{w} = \sum_{i=1}^{l} y_i \, \alpha_i \phi(\boldsymbol{x}_i), \tag{2.5}$$

donde lo nuevo respecto a las anteriores ecuaciones es que ahora $\boldsymbol{w}$ es el vector normal al hiperplano de separación en el *espacio de características*, y que $\alpha_i \geq 0$ son los multiplicadores de Lagrange. Estos multiplicadores sólo son $\alpha_i \neq 0$ para ciertos patrones $\boldsymbol{x}_i$, a los que llamamos *vectores soporte*. Estos vectores soporte son aquellos patrones de entrenamiento que determinan el máximo margen que hay entre las clases, y que si se modificasen, el hiperplano solución sería distinto.

Una vez concluido el entrenamiento y encontrado el hiperplano más adecuado para la clasificación de las clases, pasamos a la fase de test. De esta manera, para decidir a qué clase pertenecen los patrones de entrada desconocidos se plantea el siguiente test:

$$\boldsymbol{w}^T \phi(\boldsymbol{x}) + b \gtrless 0. \tag{2.6}$$

A continuación, teniendo en cuenta lo hallado en (2.5), podemos reescribir (2.6) como:

$$\sum_{i=1}^{l} \alpha_i \, y_i \big(\phi(\boldsymbol{x}_i) \cdot \phi(\boldsymbol{x})\big) + b \gtrless 0. \tag{2.7}$$

Sin embargo, trabajar en el *espacio de características* es algo computacionalmente muy costoso, por lo que como se demuestra en [10] esto se puede solucionar utilizando funciones *kernel* que permitan trabajar en el *espacio de entrada*. Así, reescribiendo (2.7) definitivamente obtenemos:

$$\sum_{i=1}^{l} \alpha_i \, y_i \, K(\boldsymbol{x}, \boldsymbol{x}_i) + b \gtrless 0, \tag{2.8}$$

donde en función del resultado que se obtenga de la inecuación, el patrón **x** del conjunto de test será asignado a una clase u otra.

Respecto a las funciones *kernel* que existen, cabe destacar que entre las que más se han investigado y son más utilizadas, se encuentran las siguientes:

$$K(\boldsymbol{x}, \boldsymbol{x}_i) = (\boldsymbol{x} \cdot \boldsymbol{x}_i + 1)^p, \tag{2.9}$$

$$K(\boldsymbol{x}, \boldsymbol{x}_i) = e^{-\frac{||\boldsymbol{x}_i - \boldsymbol{x}||^2}{2\sigma^2}}, \tag{2.10}$$

donde (2.9) resulta en un clasificador polinómico de grado *p* y (2.10) hace referencia a la función conocida como Gaussian Radial Basis, en la que σ junto con C (introducido en (2.4)) son los parámetros que se necesitan ajustar para obtener la mejor probabilidad de acierto posible en la clasificación.

A continuación, para finalizar el apartado e ilustrar tanto la fase de entrenamiento como la de clasificación, en las Figuras 2.1 y 2.2 se puede ver un ejemplo sencillo de clasificación, en el que se aprecia tanto el hiperplano construido por la SVM, como los *vectores soporte* y la clasificación de los patrones de test antes mencionados.

En este ejemplo, los patrones de entrada son de 2 dimensiones, un caso que comparado con las dimensiones con las que se suele trabajar en entornos de investigación resulta algo simplificado, pero que permite entender de manera simple el funcionamiento de la SVM. En este caso, las clases se encuentran centradas en torno a las coordenadas (-1,0) y (1,0), y están formadas por patrones de entrada aleatorios que siguen una distribución gaussiana bidimensional, cuya desviación típica es de 0.6. Además, en este ejemplo, la función kernel utilizada es la que se muestra en (2.10).

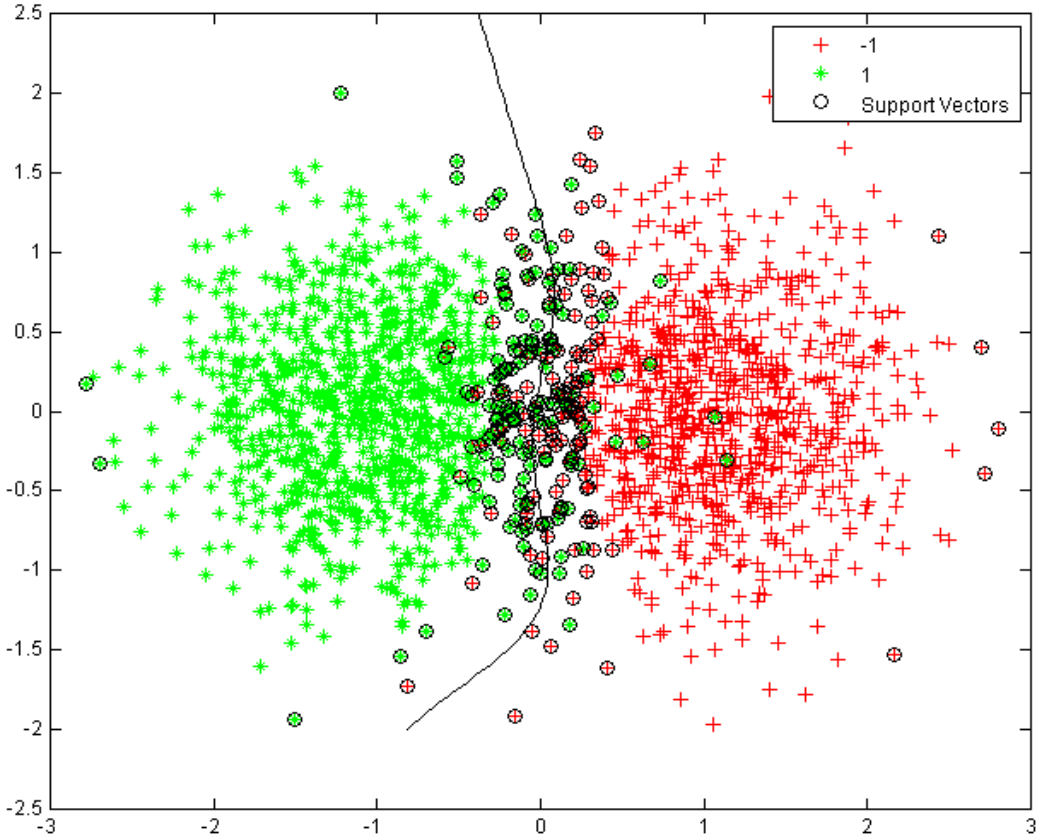

Figura 2.1. Ejemplo representativo de la fase de entrenamiento de la SVM, en el que se muestra la creación del hiperplano de separación y la elección de los vectores soporte.

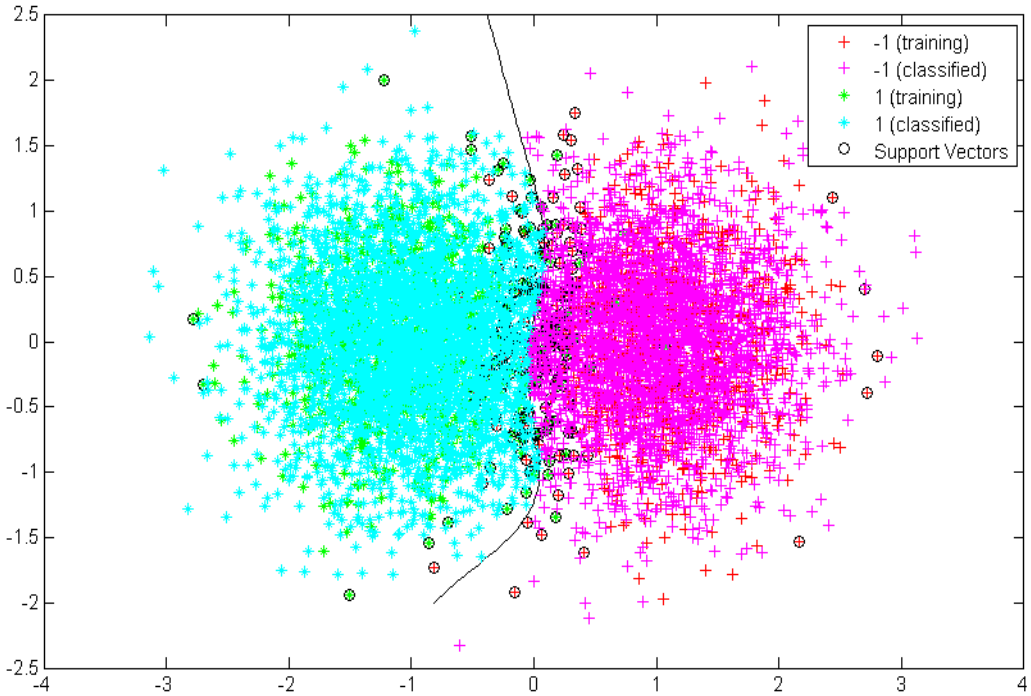

Figura 2.2. Ejemplo de la fase de clasificación de los patrones del conjunto de test de la SVM.

La Figura 2.1 se corresponde con la fase de entrenamiento de la SVM, en la que en este ejemplo se ha construido el hiperplano de separación entre los patrones de entrada de la clase centrada en (-1,0), etiquetados como "+1" (verde), y los pertenecientes a la otra clase, centrados en (1,0) y etiquetados como "-1" (rojo). A su vez, rodeados con círculos negros se encuentran los *vectores soporte*, que más tarde se utilizarán para la fase de clasificación que se observa en la Figura 2.2.

De esta manera, como se puede apreciar en la Figura 2.2, ahora en color cian ("+1") y magenta ("-1") se muestran los patrones de test utilizados y la clasificación que ha realizado la SVM de los mismos, en la que como dato significativo se ha obtenido una probabilidad de acierto del 96 %.

2.2 Multiclasificación

En este apartado se van a describir las principales técnicas utilizadas para la clasificación de conjuntos de entrada en los que hay representación de tres o más clases. En el mundo de la clasificación, estas técnicas son conocidas como de multiclasificación.

En su comienzo, la SVM fue diseñada para realizar únicamente clasificaciones binarias, es decir, clasificaciones en las que solo hay dos clases. Sin embargo, con el avance de la tecnología, han ido apareciendo nuevas técnicas con las que se puede utilizar la SVM para clasificar tres o más clases de una vez. No obstante, se ha demostrado que éstas últimas son computacionalmente más costosas que las binarias [12], por lo que, actualmente, para realizar una multiclasificación se opta por combinar varios clasificadores binarios.

Así, a continuación, se van a introducir brevemente los fundamentos de los principales métodos de clasificación múltiple basados en la resolución de clasificadores binarios [13].

El primer método es el denominado como "*one-against-all*". Esta técnica se basa en la construcción de tantos clasificadores binarios como clases se quieran clasificar, entrenando la SVM para cada uno de ellos. La característica principal de este método es que en cada entrenamiento, la SVM recibe los patrones de la clase "*one*" con etiquetas positivas y el resto con negativas. En la fase de clasificación, para cada uno de los patrones del conjunto de test y para cada clasificador binario se evalúa la parte izquierda de la inecuación (2.8). Así, cuando este proceso ha terminado, se comparan todas las salidas y se asigna a cada patrón de test la etiqueta de la clase ganadora.

El siguiente método que se presenta es el conocido como "*one-against-one*". En este método se construyen k(k-1)/2 clasificadores binarios, donde k indica el número de clases existentes. En cada clasificación binaria, la SVM es entrenada únicamente por dos de las k clases que hay en total, estando identificadas cada una por sus respectivas etiquetas. Cuando todos los hiperplanos han sido construidos y la fase de entrenamiento ha concluido, se da paso a la de clasificación, donde cada patrón **x** del conjunto de test se introduce en (2.8) para cada uno de los clasificadores. Después, observando los resultados, en cada clasificación, a la clase binaria elegida se le asigna un *voto*. De este modo, una vez que **x** ha pasado por los k(k-1)/2 clasificadores binarios, se hace un recuento de los *votos* que tiene cada clase, eligiendo como ganadora definitiva a la clase que más votos tenga.

El último método que se va a tratar es el denominado como *directed acyclic graph SVM (DAGSVM)*. Este algoritmo tiene una fase de entrenamiento idéntica a la del "*one-against-one*" en la que tiene que construir k(k-1)/2 hiperplanos de separación. Sin embargo, la fase de clasificación es diferente, ya que en este caso se utiliza un *grafo* que tiene k(k-1)/2 nodos y k vértices, donde cada nodo es un clasificador binario. De esta manera, el procedimiento comienza evaluando el patrón de test **x** en la inecuación (2.8) del nodo raíz y obteniendo la primera decisión binaria. Así, en función de la clase elegida, se recorre el grafo por un camino u otro y se evalúan los siguientes clasificadores binarios hasta llegar a uno de los k vértices, que indica finalmente cuál es la clase ganadora.

En cuanto a la elección de la mejor técnica de entre todas las que existen, ésta dependerá de la aplicación en particular que se estudie, aunque en este ámbito hay que mencionar que las estrategias presentadas en este apartado tienen en general un comportamiento similar, por lo que los resultados que con ellas se obtienen son semejantes.

Para terminar este apartado, debe mencionarse que la figura de mérito que se tiene en cuenta en cualquier método de clasificación es la *matriz de confusión*. Esta matriz nos ofrece información sobre la probabilidad de acierto en la clasificación de cada clase, así como de los diferentes tipos de error cometidos. De esta manera, las columnas de la matriz indican las clases decididas por el clasificador y las filas las clases que se debieran haber elegido, por lo que los elementos en la diagonal principal se corresponden con las clasificaciones sin fallo, es decir, con las probabilidades de acierto para cada clase, y el resto de elementos son las probabilidades de error cometidas en la clasificación.

