



Universidad de Valladolid

Detección de defectos en tiempo real en una línea de
fabricación de tableros mediante técnicas de reconocimiento
de patrones

Trabajo de Fin de Grado

Grado de Ingeniería Informática

Mención Computación

Universidad de Valladolid

Autor: Alejandro Rodríguez Collado

Tutores: M^a Aránzazu Simón Hurtado y Carlos Enrique Vivaracho Pascual

Resumen

Las técnicas de análisis de datos han ido introduciéndose en el mundo de la factorías dando lugar a la Industria 4.0. En el caso del grupo Sonae Arauco diversos dispositivos les han permitido ser galardonados con premios por innovación tecnológica. Uno de sus sistemas es el “Smart Eyes”, un sistema de detección de imperfecciones en los tableros producidos con filtros de imágenes.

Este proyecto tiene como objetivo crear un sistema de detección de estas imperfecciones empleando técnicas de análisis de datos y aprendizaje automático. Este proyecto es un Trabajo de Fin de Grado del Programa de Estudio Conjuntos INDat - Ingeniería Informática + Estadística. Por lo tanto constará de dos memorias, una por grado. Esta es la memoria de Ingeniería Informática, y consta de las siguientes partes.

Una primera parte describirá el problema en su conjunto así como los datos obtenidos por parte de la empresa para estudiar el problema. Esta información estará acompañada de una descripción de los antecedentes al desarrollo de este proyecto.

En la segunda parte del proyecto se explicarán los procedimientos de tratamiento de imágenes empleados en la actualidad por la empresa así como nuestro algoritmo propio para el filtrado.

La tercera parte consistirá en el empleo de distintos tipos de clasificadores, principalmente regresión logística, redes neuronales y Support Vector Machines. Esta parte aparecerá desarrollada de forma exclusiva en la memoria del grado en Ingeniería Informática y tendrá su contra-parte en la memoria del TFG de Estadística sobre el uso de clasificadores relacionados con análisis discriminante y árboles de decisión.

La cuarta parte analizará los resultados obtenidos con cada uno de los clasificadores en esta memoria. De esta forma, podremos conocer qué metodología ha dado lugar a resultados mejores. El rendimiento de cada clasificador aparecerá reflejado en la memoria en la cual se haya explicado previamente el funcionamiento del clasificador.

Un epílogo servirá para exponer las conclusiones sacadas relacionadas con la consecución de los objetivos marcados así como para desglosar el posible trabajo futuro a realizar.

Abstract

The data analysis techniques have been gradually introduced in the world of factories, giving birth to the 4.0 Industry. Sonae Arauco has developed various devices that have allowed them to be multiple times awarded thanks to his technical innovation. They developed “Smart Eyes”, an imperfection-detecting system to be used in their board production line that works using filtering.

The goal of this project is to create an imperfection-detecting system that uses data analysis techniques and Machine Learning. This End-of-Degree Project is of a double degree (INDat – double degree in Computer Engineering and Statistics), so it consists of two memories, one per degree. This is the memory corresponding to Computer Engineer degree and it consists of several parts.

The first part will describe the general state of the problem as well as the data provided by the company. This information will be accompanied by a description of the antecedents of the Project.

In the second part of the Project the image treatment procedures will be explained: both the system currently working in Tradema as well as our own algorithm to filter the images.

The third part will describe different classifiers as well as its results. The classifiers appearing in this part will be related to logistic regression, neural networks and support vector machines. In the Statistics End-of-Degree Project memory, you can find classifiers related to discriminant analysis and decision trees.

The fourth part will analyze the obtained results of each classifier. This will allow us to know what has been the method that has obtained the best results. The performance of each classifier will be written on the memory that has previously explained the theory behind the classifier.

The epilogue will serve to explain the observed conclusions related to the achievement of proposed goals as well as break down the possible future work.

Agradecimientos

Todo el trabajo y dedicación que han hecho falta para el desarrollo de este proyecto son fruto del apoyo continuo de personas que han permanecido a mi lado desde el comienzo del mismo.

En primer lugar, querría agradecer la ayuda continua, atenta, sensata y paciente de mis tutores