Capítulo 3

Medidas experimentales

En este capítulo se va a presentar información detallada del escenario de interferencia *multiple-input multiple-output (MIMO)* sobre el que se han realizado medidas experimentales, incluyendo una descripción del mismo, la metodología de medida, los diferentes escenarios interferentes que se han intentado representar y la influencia de estos últimos sobre los datos de entrada de la máquina de vectores soporte (del inglés *support vector machine*, SVM).

3.1 Escenario planteado

El escenario general que se ha estudiado a largo de este proyecto es el canal de interferencia MIMO $(MxN,d)^K$, formado por *K* usuarios transmitiendo simultáneamente *d streams* de datos, donde cada nodo TX quiere comunicarse con su correspondiente nodo RX, estando ambos equipados con *N* y *M* antenas, respectivamente.

De manera general, en un escenario en el que hay K usuarios transmitiendo y K usuarios recibiendo, existen K canales directos (entre el transmisor y receptor deseado) y K(K-1) canales interferentes. Por lo tanto, debido a que en este proyecto en particular las medidas experimentales se llevaron a cabo en un sistema $(2x2,d)^3$, en este caso existen 3 canales directos y 6 interferentes.

En la Figura 3.1 se puede ver un esquema representativo del escenario expuesto en este proyecto, en el que se puede apreciar los canales directos (líneas continuas) y los interferentes (líneas discontinuas), aunque la verdadera situación espacial de los nodos en el laboratorio en el que se realizaron las medidas, se encuentra detallada en las imágenes de [14].

En la Figura 3.1, cada $\mathbf{H}_{lk}$ es una matriz compleja de tamaño 2x2 que modela cada uno de los canales banda estrecha no selectivos en frecuencia que hay entre las 2 antenas del nodo transmisor k-ésimo y las 2 antenas del nodo receptor l-ésimo.

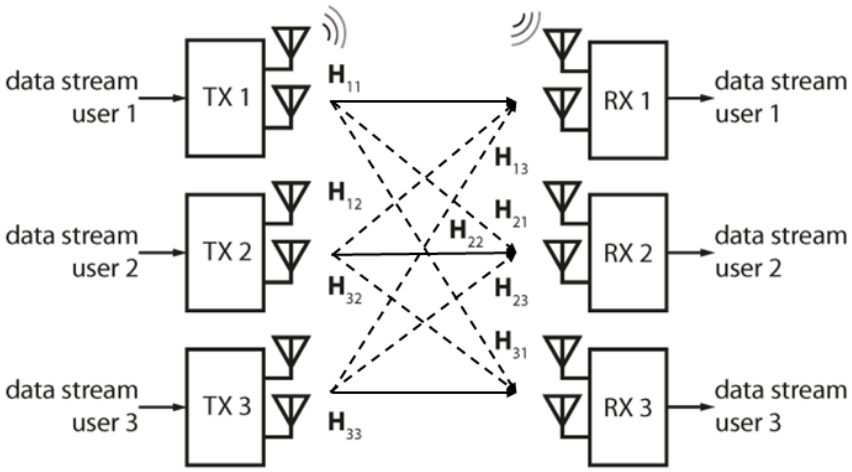

Figura 3.1. Escenario representativo del canal de interferencia MIMO $(2x2,d)^3$ sobre el que se han realizado las medidas experimentales, donde las líneas rayadas hacen referencia a los enlaces interferentes y las continuas a los enlaces directos.

Para finalizar este apartado, cabe destacar que del canal de interferencia MIMO $(2x2,d)^3$ no se ha especificado el valor que indica el número de *streams* de datos que los usuarios transmiten, ya que esto dependerá de la estrategia de transmisión que se aplique, como se verá más adelante.

3.2 Características y consideraciones

Debido a que una parte fundamental del principal objetivo del proyecto se basa en la obtención de medidas de canal, a continuación se presentan las características y consideraciones más específicas del proceso llevado a cabo para ello.

La obtención tanto de estimas de canal como de potencias de ruido se ha realizado utilizando el banco de pruebas descrito en [9], donde se encuentran todos los detalles técnicos sobre los nodos utilizados. Entre estos datos, cabe destacar que en concreto la frecuencia de trabajo es de 5.6 GHz y que cada nodo físico dispone de 8 antenas y 4 transceptores. Sin embargo, dado que no es posible utilizar los 4 a la vez y que en el escenario planteado $(2x2,d)^3$ sólo hay dos antenas por nodo, lo que hacemos es utilizar el *switch* que los controla, de manera que alternamos los transceptores que se utilizan en cada momento. Además, también variamos las antenas por las que se transmite/recibe, con lo que hacemos que el conjunto final de medidas obtenido sea mucho más rico y por lo tanto más cercano a los diferentes escenarios que habitualmente tienen lugar en los sistemas de comunicaciones inalámbricos actuales.

Por último, la estima de los diferentes canales y potencias de ruido se ha hecho en base a una transmisión banda ancha con o*rthogonal frequency division multiplexing (OFDM)*, de acuerdo a las especificaciones de capa física en el estándar 802.11a/g del Instituto de Ingeniería Eléctrica y Electrónica (del inglés *Institute of Electrical and Electronics Engineers*, IEEE) para redes de área local inalámbricas (del inglés *wireless local area networks*, WLAN). Sin embargo, nuestro objetivo no es recrear una transmisión OFDM convencional, por lo que en este caso vamos a interpretar cada una de las 52 subportadoras, normalmente utilizadas en OFDM como subportadoras de información (48) y piloto (4), como 52 canales monoportadora paralelos no selectivos en frecuencia.

3.3 Procesos de estimación

Una vez explicadas algunas de las características más relevantes sobre los equipos físicos y la transmisión realizada, pasamos a detallar el proceso que se sigue desde la generación de la trama a transmitir hasta su procesado en cada nodo RX.

En primer lugar, en la Figura 3.2 se muestra cómo es la trama a nivel físico definida por el estándar IEEE 802.11a/g, a la cual nos referiremos más adelante, ya que para este proyecto se ha variado el contenido de ciertos campos de la misma.

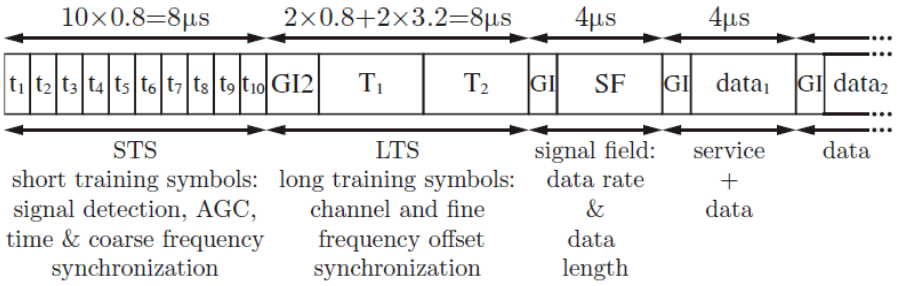

Figura 3.2. Estructura de la trama a nivel físico definida por el estándar IEEE 802.11a/g [9].

Las diferencias introducidas en la trama que se utiliza en este proyecto se encuentran en los campos *data*, donde habitualmente van los símbolos OFDM con información de usuario. En este caso hemos sustituido esta información por una serie de símbolos de entrenamiento idénticos a los *long training symbols (LTS)* y conocidos de antemano, con el objetivo de realizar una estimación de los canales y potencia de ruido mucho más precisa que la que se suele hacer únicamente con los 2 LTS que forman parte de la cabecera. De esta manera, los símbolos transmitidos por cada antena son 32 LTS, algo

que se puede apreciar en la Figura 3.3, en la que se muestra cuál es la información que se envía por cada una de las dos antenas de las que dispone cada nodo TX.

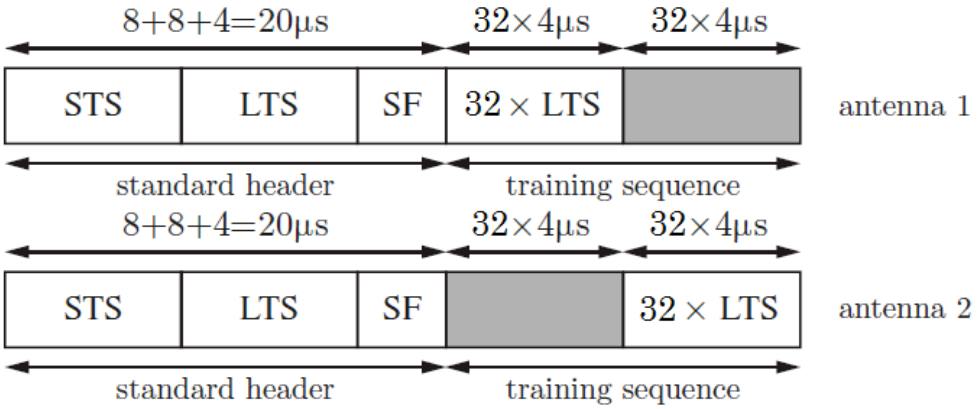

Figura 3.3. Estructura simplificada de la trama a nivel físico definida por el estándar IEEE 802.11a/g y las modificaciones introducidas para su envío por cada antena en los nodos TX [9].

En esta misma Figura 3.3 se puede observar cómo ambas antenas no transmiten los 32 símbolos LTS en el mismo intervalo temporal, algo que en el nodo RX será útil para estimar cada uno de los canales que hay entre todas las posibles combinaciones de antenas, es decir, cada elemento de las matrices de canal $\mathbf{H}_{lk}$.

Una vez generadas las tramas a la frecuencia marcada por el estándar IEEE 802.11a/g (20 Mmuestras/s), lo que se hace es interpolarlas por un factor 2, debido a que el oscilador externo que sincroniza todos los nodos trabaja a 40 Mmuestras/s. Después, la información pasa por un modulador IQ y es almacenada en los *buffers* que incorporan los nodos transmisores. Así, en el momento en el que se indica el inicio de la transmisión, la información pasa a los *digital-analog-converters (DACs)* con los que está equipado cada nodo TX y, posteriormente, se conduce hasta el frontal RF, desde donde se transmite a través de dos de las ocho antenas disponibles, a una frecuencia central de 5610 MHz.

Simultáneamente a la transmisión de las tramas, los nodos RX comienzan el proceso de adquisición, realizando el procedimiento inverso que se llevó a cabo en los transmisores. De esta manera, una vez que la señal recibida ha sido filtrada adecuadamente, ésta pasa por un demodulador IQ y por los *analog-digital-converters (ADCs)*, donde a su salida, las muestras adquiridas son almacenadas en el *buffer* del que dispone cada nodo RX. De este modo, el siguiente paso consiste en la obtención de las señales complejas correspondientes a las tramas enviadas y en el comienzo del procesado de la información. Así, como en cualquier comunicación inalámbrica, las

siguientes acciones que se realizan son la sincronización temporal, diezmado y estima e igualación del canal.

En concreto, la estima de canal es un paso clave en este proyecto, ya que los canales son la información que queremos obtener con estas medidas, y por lo tanto, si ésta no se hiciese correctamente ningún resultado posterior sería válido. Es por esto que, como se explicó previamente y se observa en la Figura 3.3, en las tramas transmitidas se enviaron como *payload* 32 LTS idénticos, con lo que se puede hacer un promediado de los datos recibidos para cada subportadora y luego comparar lo que se ha recibido con lo que en realidad se envió. Así el canal estimado se puede expresar como:

$$h_n = \frac{\sum_s z_{n,s}}{32\, z'_n}, \tag{3.1}$$

donde,

- $z_{n,s}$ es la información recibida para la subportadora n-ésima en el símbolo s-ésimo de los 32 enviados.
- z'_n es la información que realmente se envió para la subportadora n-ésima.

Una vez estimado el canal, también se estima la potencia de ruido, que se obtiene como la varianza de los datos recibidos para cada subportadora a lo largo de los 32 LTS. Por lo tanto la potencia de ruido se puede expresar como:

$$N_n = \frac{\sum_s |z_{n,s} - h_n z'_n|^2}{32}. \tag{3.2}$$

Hay que subrayar que como se dijo al final del tercer apartado de este capítulo, para nosotros cada subportadora será un canal monoportadora no selectivo en frecuencia. Sin embargo en la Figura 3.4 se muestra un ejemplo de los canales que experimentarían transmisiones convencionales OFDM, con lo que se pretende mostrar el entorno en el que se realizaron las medidas.

De esta manera, la Figura 3.4 está compuesta por 9 gráficas en forma matricial, donde cada fila hace referencia a un nodo receptor concreto, y cada columna a un nodo transmisor. Así, cada una de las 9 gráficas muestra el canal existente para las 52 subportadoras entre una pareja de nodos, donde las gráficas que se encuentran en la diagonal principal representan los enlaces directos (la comunicación deseada) y, el resto, los enlaces interferentes. En este caso, la Figura 3.4 muestra un ejemplo de los canales existentes durante una medida experimental, con el que se puede apreciar que el entorno de trabajo en el que se realizaron las medidas es similar a cualquier entorno de comunicaciones inalámbricas, en el que ciertas portadoras observan peores canales que otras. Cada línea de color que aparece en las gráficas se corresponde con el canal que hay entre la pareja formada por una antena del nodo TX y una del nodo RX.

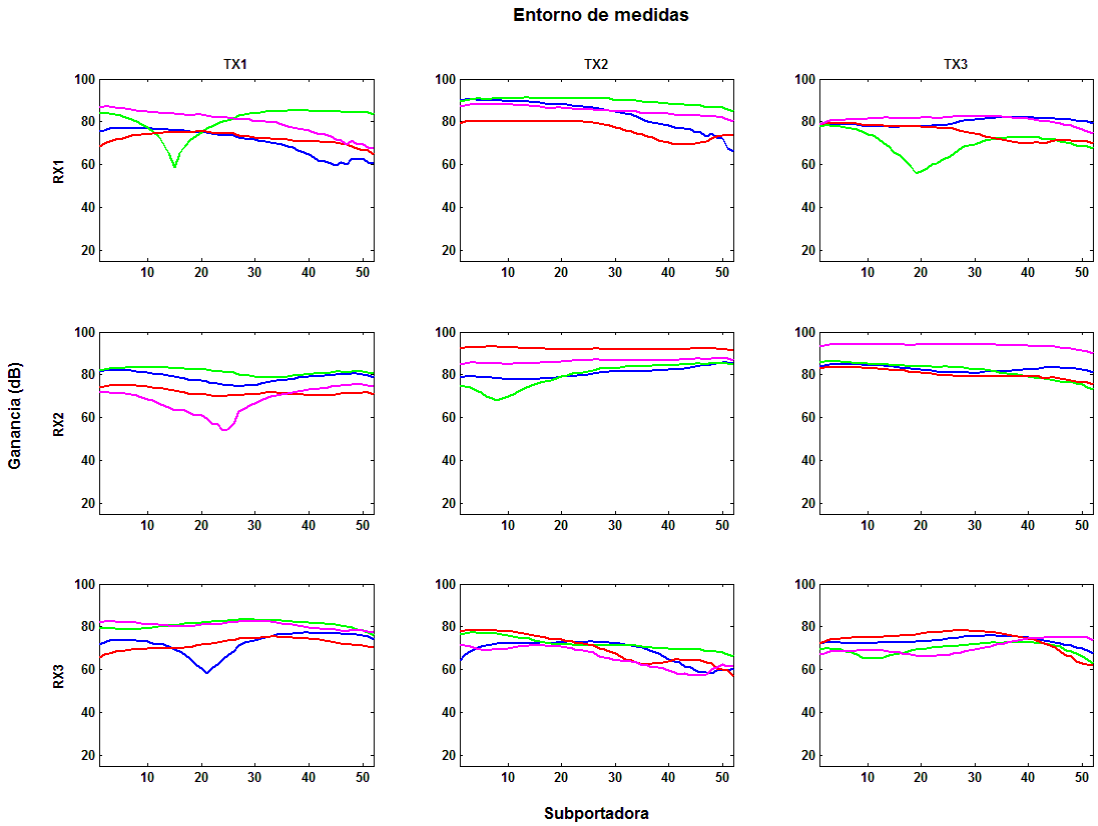

Figura 3.4. Ejemplo de los canales existentes para cada subportadora en la transmisión OFDM utilizada en las medidas experimentales. Las gráficas de la diagonal principal se corresponden con enlaces directos, mientras que el resto muestran enlaces interferentes. Cada línea de color hace referencia al canal que hay entre la pareja formada por una antena del nodo TX y una del nodo RX, mostrándose así en cada gráfica las 4 posibles combinaciones que existen en cada enlace.

3.4 Generación de diferentes escenarios

Como se mencionó en el tercer apartado de este capítulo, el hecho de alternar las antenas por las que se transmite y recibe pretende recrear diferentes situaciones, intentando acercarse lo máximo posible a la gran variedad de escenarios que comúnmente tienen lugar en los sistemas inalámbricos reales. Sin embargo, esto no representa todas las diferentes maneras en las que varios usuarios pueden interferir la comunicación de un tercero, ya que en un entorno de canal de interferencia MIMO real los usuarios interferentes no están fijos en una posición concreta ni a la misma distancia unos de otros. Por eso, en este proyecto se ha pretendido ir un paso más allá e intentar obtener datos que también representen estas situaciones. Con la Figura 3.5 se persigue entender de manera visual esta motivación.

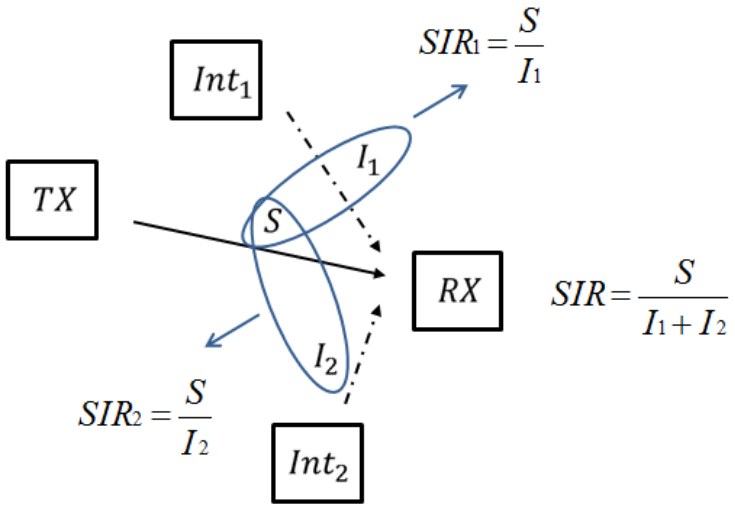

Figura 3.5. Representación simplificada a un único nodo RX del escenario tratado en este proyecto, en la que se observa que los nodos interferentes se encuentran a diferentes distancias, y por lo tanto, la SIR asociada variará en función de su posición.

Con el objetivo de simular un entorno en el que los usuarios no son estáticos y debido a la imposibilidad de mover de lugar los nodos utilizados, lo que se ha planteado en este proyecto es incluir dos variables, SIR_1 y SIR_2, que desde el punto de vista de los nodos RX harán referencia a la *relación-señal-a-interferencia* (SIR) asociada al primer y segundo nodo interferente, respectivamente. De este modo, modificando el valor de estas variables somos capaces de reproducir las variaciones en el nivel de las interferencias que perciben los receptores en un sistema real.

Dado que en el escenario $(2x2,d)^3$ hay 3 nodos RX, cada uno de ellos tendrá una percepción diferente de quién es el primer o segundo nodo interferente. Así por ejemplo, para el nodo RX_1 consideramos que el interferente 1 sería el nodo TX_2 y el interferente 2 sería el nodo TX_3. Sin embargo, para el nodo RX_2 consideramos que el interferente 1 sería el nodo TX_1 y el interferente 2 sería el nodo TX_3. Un razonamiento similar ocurre con el nodo RX_3.

Para recrear los nuevos escenarios que perseguimos, tanto SIR_1 como SIR_2 tomarán valores dentro del rango [-5,30] dB, algo que permitirá tener escenarios muy variados, donde -5 implica que la interferencia está 5 dB por encima de la señal deseada y 30 significa que la interferencia está 30 dB por debajo de la señal deseada. La simulación de estos escenarios se hace de manera *sintética*, es decir, justo en el momento previo al almacenamiento de las tramas en los *buffers* de los nodos TX, éstas se atenúan o amplifican mediante software de forma independiente para cada nodo TX en función del escenario a emular.

Todo esto permite que en la Figura 3.6 podamos ver un ejemplo de lo que sería la señal recibida de manera simultánea en cada uno de los nodos receptores.

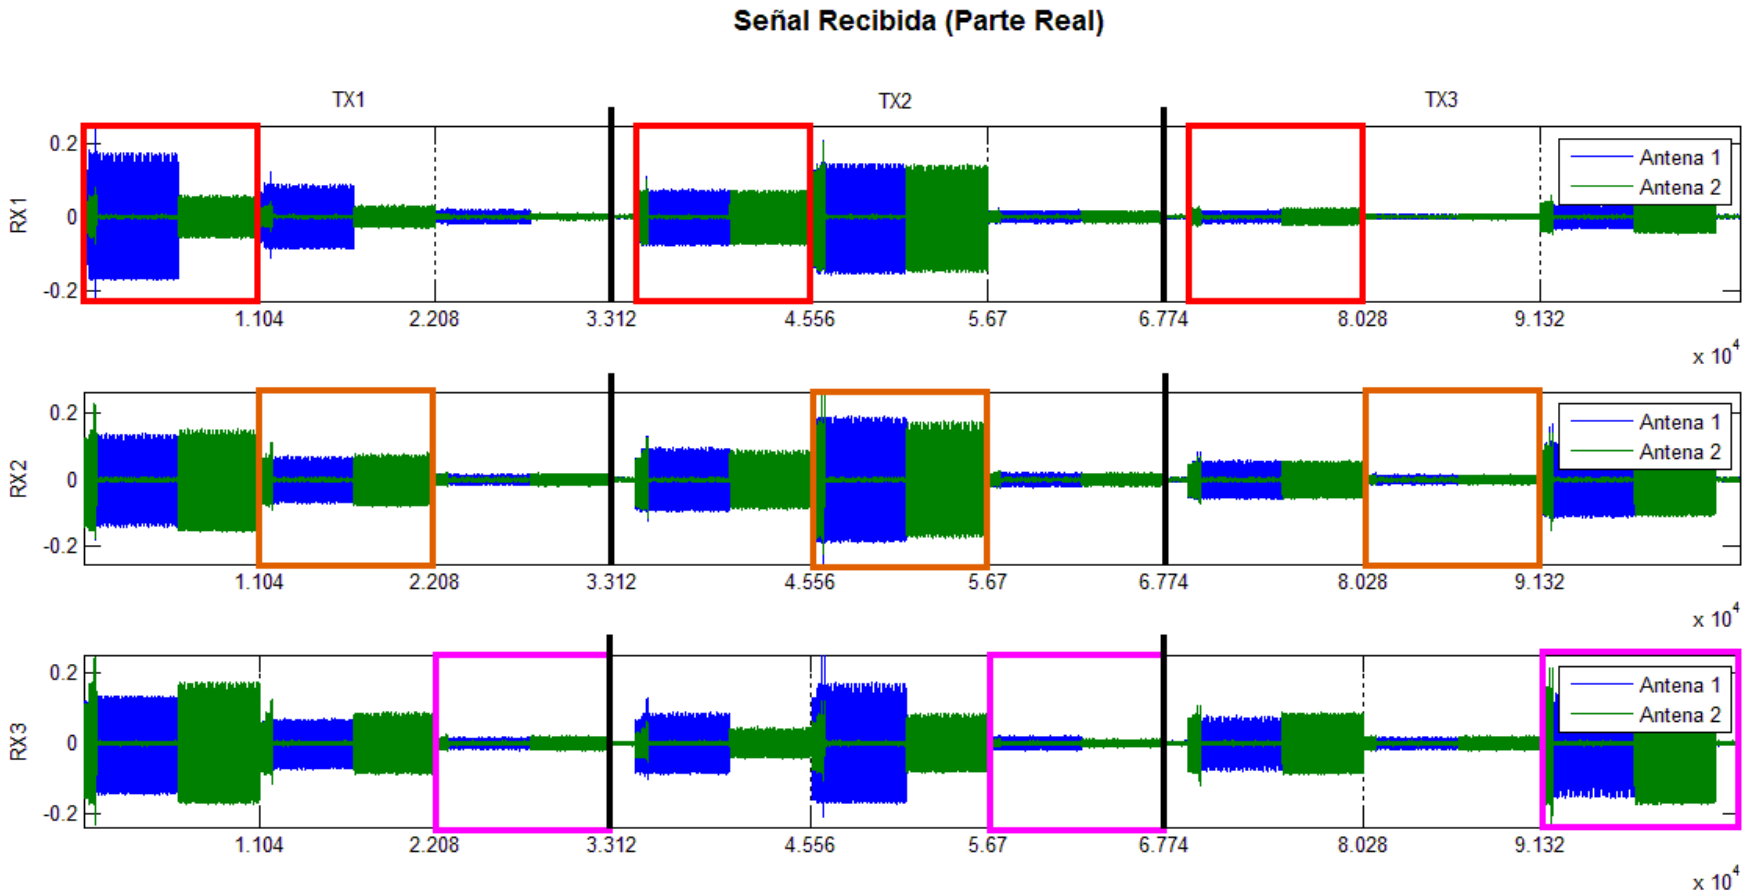

Figura 3.6. Representación de la parte real de las señales recibidas simultáneamente por los nodos RX (filas), procedentes de cada nodo TX (columnas). Debido al esquema de transmisión llevado a cabo, en color rojo, naranja y magenta se encuentran las tramas con las que los nodos RX_1, RX_2 y RX_3 deben quedarse, respectivamente. Además en azul y verde se puede apreciar la multiplexación temporal tratada en el Apartado 3.4, distinguiendo claramente la información que fue enviada por cada antena. En este ejemplo, los valores de SIR_1 y SIR_2 utilizados son 3 y 10 dB, respectivamente.

La interpretación que se debe de hacer de la Figura 3.6 es la siguiente:

- La figura está dividida en tres gráficas, que se corresponden con la señal recibida de manera simultánea en cada uno de los nodos receptores.

- En estas tres gráficas, no solo se pueden apreciar las variaciones de SIRs antes comentadas, sino que también se puede distinguir claramente que la señal recibida por cada nodo RX está dividida en tres partes (entre barras de color negro). Esta división se debe a que para poder estimar correctamente las matrices de canal $\mathbf{H}_{lk}$ de todos los posibles enlaces entre nodos, lo que se ha hecho es multiplexar temporalmente la transmisión de los nodos TX para que no se solapen entre ellos. La explicación para proceder de este modo se debe a que a pesar de que el escenario propuesto persigue representar la transmisión simultánea de tres usuarios, en un primer momento se debe conocer cómo es el canal por el que viaja cada interferencia de manera independiente.

- De esta forma, para un nodo RX, se puede apreciar como cada fragmento de la señal, correspondiente a una combinación de usuarios concreta, se divide en otros tres, entre los que se perciben las variaciones de SIR mencionadas. Esta nueva división se debe a que en cada nodo TX las tramas generadas se transmiten tres veces, con diferentes niveles de señal de acuerdo a las variables SIR_1 y SIR_2. Con esto se pretende que cada nodo RX sólo se quede con una trama concreta procedente de cada transmisor, y así poder simular el escenario deseado con las SIRs requeridas.

Como se ve en la figura, la posición de las tramas elegidas variará en función de cuál sea el nodo RX. Así, basándonos en el ejemplo concreto de la Figura 3.6, el nodo RX_1 se quedaría con las tramas marcadas de color rojo, el nodo RX_2 con las marcadas en naranja y el nodo RX_3 con las magenta. De este modo, en este caso, para cada nodo RX tenemos dos tramas cuya amplitud se ha alterado artificialmente. Sobre la primera se ha inducido una SIR_1 de 3 dB; sobre la segunda, una SIR_2 de 10 dB. Por el contrario, la trama procedente del nodo TX deseado no se ha alterado.

Además, gracias a las tramas utilizadas (Figura 3.3) para la realización de las medidas experimentales, en la Figura 3.6 se puede distinguir claramente la señal transmitida por cada antena del nodo transmisor, representadas con los colores verde y azul.

Así, teniendo en cuenta todas las variaciones de antenas que se han hecho y las combinaciones de SIRs estudiadas, se ha podido crear una base de datos con más de 4 millones de canales estimados y potencias de ruido. De este modo, gracias a la

gran diversidad de los datos disponibles, se ha podido llevar a cabo una buena fase de entrenamiento de la SVM (tratada en el capítulo anterior).

Para finalizar este apartado, se debe mencionar que las medidas experimentales se han llevado a cabo en un entorno controlado[2], estando centralizadas desde un PC, con el que se controla tanto la parte banda base, como el frontal RF de todos los nodos.

3.5 Características de los datos de entrada a la SVM

Como se ha venido tratando a lo largo de este capítulo, el escenario (2x2,d)[3] sobre el que se ha realizado las medidas experimentales es un caso particular del canal de interferencia MIMO, en el que hay 3 nodos TX que quieren comunicarse con sus respectivos nodos RX, donde cada nodo está equipado con 2 antenas. Gracias a este esquema y a lo visto en apartados anteriores, cada uno de los patrones de entrada que se le pasa a la SVM es *n-dimensional*, donde cada dimensión se corresponde con la información estimada de los canales directos o interferentes, y cuyas características serán tratadas más en detalle con posterioridad.

3.5.1 Normalización

En la Sección 3.4 se ha explicado cómo obtener distintos escenarios de interferencia mediante la variación de los parámetros SIR_1 y SIR_2. Como consecuencia, no todas las dimensiones tienen valores similares, pudiendo diferenciarse en órdenes de magnitud, por lo que la variabilidad que podría haber entre éstas sería considerable. Así, antes de empezar el entrenamiento de la SVM y la fase de clasificación, hay que realizar una normalización de los patrones de entrada pertenecientes a los conjuntos de entrenamiento y test.

Es en este punto en el que se introduce la *regla de Silverman* [15], con la que se obtienen *n* valores que utilizaremos para normalizar cada una de las dimensiones de los datos de entrada. La regla de Silverman es ampliamente utilizada en el mundo de la estimación de la densidad del kernel y del *kernel width*, y en nuestro caso la fórmula utilizada es la siguiente:

$$\sigma_i = 0.9 \cdot A \cdot l_{\boldsymbol{x}_i}{}^{-1/5}, \qquad \begin{matrix} A = \min(std(\boldsymbol{x}_i), (q3 - q1)/1.34) \\ i = 1, \dots, n \end{matrix} \tag{3.3}$$

[2]Las medidas se han llevado a cabo en el laboratorio del Grupo de Tratamiento Avanzado de Señal de la Universidad de Cantabria [14].

donde

- $\boldsymbol{x}_i$ es un vector columna que hace referencia a i-ésima dimensión de los datos de entrada que tomamos.
- $q1$ y $q3$ hacen referencia al primer y tercer cuartil de $\boldsymbol{x}_i$, respectivamente.
- $l_{\boldsymbol{x}_i}$ hace referencia a la longitud del vector $\boldsymbol{x}_i$, es decir, representa el tamaño del conjunto que se está normalizando.

De esta manera, se obtienen *n* valores con los que normalizamos cada una de las *n* dimensiones tanto de los patrones de entrenamiento como de los de test. Así, dado que en este proyecto se ha optado por utilizar el *kernel* gaussiano visto en (2.10), con esta normalización se ha realizado el primer paso para ajustar el parámetro σ que en ella aparece. Sin embargo, como se verá en el Capítulo 4, todavía queda ajustar algo más este valor, buscando un escalar *g* que multiplique a σ, con el objetivo de conseguir la máxima probabilidad de acierto posible en la clasificación.

3.5.2 Dimensionalidad

Debido al escenario de interferencia MIMO $(2x2,d)^3$ planteado a lo largo de este capítulo, y haciendo referencia al objetivo fundamental del proyecto (construir una herramienta automática que en función de medidas de canal, le indique al usuario la estrategia de transmisión que debiera emplear para alcanzar el máximo *rate*), en este subapartado se van a presentar las distintas opciones consideradas respecto a la dimensionalidad de los patrones de entrada de la SVM.

Así, a continuación, se describen los 4 casos tenidos en cuenta en este proyecto, con los que se ha pretendido tratar situaciones completamente opuestas, desde el caso en el que la SVM recibe toda la información de la que disponemos, hasta la reducción de ésta en base al conocimiento que tenemos del escenario y a las propiedades físicas del problema.

El primer caso que se va a exponer es en el que se introducen patrones de dimensión 72 como datos de entrada a la SVM. Éste sería el caso extremo en el que la SVM recibiría toda la información de la que disponemos, ya que las 72 dimensiones hacen referencia a las partes real e imaginaria de los canales estimados entre cada una de las 2 antenas de las que disponen los nodos del sistema para el total de 9 enlaces.

En el segundo caso, los patrones de entrada considerados son de 36 dimensiones, donde cada dimensión se corresponde con los módulos de los canales estimados entre cada una de las 2 antenas de las que disponen los nodos TX y RX. De esta manera, la diferencia entre este caso y el anterior (72 dimensiones), es que ahora las dimensiones

de entrada no hacen referencia a la parte real e imaginaria del canal por separado, sino que, simplemente, representan el módulo del mismo.

En el tercer caso, se plantea una reducción de la dimensión de los patrones de entrada a 9. Este caso encajaría con lo que se mencionó previamente sobre la utilización del conocimiento que tenemos del escenario para plantear diferentes alternativas. Así, dado que nuestro escenario es un canal de interferencia MIMO $(2x2,d)^3$, lo que se hace en este caso es calcular la norma Frobenius de las matrices 2x2, cuyos elementos se corresponden con los 4 canales estimados que hay entre las 2 antenas de cada nodo TX y RX. De este modo reducimos cada uno de los 9 enlaces que hay entre todos los nodos a un único número, que nos daría idea de cuál es la contribución energética de la señal recibida por cada enlace.

Una ventaja de esta opción frente a las anteriores, sin entrar todavía en detalles numéricos, es que el hecho de reducir la dimensionalidad de los datos de entrada supone un beneficio en cuanto al coste computacional que tiene que asumir la SVM, con lo que el tiempo requerido para su entrenamiento y la clasificación se reducen enormemente.

El último caso que se va a explicar es aquel en el que la dimensionalidad de los patrones de entrada a la SVM se reduce a 6. Este caso deriva del anterior (9 dimensiones), diferenciándose de él en que ahora se prescinde de la norma Frobenius de los enlaces directos. Con esto se pretende observar si este caso supone alguna mejora o no respecto a los anteriores.

Capítulo 4

Procedimiento, análisis y resultados

En este capítulo se exponen los análisis y procedimientos particulares llevados a cabo en este proyecto, así como los resultados que se han obtenido a partir de los mismos.

4.1 Selección de estrategias definitivas

En este apartado se va a realizar una comparación cuantitativa entre las estrategias de transmisión en el canal de interferencia *multiple-input multiple-output (MIMO)* que fueron presentadas en el Capítulo 1. Esta comparación nos permitirá decidir qué estrategias de las propuestas formarán parte del grupo definitivo que se utilizará en la construcción de la herramienta automática que tiene como objetivo este proyecto.

La figura de mérito que se va a tener en cuenta para llegar a una decisión es el *sum rate* que proporciona cada una de las estrategias. Por lo tanto, para entender los resultados que en este apartado aparecen, hay que tener presentes (1.5), (1.13), (1.15) y (1.18), donde es necesario conocer que el ruido considerado es únicamente el estimado en las antenas receptoras de los enlaces directos, ya que tras comparar los resultados de *sum rate* con los que se obtendrían añadiendo las varianzas de ruido de los enlaces interferentes, se puede concluir que los resultados no experimentan cambios significativos.

En la Figura 4.1 se puede observar la comparación sobre la que se basa este apartado. En ella se muestra la evolución del *sum rate* que los usuarios obtendrían para cada estrategia en 640 realizaciones de canal independientes. Como recordatorio, decir que nos encontramos en el canal de interferencia MIMO $(2x2,d)^3$ que se introdujo en la Sección 3.1 y sobre el que se ha venido trabajando desde entonces.

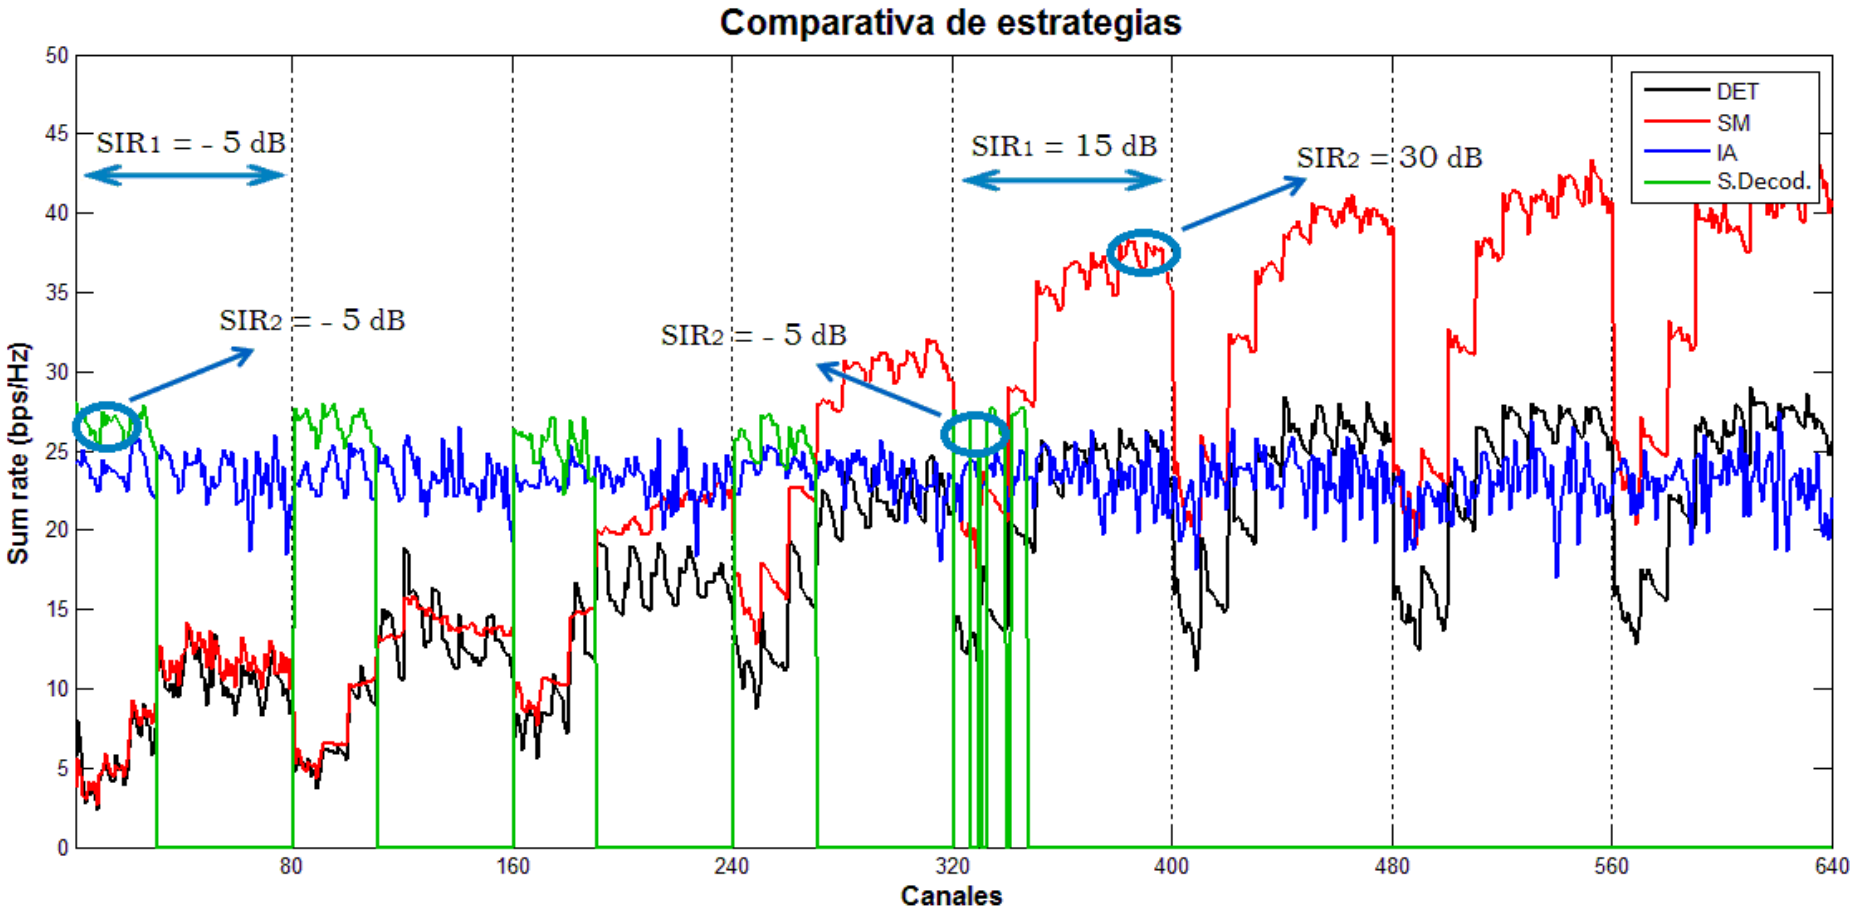

Figura 4.1. Evolución del *sum rate* que los usuarios del canal de interferencia MIMO (2x2,d)[3] consiguen para cada una de las estrategias de transmisión planteadas, a lo largo de 640 realizaciones de canal independientes. También se muestra la organización de las realizaciones de canal, indicando a qué situación de SIR se corresponden.

Sobre la Figura 4.1 se debe explicar que a pesar de que se muestran 640 realizaciones de canal independientes, gracias a los distintos escenarios recreados para diferentes situaciones de interferencia (ver Sección 3.4), los canales que se muestran están organizados de la siguiente manera: de izquierda a derecha, cada 80 canales la SIR referente al primer nodo interferente, desde el punto de vista de cada nodo RX, aumenta en 5 dB. Mientras tanto, dentro de estos 80 canales, la SIR referente al segundo nodo interferente aumenta 5 dB cada 10 canales. De ahí que se puedan percibir variaciones graduales en la evolución del *sum rate* de estrategias como *spatial multiplexing (SM)*, *dominant eigenmode transmission (DET)* o *successive decoding*.

Para una comprensión completa de la Figura 4.1, a continuación se exponen ciertas particularidades de este proyecto, referentes a algunas de las estrategias de transmisión presentadas.

En lo que a la estrategia SM se refiere, en este proyecto se ha considerado que los transmisores no tienen conocimiento del canal, por lo que éstos realizan una transmisión isótropa. De esta manera, consideramos el peor de los casos presentados en la Subsección 1.2.1, acercándonos a la realidad de muchos de los sistemas inalámbricos actuales.

En cuanto a la estrategia *successive decoding*, hay que señalar que por simplicidad se ha impuesto una condición sobre el *sum rate* que los usuarios pueden alcanzar: para que el *sum rate* sea distinto de cero, los tres receptores han de poder decodificar al menos una de las señales interferentes que reciben. De este modo, si la condición se cumple, se pueden dar todo tipo de casos: desde que todos decodifiquen únicamente una interferencia hasta que todos sean capaces de decodificar las dos interferencias que les afectan, considerando también las combinaciones intermedias (ej.: que un usuario sea capaz de decodificar sus dos interferencias, pero el resto solo decodifique una).

Para saber si el usuario k-ésimo puede decodificar una interferencia, lo que se ha planteado es comparar la potencia interferente con $\mathrm{tr}(\mathbf{\Sigma}_k)/2$, es decir, con la potencia de ruido estimada y promediada sobre las dos antenas receptoras para el canal directo entre los nodos TX_k y RX_k. Si la comparación resulta en que la potencia interferente es más de 3 dB superior a $\mathrm{tr}(\mathbf{\Sigma}_k)/2$, la interferencia será decodificada. En caso contrario, el usuario no la podría decodificar. El hecho de que se haya elegido 3 dB como umbral para tomar esta decisión, se debe a la condición previamente impuesta sobre el *sum rate*, ya que esta estrategia entraría muy pocas veces en juego si el umbral fuese superior. Por otro lado, 3 dB parece un umbral razonable, ya que se está forzando a que la potencia interferente sea al menos el doble que la del ruido.

En lo referente a la estrategia *interference alignment (IA)*, debido a la configuración planteada en este proyecto, para cada nodo existen como solución dos posibles

beamformers [9]. Sin embargo, para el cálculo del *sum rate* que los usuarios obtienen aplicando esta estrategia, se ha considerado únicamente el *beamformer* que mejores resultados proporciona.

Para concluir esta sección, a continuación se decide qué estrategias participarán en la construcción del clasificador propuesto como objetivo principal del proyecto. Así, tomando la Figura 4.1 como base, el grupo de estrategias definitivo sobre el que se continuará trabajando es el formado por: SM, IA y *successive decoding*. La elección de estas estrategias se debe a que observando la Figura 4.1, se puede ver que éstas son las que mayor juego van a aportar en una futura clasificación, ya que dependiendo de en qué tipo de situación interferente nos encontremos, el *sum rate* de una será superior al resto, sin que ninguna domine claramente en todo momento.

4.2 Entrenamiento y clasificación de la SVM

El objetivo de este apartado es explicar el proceso concreto llevado a cabo en este proyecto para el entrenamiento de la máquina de vectores soporte (del inglés *support vector machine*, SVM) y la posterior clasificación, una explicación que permitirá obtener un mejor entendimiento del resto de apartados de este capítulo.

En este proyecto se ha optado por la construcción de un clasificador multiclase (ver Sección 2.2) formado por la combinación de tres clasificadores binarios. Esta decisión se ha tomado en base a la conclusión alcanzada en la sección anterior, ya que cada estrategia de transmisión es una *clase* a clasificar y, en este caso, el número total de *clases* es tres. De esta manera, para realizar un entrenamiento completo de la SVM lo que hay que hacer es encontrar los valores de *g* (escalar que multiplica al *kernel width* calculado con la *regla de Silverman* [15]) y *C* (constante con la que se penaliza más o menos los errores cometidos en el entrenamiento de la SVM) más adecuados, con el objetivo de obtener la mejor probabilidad de acierto posible en cada clasificación binaria. Como primera aproximación, para cada clasificador binario se plantea una búsqueda amplia de ambos parámetros (abarcando hasta tres órdenes de magnitud), pero no muy detallada (pasos grandes). Una vez que este proceso ha finalizado, a partir de los valores hallados se realiza una nueva búsqueda mucho más exhaustiva que la anterior, encontrando finalmente los 3 valores de *g* y 3 valores de *C* que dan lugar a la máxima probabilidad de acierto y con los que ya seríamos capaces de comenzar la fase de clasificación.

La técnica de multiclasificación utilizada tras el entrenamiento de la SVM es *one-against-all* (ver Sección 2.2), ya que se trata de una de las más sencillas de implementar y con la que en general se obtienen resultados muy positivos.

Para poder llevar a cabo tanto el proceso de entrenamiento como el de clasificación, a la SVM no solo hay que pasarle los patrones de entrada con la información de los canales, sino que también hay que indicarle a qué clase pertenece cada uno. Esto se hace mediante etiquetas, que son asignadas gracias a la evaluación de las fórmulas del *sum rate* de las estrategias que participan en la construcción del clasificador. De esta manera, tomando como base (1.5), (1.15) y (1.18), lo que se hace para cada patrón de entrada es comparar los 3 *sum rates*, elegir el mayor y asignar al patrón la etiqueta correspondiente a la estrategia ganadora. Así, una vez que finalice la fase de clasificación del conjunto de test, ya se podría calcular la *matriz de confusión* (ver Sección 2.2).

4.3 Evolución del sistema de clasificación respecto al tamaño del conjunto de entrenamiento

En este apartado se introducen los análisis realizados sobre la evolución que sufren parámetros clave en la SVM, en función del tamaño de los conjuntos de entrenamiento utilizados. En las siguientes subsecciones se presentan las evoluciones del error cometido en la clasificación, del número de *vectores soporte* utilizados y del gasto computacional que conlleva la fase de entrenamiento.

En todos los estudios desarrollados en este apartado, los tamaños de los conjuntos de entrenamiento analizados toman valores dentro del intervalo [1000, 20000], con pasos de 1000 patrones. Con el objetivo de que en cada gráfica se puedan mostrar unos resultados estadísticamente válidos, para cada punto de la misma se han promediado los resultados obtenidos al utilizar 10 conjuntos de entrenamiento independientes. El error en la clasificación se ha evaluado utilizando 20000 patrones de test.

4.3.1 Evolución del error

Para medir cuál es el error cometido en la clasificación, en este proyecto se ha optado por cuantificar lo que se alejan las *matrices de confusión* de la matriz identidad. Para ello se plantea la siguiente expresión:

$$E_n = ||\boldsymbol{I}_3 - \boldsymbol{C}_n||_F^2, \tag{4.1}$$

donde $\mathbf{C}_n \in \mathbb{R}^{3x3}$ es la matriz de confusión obtenida tras la clasificación del conjunto de test formado por patrones de dimensión *n*, pudiendo *n* tomar los valores 6, 9, 36 ó 72, como se vio en el Subapartado 3.5.2. La matriz de confusión es la figura de mérito utilizada tras la fase de clasificación para cuantificar cómo de buena ha sido ésta. De

esta manera, para entender mejor los resultados que se muestran en este apartado, pasamos a describir brevemente como es la estructura de estas matrices para el escenario planteado en este proyecto.

En este caso, el tamaño de las matrices de confusión es 3x3, donde en la diagonal principal se encuentra la probabilidad de acierto en la clasificación para cada una de las *clases* y fuera de ella las probabilidades de error cometidas. Así, asignando etiquetas concretas a las estrategias definitivas ("1" para *successive decoding*, "0" para IA y "-1" para SM) y siguiendo el orden en el que se nombran, si por ejemplo el elemento 1,2 de la matriz de confusión es 0.1, esto quiere decir que del total de patrones pertenecientes a la clase 1 (*successive decoding*), el 10 % fueron identificados erróneamente por la SVM como de la clase 0 (IA).

A continuación, basándonos en (4.1) se presenta la Figura 4.2, donde se observa cómo el error cometido en la clasificación varía respecto al tamaño de los conjuntos de entrenamiento estudiados para cada dimensión. En esta figura también se puede ver cuál es el intervalo de confianza dentro del que se encuentra el error calculado.

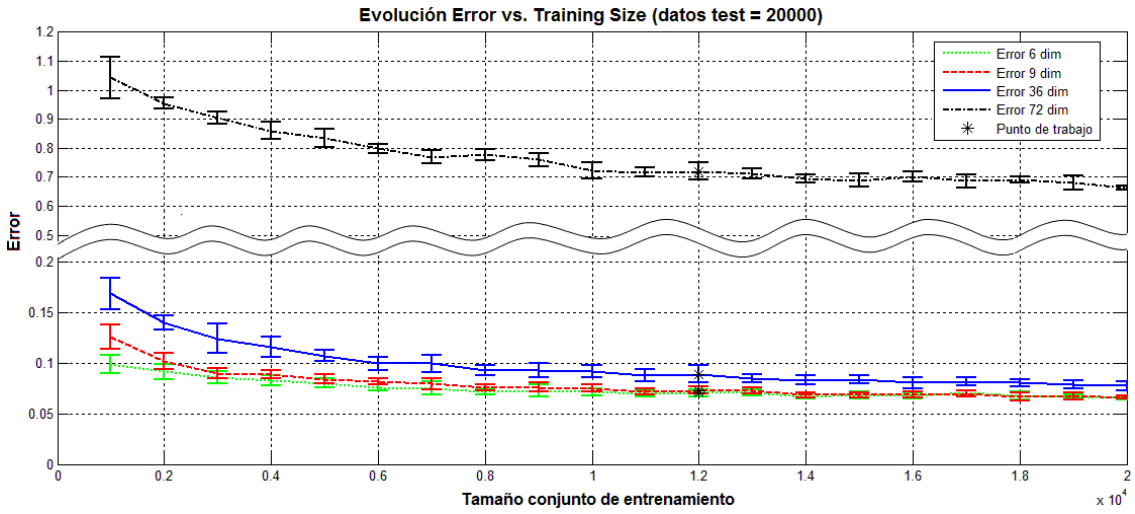

Figura 4.2. Evolución del error cometido en la clasificación para cada una de las dimensiones estudiadas, respecto al número de patrones de entrenamiento utilizados. Asimismo se puede observar el intervalo de confianza en el que se encuentran los resultados y el punto de trabajo elegido en este proyecto (12000 patrones de entrenamiento).

El hecho de que la Figura 4.2 se encuentre dividida, se debe a que la evolución del error para 72 dimensiones dista numéricamente mucho del resto, por lo que si no se hubiese fragmentado la figura, no se apreciaría con claridad la evolución para el resto de dimensiones.

En general, se puede ver como a medida que el número de patrones de entrenamiento utilizados es mayor, el error disminuye. Éste es un resultado lógico, ya que cuanta más información tenga la SVM, más preciso será el hiperplano de separación entre *clases* construido. De la Figura 4.2 también cabe destacar que para patrones de entrada de 72 dimensiones, el error cometido es bastante superior al resto, por lo que esta dimensión será descartada de la construcción de la herramienta automática que se persigue en este proyecto.

En la Figura 4.2, en forma de estrella está marcado el punto de trabajo elegido en este proyecto. Esta elección se debe, entre otras cosas, a que como se observa, 12000 patrones de entrenamiento es un tamaño relativamente bueno, ya que el error que se comete es bastante bajo para las dimensiones representadas y el tamaño no es excesivamente pequeño, por lo que se podrá entrenar la SVM correctamente.

4.3.2 Evolución del número de vectores soporte necesarios

En este subapartado se analiza el número de *vectores soporte* que la SVM necesita para definir el hiperplano de separación entre *clases*. Éste es un parámetro clave en el proceso de aprendizaje, ya que a medida que este número crece, la complejidad de la SVM y el tiempo necesario para el entrenamiento aumentan, algo que a día de hoy podría llegar a ser intolerable si se quisiese implementar este tipo de clasificaciones en sistemas comerciales.

En la Figura 4.3, se muestra la evolución del número de *vectores soporte* utilizados en el entrenamiento de la SVM, respecto a diferentes tamaños del conjunto de entrenamiento. El eje de ordenadas de la figura hace referencia a la suma de los *vectores soporte* que se utilizan en los 3 clasificadores binarios planteados en este proyecto.

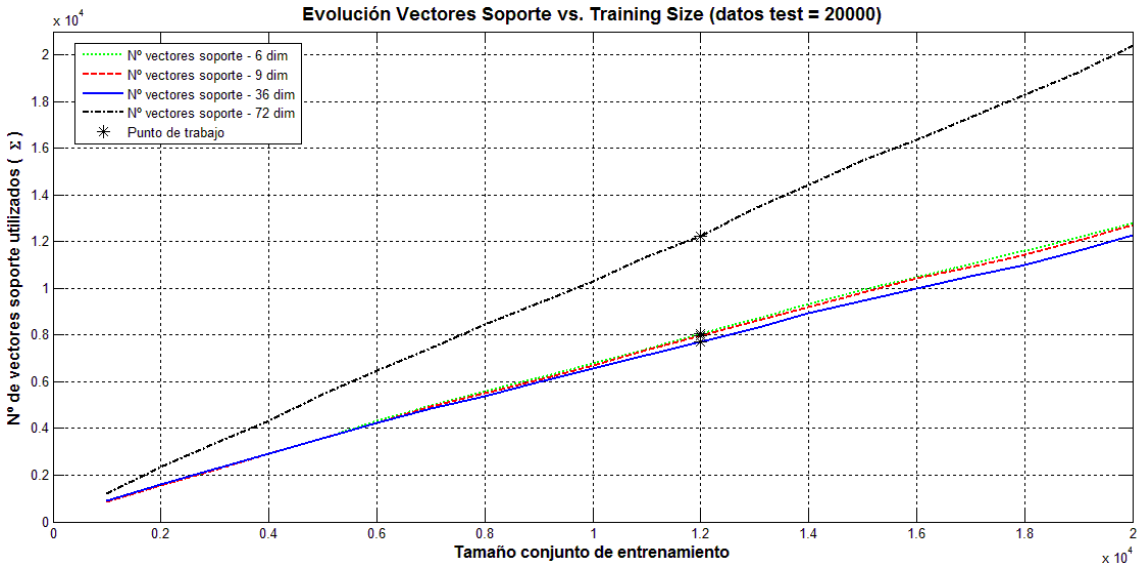

Figura 4.3. Evolución del total de los vectores soporte utilizados por la SVM para todas las dimensiones estudiadas, respecto al número de patrones de entrenamiento utilizados. Asimismo, se puede observar el punto de trabajo elegido en este proyecto (12000 patrones de entrenamiento).

Al igual que en la subsección anterior, en esta figura, con una estrella se indica el punto de trabajo elegido en este proyecto. Dado que en este punto el número total de *vectores soporte* para las dimensiones representadas (a excepción de 72, que será descartada) es muy parecido y está en torno a los 8000, podríamos decir que, en media, cada clasificador binario utiliza 2700 *vectores soporte*, aproximadamente. En base a este último dato se puede determinar que la elección del punto de trabajo es bastante razonable, ya que cada clasificador binario utilizaría, aproximadamente, un 22 % de los patrones que forman el conjunto de entrenamiento, llevándose a cabo un aprendizaje generalizado.

4.3.3 Análisis del gasto computacional

En este último subapartado se presenta el estudio llevado a cabo sobre el gasto computacional que conlleva la fase de entrenamiento de la SVM, asumiendo que ya han sido encontrados los parámetros *g* y *C* mencionados en la Sección 4.2. En la Figura 4.4, se muestra la evolución de este gasto computacional respecto a diferentes tamaños del conjunto de entrenamiento.

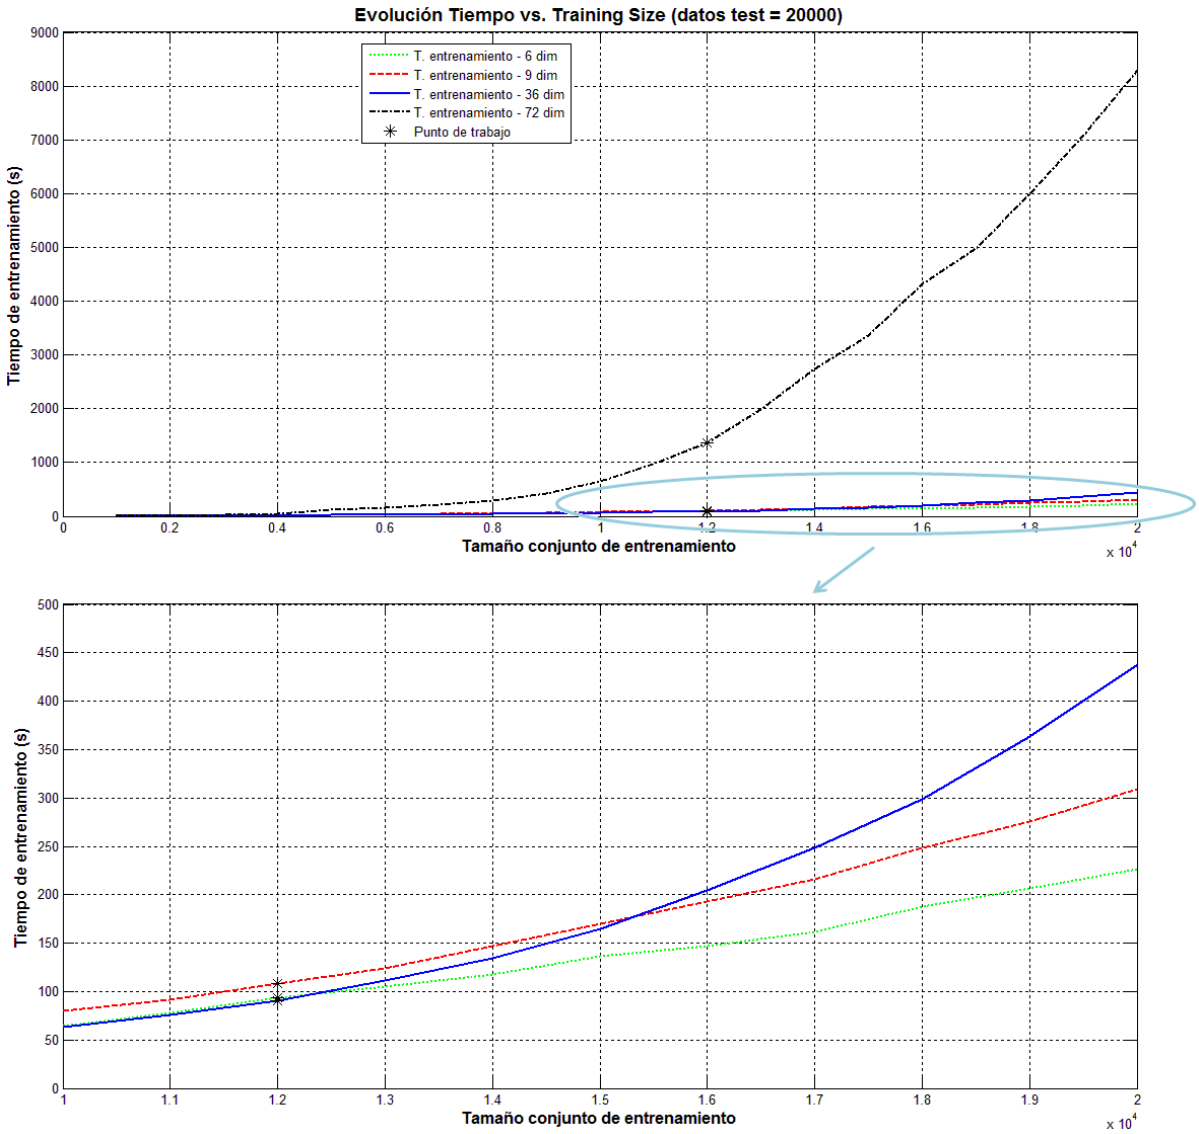

Figura 4.4. Evolución del gasto computacional en la fase de entrenamiento de la SVM para todas las dimensiones estudiadas, respecto al número de patrones de entrenamiento utilizados. Asimismo, se puede observar el punto de trabajo elegido en este proyecto (12000 patrones de entrenamiento).

Como se puede observar en la figura, a medida que el tamaño de los conjuntos de entrenamiento crece, el tiempo requerido aumenta significativamente. Dado que el tiempo es un parámetro esencial a la hora de intentar trasladar este tipo de sistemas a la realidad, estos resultados deben ser tenidos muy en cuenta.

Lo ideal sería disponer de un sistema que pudiese trabajar con un número enorme de patrones de entrada y que el coste computacional necesario para su entrenamiento fuese muy reducido. Sin embargo, en la realidad existe una relación de compromiso entre ambas condiciones y, por lo tanto, hay que buscar la solución que mejor se adapte a los recursos disponibles.

En la Figura 4.4, se puede ver como el gasto computacional asociado a la utilización de patrones de 72 dimensiones es ampliamente superior al del resto de dimensiones estudiadas, lo que respalda la decisión de descartar esta opción para la construcción del clasificador final. En esta figura también se puede observar que otro de los motivos para la elección del punto de trabajo utilizado en este proyecto (marcado con una estrella), es que éste lleva asociado un coste computacional asumible, lo que ha permitido realizar numerosas pruebas en un tiempo razonable.

4.4 Primeros resultados

Como ya se ha ido adelantando en apartados anteriores, la *matriz de confusión* es la figura de mérito utilizada para evaluar cuán buena ha sido la clasificación realizada por la SVM. En la Tabla 4.1, se muestran ejemplos representativos de las *matrices de confusión* obtenidas para las distintas dimensiones de datos de entrada estudiadas (ver Subapartado 3.5.2), incluyendo los parámetros *g* y *C* correspondientes a cada uno de los tres clasificadores binarios de *one-against-all*.

6 dimensiones

S.Decod.	IA	SM
0.8765	0.0908	0.0327
0.0776	0.8746	0.0478
0.0073	0.0929	0.8998

C →	85	75	6	
g →	28	24	7	

9 dimensiones

S.Decod.	IA	SM
0.8708	0.0995	0.0298
0.0749	0.8603	0.0648
0.0076	0.0805	0.9118

C →	61	25	43
g →	46	16	20

36 dimensiones

S.Decod.	IA	SM
0.8311	0.1206	0.0483
0.0805	0.8550	0.0645
0.0090	0.0671	0.9239

C →	35	20	37
g →	83	86	94

72 dimensiones

S.Decod.	IA	SM
0.4298	0.3995	0.1707
0.1920	0.6663	0.1417
0.0420	0.0392	0.9188

C →	450	200	50
g →	850	1000	650

Tabla 4.1. Ejemplo representativo de las matrices de confusión obtenidas para las distintas dimensiones de datos de entrada estudiadas. Junto a cada matriz aparecen los parámetros g y C correspondientes a cada clase. El número de patrones de entrenamiento y test utilizados en cada conjunto son 12000 y 20000, respectivamente.

Los resultados mostrados en la Tabla 4.1 se obtienen utilizando conjuntos de entrenamiento formados por 12000 patrones, ya que tal y como se vio en la sección anterior, este tamaño consigue un compromiso adecuado entre el coste computacional asociado al entrenamiento de la SVM, el número de vectores soporte necesarios y las probabilidades de acierto obtenidas. Por otro lado, los conjuntos de test utilizados están formados por 20000 patrones, un tamaño que permite tener cierta seguridad sobre la validez de los resultados que se obtienen.

Gracias al cálculo de las *matrices de confusión* que se muestran en la Tabla 4.1, más adelante podremos determinar la dimensionalidad de los datos de entrada que aporta el mejor balance entre la mínima información necesaria y más discriminativa de los canales, y la probabilidad de acierto en la clasificación, con lo que se persigue construir un clasificador lo más sencillo y fiable posible.

4.5 Clasificador híbrido propuesto

Los primeros resultados numéricos de multiclasificación se mostraron en el apartado anterior con las *matrices de confusión* de la Tabla 4.1. Aunque estos valores nos sirven como primer indicativo de los resultados que podemos alcanzar, lo que perseguimos son resultados estadísticamente válidos, por lo que en este apartado se plantea: crear varios conjuntos de entrenamiento y test, seguir para cada uno las fases de entrenamiento y clasificación explicadas en la Sección 4.2, obtener las *matrices de confusión* correspondientes y promediar las probabilidades de acierto a lo largo de todos los conjuntos utilizados. Siguiendo todos estos pasos, en la Tabla 4.2 se presenta una comparativa de las probabilidades de acierto (diagonal principal de las *matrices de confusión*) que se consiguen para cada *clase* y para cada una de las dimensiones de datos de entrada estudiadas.

Dimensión	Successive decoding	IA	SM
6	0.8849 ± 0.006	0.8720 ± 0.007	0.8944 ± 0.004
9	0.8759 ± 0.008	0.8557 ± 0.008	0.9063 ± 0.005
36	0.8313 ± 0.009	0.8617 ± 0.007	0.9223 ± 0.004
72	0.4221 ± 0.011	0.6579 ± 0.007	0.9164 ± 0.003

Tabla 4.2. Comparativa de las probabilidades de acierto obtenidas y promediadas a lo largo de 20 conjuntos independientes, para las diferentes estrategias de transmisión y dimensiones de los patrones de entrada estudiadas. El número de patrones de entrenamiento y test utilizados en cada conjunto son 12000 y 20000, respectivamente.

Los resultados mostrados en la Tabla 4.2 se han obtenido promediando las probabilidades de acierto conseguidas tras la clasificación de 20 conjuntos de test independientes, donde cada conjunto está formado por 20000 patrones. Para llegar a estos resultados, también se tiene que tener en cuenta que los parámetros *g* y *C* utilizados para cada dimensión, son los mostrados en la Tabla 4.1.

En la Tabla 4.2, junto con la probabilidad de acierto aparece la desviación estándar de los datos promediados, un parámetro que debido a su bajo valor numérico, nos indica que el promedio de 20 conjuntos independientes es suficiente para obtener resultados estadísticamente válidos.

A continuación, vamos a presentar ciertas características relacionadas con la dimensionalidad de los patrones de entrada, que nos permitirán descartar la utilización de dos de las dimensionalidades estudiadas:

1) Con 72 dimensiones se obtienen los peores resultados. Esto puede ser debido a que estemos haciendo *overfitting*, es decir, que se estén introduciendo dimensiones que no aportan nada, pudiendo incluso perjudicar el proceso de entrenamiento de la SVM, ya que estaríamos haciendo algo parecido a introducir ruido.
   Un ejemplo de esto podría verse con la estrategia *successive decoding*, en la que las interferencias sólo entran en juego cuando una de ellas no puede ser decodificada (condición definida en el Apartado 4.1). Por lo tanto, la mayor parte del tiempo se estarían añadiendo canales interferentes con los que no introducimos información útil a la SVM.
   Otra causa a la que pueden deberse estos resultados, es que el número de patrones de entrenamiento no sea lo suficientemente elevado y, por lo tanto, hubiese que trabajar con conjuntos de mayor tamaño para obtener mejores resultados.

2) Con 6 dimensiones, a pesar de que parece que se obtienen los mejores resultados, éstos no pueden ser tenidos en cuenta junto al resto. Fruto de la metodología utilizada para la creación de diferentes escenarios de interferencia (ver Sección 3.4), las variaciones que sufren los canales interferentes son mucho mayores que las que sufren los directos, por lo que la SVM ha aprendido que estos últimos no aportan información relevante para la clasificación. Esto hace que utilizando únicamente 6 dimensiones se consigan resultados similares a los obtenidos con 9. Sin embargo, el conocimiento del problema nos dice que los canales directos son indispensables y deben estar presentes en los datos que se utilicen, por lo que los resultados obtenidos para 6 dimensiones han sido descartados.

Una vez presentados los motivos por los que no se van a utilizar patrones de entrada de 6 ó 72 dimensiones, para poder proponer un clasificador definitivo, debemos

considerar las dos dimensionalidades restantes. Por eso, a pesar de que la probabilidad de acierto en ambas no es muy distinta para las diferentes estrategias de transmisión, a continuación vamos a hacer un estudio de por qué en unas estrategias es preferible utilizar datos con 36 dimensiones y en otras con 9. Como recordatorio, decir que el escenario concreto ante el que nos encontramos es el canal de interferencia MIMO $(2x2,d)^3$.

i. Para la estrategia *successive decoding* es preferible utilizar patrones de entrada de 9 dimensiones, ya que es posible que con 36 estemos haciendo *overfitting* y, por lo tanto, solo sea necesario conocer la contribución energética de la señal recibida por cada enlace.

ii. La estrategia IA se basa en el alineamiento de interferencias aplicando *beamformers* que se calculan a partir de las matrices de canal de los enlaces interferentes. Por lo tanto, dado que en este caso es necesario tener la máxima información posible de los canales interferentes, los patrones de entrada que deben utilizarse son de 36 dimensiones.

iii. La estrategia SM es la única estrategia de transmisión estudiada en la que cada nodo TX envía dos *streams* de datos independientes a la vez. Por ello, en el receptor es necesario tener un conocimiento lo más detallado posible de los canales por los que viajan ambos *streams*, ya que de otra forma, la probabilidad de acierto se vería penalizada. En este caso, la mejor opción es utilizar patrones de entrada de 36 dimensiones.

De acuerdo con los resultados y explicaciones que se han presentado a lo largo de este apartado, se puede concluir que para construir la herramienta automática que persigue este proyecto, los datos de entrada deben tener 9 ó 36 dimensiones. En concreto, se ha determinado que la máxima probabilidad de acierto se conseguiría construyendo un clasificador que reciba patrones de entrada de 36 dimensiones y que después, dado que se pretende realizar una clasificación múltiple, en función de la estrategia que vaya a evaluar en cada clasificador binario, utilice los datos recibidos sin modificarlos o haga la norma Frobenius de los datos correspondientes a cada enlace, reduciendo así la dimensionalidad de los patrones de entrada a 9.

En resumen, el clasificador propuesto es un clasificador híbrido que para las estrategias IA y SM utiliza datos de entrada de 36 dimensiones, mientras que para la estrategia *successive decoding* reduce la dimensionalidad de los patrones de entrada a 9.

En la Figura 4.5, se muestra un esquema de lo comentado previamente, con el que se pretende entender de forma visual cómo funciona el clasificador híbrido propuesto.

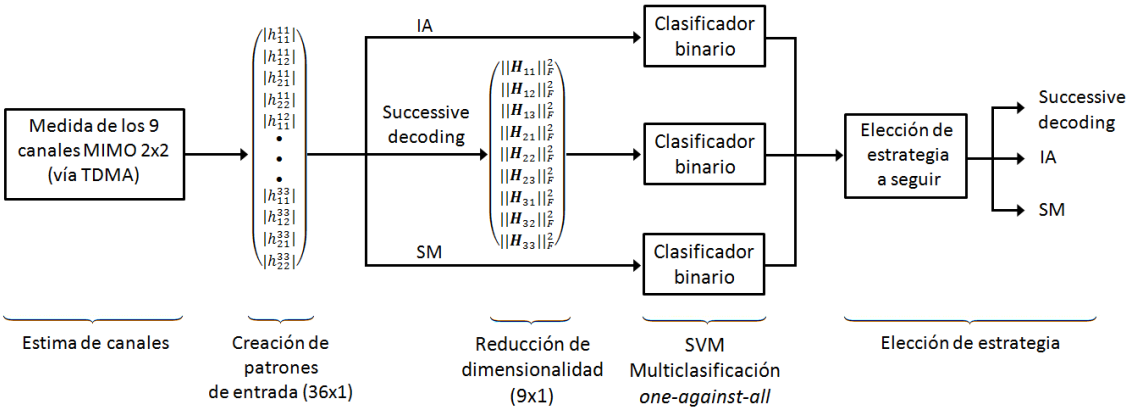

Figura 4.5. Esquema detallado del clasificador híbrido propuesto, en el que se indican los pasos a seguir desde la obtención de las medidas de canal hasta la elección de la estrategia de transmisión que deben aplicar los usuarios.

Por último, para completar el análisis y la elección de este clasificador híbrido, a continuación se presenta el estudio llevado a cabo sobre el efecto que tendría añadir el ruido estimado durante las medidas experimentales como dato de entrada a la SVM.

4.5.1 Análisis del ruido en el vector de características

A lo largo de este proyecto, básicamente, se ha hablado del ruido para explicar cómo se ha estimado (Capítulo 3) y comentar la influencia que tiene en las fórmulas teóricas del *sum rate* en cada estrategia de transmisión (Capítulo 1). Sin embargo, en este último subapartado se termina de dar forma al clasificador híbrido propuesto estudiando el efecto que tendría añadir el ruido a los conjuntos de entrenamiento y test utilizados. De esta manera, lo que se pretende observar es si el hecho de añadir el ruido como dimensión adicional en los datos de entrada, tiene algún beneficio respecto a lo hecho hasta el momento.

Haciendo referencia a la Tabla 4.2, a la vista de que los resultados obtenidos para 9 dimensiones son fiables y a que este caso es uno de los que se utilizan en el clasificador híbrido propuesto, a continuación se presenta la Tabla 4.3. En esta tabla, se muestra una comparativa entre las probabilidades de acierto promediadas a lo largo de 20 conjuntos independientes, tanto para el caso de 9 dimensiones estudiado anteriormente como para este mismo caso añadiéndole 3 dimensiones de ruido (correspondientes a las 3 potencias de ruido estimadas en los enlaces directos del

canal de interferencia MIMO (2x2,d)[3] planteado). Hay que recordar que únicamente se habla de las potencias de ruido de los 3 enlaces directos porque, tal y como se comentó al comienzo de este capítulo, el cálculo teórico del *sum rate* se ve mínimamente alterado cuando se añade el ruido de los enlaces interferentes.

Dimensiones señal + ruido	Successive decoding	IA	SM
9 + 0	0.8759 ± 0.008	0.8557 ± 0.008	0.9063 ± 0.005
9 + 3	0.8618 ± 0.006	0.8630 ± 0.007	0.9062 ± 0.005

Tabla 4.3. Comparativa entre las probabilidades de acierto promediadas a lo largo de 20 conjuntos independientes para los patrones de entrada de entrada de 9 y 9+3 dimensiones, donde éstos últimos se diferencian de los primeros en que incluyen 3 dimensiones correspondientes a las potencias de ruido estimadas en los enlaces directos. El número de patrones de entrenamiento y test utilizados en cada conjunto son 12000 y 20000, respectivamente.

En la Tabla 4.3 no se aprecian diferencias considerables entre las probabilidades de acierto para los patrones de entrada de 9+0 y 9+3 dimensiones, algo que se debe a la naturaleza del ruido y a la capacidad de aprendizaje de la SVM. Al igual que ocurre en el punto 2 de la Sección 4.5, la variabilidad del ruido térmico (ruido blanco) es despreciable frente a la variabilidad introducida artificialmente en los canales interferentes. Por tanto, es razonable que éste no aporte información relevante para la clasificación.

Hay que mencionar que para llegar a la Tabla 4.3, los parámetros *g* y *C* utilizados para los patrones de entrada de 9+0 dimensiones son los que aparecen en la Tabla 4.1, mientras que los utilizados para los patrones de dimensión 9+3 son los siguientes:

	S. dec.	IA	SM
C	→ 65	8	58
g	→ 33	20	30

Tabla 4.4. Valores de g y C utilizados en el entrenamiento y clasificación de los patrones de entrada de dimensión 9+3.

Para finalizar, teniendo en cuenta los resultados mostrados en este subapartado, se puede concluir que el ruido no es un factor decisivo y, por lo tanto, el clasificador híbrido propuesto debe seguir trabajando con datos de entrada de 9 y 36 dimensiones.

4.6 Síntesis de resultados

En este apartado se van a resumir brevemente los resultados más relevantes que se han ido obteniendo a lo largo de este proyecto.

De entre las diferentes estrategias de transmisión que existen para el canal de interferencia MIMO, este estudio se ha centrado en SM, IA y *successive decoding*, ya que estas tres estrategias son las que mayor juego aportan en la construcción de la herramienta automática de clasificación que tiene como objetivo este proyecto. De esta manera, dado que se tiene que llevar a cabo una clasificación ternaria, se ha decidido que *one-against-all* es la técnica de clasificación múltiple más adecuada, ya que se trata de una de las más sencillas de implementar y con la que en general se obtienen resultados muy positivos.

Para conseguir una buena relación de compromiso entre el gasto computacional que conlleva el entrenamiento del clasificador, el número de vectores soporte necesarios y la probabilidad de acierto en clasificación, se ha demostrado que 12000 es el número apropiado de patrones que deben formar los conjuntos de entrenamiento. Por otro lado, para construir un clasificador sencillo, pero fiable, se ha concluido que los patrones de entrada que recibe deben ser de 9 y 36 dimensiones, ya que de esta manera se consigue un *trade-off* razonable entre la mínima información necesaria y más discriminativa de los canales, y la probabilidad de acierto en clasificación.

Otro resultado obtenido en este proyecto, es la determinación de la poca relevancia que tiene el hecho de añadir el ruido a los patrones de entrada, en lo que a la probabilidad de acierto en clasificación se refiere.

Por último, como resultado final se ha determinado que el mejor clasificador posible que se puede construir para el escenario de canal de interferencia MIMO $(2x2,d)^3$ planteado, es aquel que para las estrategias IA y SM utiliza patrones de entrada de 36 dimensiones, mientras que para la estrategia *successive decoding* reduce la dimensionalidad de los patrones a 9.

Capítulo 5

Conclusiones y líneas futuras

En este último capítulo se presentan, de manera general, las conclusiones que se han podido alcanzar a lo largo del desarrollo de este proyecto, así como una breve descripción de las posibles líneas de investigación que pueden surgir a partir del mismo.

5.1 Conclusiones

El principal objetivo abordado por este proyecto ha sido la construcción de una herramienta automática basada en técnicas de clasificación y *machine learning*, que en función de medidas de canal, indica a los usuarios la estrategia de transmisión que deben seguir para alcanzar el máximo *sum rate* en su comunicación. En concreto, este trabajo se ha llevado a cabo en un escenario de canal de interferencia *multiple-input multiple-output (MIMO)*, lo que nos ha permitido conocer las características más relevantes de un escenario que sirve como base de numerosas investigaciones en el campo de las comunicaciones.

En lo referente a la gestión de interferencias, este proyecto se desmarca de estrategias de transmisión que tratan de evitarlas ortogonalizando las transmisiones de los usuarios en el tiempo o en la frecuencia, como *time division multiple access (TDMA)* y *frequency division multiple access (FDMA)*, y centra su estudio en estrategias que obtienen un mejor aprovechamiento de los recursos, actuando sobre las interferencias y explotando las posibilidades que ofrecen en conjunto los sistemas MIMO y la dimensión *espacial*. Entre estas estrategias se incluye alguna tan novedosa como *interference alignment (IA)*.

La primera contribución que podemos destacar de este proyecto es que gracias a la construcción de la herramienta automática de clasificación y a la aplicación de las estrategias de transmisión presentadas, los usuarios son capaces de adaptarse de

manera eficaz a un entorno en el que predomina la interferencia, consiguiendo trabajar al máximo *sum rate* posible.

Como segunda contribución, se ha podido comprobar que clasificaciones múltiples complejas como las que se han llevado a cabo en este proyecto, se pueden realizar haciendo uso conjunto de la máquina de vectores soporte (del inglés *support vector machine*, SVM) y técnicas simples de multiclasificación como *one-against-all*, ya que, tal y como se ha visto, las probabilidades de acierto conseguidas son bastante razonables.

Otra contribución a señalar es la conclusión alcanzada con la que se determina que para realizar el entrenamiento de la SVM y la posterior clasificación, no es necesario utilizar toda la información sobre los canales que hay entre los nodos transmisores y receptores, ya que en ocasiones esto puede llegar a ser perjudicial.

A modo de conclusión final y de forma más simplificada que en la Figura 4.5, en la Figura 5.1 se muestra un esquema del proceso seguido desde la estimación de las matrices de canal hasta la elección de la estrategia de transmisión que los usuarios deben seguir.

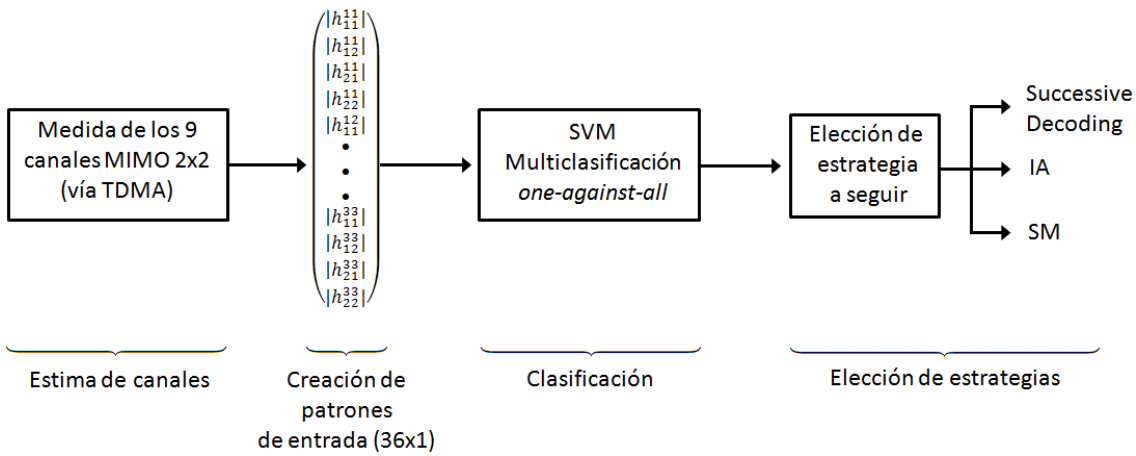

Figura 5.1. Esquema general, a nivel de bloques, del proceso seguido durante el proyecto hasta la elección final de la estrategia a seguir por los usuarios.

5.2 Líneas futuras

Este proyecto sirve como base para futuras investigaciones relacionadas con las telecomunicaciones en el área de las SVMs, *machine learning*, etc., ya que se trata de un campo bastante novedoso y que está en continua investigación. Sin embargo, hay que destacar que la SVM, uno de los principales pilares de este proyecto, tiene

numerosas aplicaciones, no solo en el ámbito de las telecomunicaciones, sino también en áreas tan diversas como el reconocimiento de movimientos humanos [16] o la biomedicina [17].

El contenido de este proyecto sirve de apoyo para futuras investigaciones que profundicen más en diferentes aspectos que, por ejemplo, en sistemas comerciales pueden tomar una mayor importancia. Así, aunque en este proyecto, por simplicidad, todos los usuarios llevan a cabo la misma estrategia de transmisión, esto se podría ampliar de manera que el clasificador fuese capaz de aislar a los diferentes usuarios, es decir, tratarlos de manera individual. De este modo, cada usuario podría llevar a cabo una estrategia independiente de la del resto, por lo que este avance permitiría tener un sistema más completo y flexible.

Otra interesante línea de investigación sería profundizar en el estudio realizado en este proyecto teniendo en cuenta escenarios con más usuarios y considerando topologías diferentes al canal de interferencia. Esto supondría un enfoque más cercano a lo que ocurre en los sistemas inalámbricos actuales, y gracias al avance de la tecnología, este tipo de procedimientos podrían llegar a ser una alternativa a los convencionales.

El hecho de que cada vez se utilice un mayor número de sistemas basados en *machine learning*, hace que en el futuro los dispositivos puedan ser más flexibles, autónomos y sean capaces de adaptarse a diferentes entornos sin problemas [18]. Todas estas ventajas hacen que éste sea un campo que ha tomado cierta importancia en los últimos años y en el que se debe seguir investigando, ya que son muchos los beneficios que se pueden conseguir.

Referencias

[1] OESTGES, Claude; CLERCKX, Bruno. *MIMO wireless communications: from Real-World Propagation to Space-Time Code Design*. Academic Press, 2007.

[2] NEGRO, Francesco, et al. On the MIMO interference channel. En: *Information Theory and Applications Workshop (ITA)*, IEEE, 2010. págs. 1-9.

[3] ANDREWS, Jeffrey G.; CHOI, Wan; HEATH, Robert W. *Overcoming interference in spatial multiplexing MIMO cellular networks*. Wireless Communications, IEEE, 2007, vol. 14, n.º 6, págs. 95-104.

[4] HUANG, Howard; PAPADIAS, Constantinos B.; VENKATESAN, Sivarama. *MIMO Communication for Cellular Networks*. Springer, 2012.

[5] KLEMA, Virginia; LAUB, Alan J. The singular value decomposition: Its computation and some applications. *IEEE Transactions on Automatic Control*, 1980, vol. 25, n.º 2, págs. 164-176.

[6] ANDERSEN, Jørgen Bach. Array gain and capacity for known random channels with multiple element arrays at both ends. *IEEE Journal on Selected Areas in Communications*, 2000, vol. 18, n.º 11, págs. 2172-2178.

[7] DAHL, Tobias; CHRISTOPHERSEN, Nils; GESBERT, David. Blind MIMO eigenmode transmission based on the algebraic power method. *IEEE Transactions on Signal Processing,* 2004, vol. 52, n.º 9, págs. 2424-2431.

[8] JAFAR, Syed A. *Interference Alignment: A New Look at Signal Dimensions in a Communication Network*. Now Publishers Inc, 2010, vol. 7, n.º 1.

[9] LAMEIRO, Cristian, et al. *Experimental Evaluation of Interference Alignment for Broadband WLAN Systems*, 2013. Disponible en: http://arxiv.org/abs/1309.4355

[10] CORTES, Corinna; VAPNIK, Vladimir. Support-vector networks. *Machine learning*, 1995, vol. 20, n.º 3, págs. 273-297.

[11] BURGES, Christopher JC. A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 1998, vol. 2, n.º 2, págs. 121-167.

[12] BEN-HUR, Asa; WESTON, Jason. A user's guide to support vector machines. En: *Data mining techniques for the life sciences*. Humana Press, 2010. págs. 223-239.

[13] HSU, Chih-Wei; LIN, Chih-Jen. A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks,* 2002, vol. 13, n.º 2, págs. 415-425.

[14] MINISTERIO DE CIENCIA E INNOVACIÓN. [sitio web]. 2008. *The COMONSENS Multiuser MIMO Testbed*. [Consulta: 23 Febrero 2014]. Disponible en: http://www.comonsens.org/index.php?name=demonstrators

[15] SILVERMAN, Bernard W. *Density estimation for statistics and data analysis*. Londres: CRC press, 1986.

[16] SCHULDT, Christian; LAPTEV, Ivan; CAPUTO, Barbara. Recognizing human actions: a local SVM approach. En: *Proceedings of the 17th International Conference on Pattern Recognition (ICPR)*, IEEE, 2004, vol. 3, págs. 32-36.

[17] WANG, Lipo. *Support Vector Machines: theory and applications*. Springer, 2005.

[18] CLANCY, Charles, et al. Applications of machine learning to cognitive radio networks. *Wireless Communications*, *IEEE*, 2007, vol. 14, n.º 4, págs. 47-52.

Índice de figuras y tablas

Figura 0.1: Modelo general del canal de interferencia MIMO, en el que hay K usuarios transmitiendo, equipados con N antenas cada uno, y K usuarios recibiendo, equipados a su vez con M antenas. Con líneas discontinuas se muestran los canales interferentes, mientras que con líneas continuas se hace referencia a los canales directos.

Figura 0.2: Modelo simplificado de la función que el ente central tiene como controlador de las estrategias que los usuarios deben aplicar en función de las medidas de canal que recibe.

Figura 0.3: Modelo a nivel de bloques del proceso seguido desde la obtención de las medidas de canal hasta la elección de la estrategia a utilizar. También se muestra quién es el encargado de realizar cada una de las tareas a lo largo del proceso.

Figura 1.1: Ejemplo general del canal de interferencia MIMO, en el que K usuarios, equipados con N antenas, transmiten simultáneamente, provocando la presencia de canales interferentes (líneas discontinuas) que afectan a los K-1 nodos receptores con los que no pretenden comunicarse. También se muestran los canales directos (líneas continuas) y los nodos receptores provistos de M antenas.

Figura 1.2: Esquema general de la precodificación y decodificación, basadas en la SVD, de la señal transmitida entre una pareja de nodos TX y RX.

Figura 1.3: División del canal MIMO **H** en varios SISO independientes gracias a la aplicación de la SVD.

Figura 1.4: Esquema simplificado del proceso de decodificación sucesiva que se lleva a cabo en la estrategia de transmisión *successive decoding* en el canal de interferencia MIMO.

Figura 1.5: Ejemplo de la alineación de interferencias llevada a cabo por la estrategia IA en un escenario general de canal de interferencia MIMO, en el que hay K parejas de nodos transmisor-receptor.

Figura 2.1: Ejemplo representativo de la fase de entrenamiento de la SVM, en el que se muestra la creación del hiperplano de separación y la elección de los vectores soporte.

Figura 2.2: Ejemplo de la fase de clasificación de los patrones del conjunto de test de la SVM.

Figura 3.1: Escenario representativo del canal de interferencia MIMO $(2x2,d)^3$ sobre el que se han realizado las medidas experimentales, donde las líneas rayadas hacen referencia a los enlaces interferentes y las continuas a los enlaces directos.

Figura 3.2: Estructura de la trama a nivel físico definida por el estándar IEEE 802.11a/g [9].

Figura 3.3: Estructura simplificada de la trama a nivel físico definida por el estándar IEEE 802.11a/g y las modificaciones introducidas para su envío por cada antena en los nodos TX [9].

Figura 3.4: Ejemplo de los canales existentes para cada subportadora en la transmisión OFDM utilizada en las medidas experimentales. Las gráficas de la diagonal principal se corresponden con enlaces directos, mientras que el resto muestran enlaces interferentes. Cada línea de color hace referencia al canal que hay entre la pareja formada por una antena del nodo TX y una del nodo RX, mostrándose así en cada gráfica las 4 posibles combinaciones que existen en cada enlace.

Figura 3.5: Representación simplificada a un único nodo RX del escenario tratado en este proyecto, en la que se observa que los nodos interferentes se encuentran a diferentes distancias, y por lo tanto, la SIR asociada variará en función de su posición.

Figura 3.6: Representación de la parte real de las señales recibidas simultáneamente por los nodos RX (filas), procedentes de cada nodo TX (columnas). Debido al esquema de transmisión llevado a cabo, en color rojo, naranja y magenta se encuentran las tramas con las que los nodos RX_1, RX_2 y RX_3 deben quedarse, respectivamente. Además en azul y verde se puede apreciar la multiplexación temporal tratada en el Apartado 3.4, distinguiendo claramente la información que fue enviada por cada antena. En este ejemplo, los valores de SIR_1 y SIR_2 utilizados son 3 y 10 dB, respectivamente.

Figura 4.1: Evolución del *sum rate* que los usuarios del canal de interferencia MIMO $(2x2,d)^3$ consiguen para cada una de las estrategias de transmisión planteadas, a lo largo de 640 realizaciones de canal independientes. También se muestra la organización de las realizaciones de canal, indicando a qué situación de SIR se corresponden.

Figura 4.2: Evolución del error cometido en la clasificación para cada una de las dimensiones estudiadas, respecto al número de patrones de entrenamiento utilizados. Asimismo se puede observar el intervalo de confianza en el que se encuentran los resultados y el punto de trabajo elegido en este proyecto (12000 patrones de entrenamiento).

Figura 4.3: Evolución del total de los vectores soporte utilizados por la SVM para todas las dimensiones estudiadas, respecto al número de patrones de entrenamiento utilizados. Asimismo, se puede observar el punto de trabajo elegido en este proyecto (12000 patrones de entrenamiento).

Figura 4.4: Evolución del gasto computacional en la fase de entrenamiento de la SVM para todas las dimensiones estudiadas, respecto al número de patrones de entrenamiento utilizados. Asimismo, se puede observar el punto de trabajo elegido en este proyecto (12000 patrones de entrenamiento).

Figura 4.5: Esquema detallado del clasificador híbrido propuesto, en el que se indican los pasos a seguir desde la obtención de las medidas de canal hasta la elección de la estrategia de transmisión que deben aplicar los usuarios.

Figura 5.1: Esquema general, a nivel de bloques, del proceso seguido durante el proyecto hasta la elección final de la estrategia a seguir por los usuarios.

Tabla 4.1: Ejemplo representativo de las matrices de confusión obtenidas para las distintas dimensiones de datos de entrada estudiadas. Junto a cada matriz aparecen los parámetros g y C correspondientes a cada clase. El número de patrones de entrenamiento y test utilizados en cada conjunto son 12000 y 20000, respectivamente.

Tabla 4.2: Comparativa de las probabilidades de acierto obtenidas y promediadas a lo largo de 20 conjuntos independientes, para las diferentes estrategias de transmisión y dimensiones de los patrones de entrada estudiadas. El número de patrones de entrenamiento y test utilizados en cada conjunto son 12000 y 20000, respectivamente.

Tabla 4.3: Comparativa entre las probabilidades de acierto promediadas a lo largo de 20 conjuntos independientes para los patrones de entrada de entrada de 9 y 9+3 dimensiones, donde éstos últimos se diferencian de los primeros en que incluyen 3 dimensiones correspondientes a las potencias de ruido estimadas en los enlaces directos. El número de patrones de entrenamiento y test utilizados en cada conjunto son 12000 y 20000, respectivamente.

Tabla 4.4: Valores de g y C utilizados en el entrenamiento y clasificación de los patrones de entrada de dimensión 9+3.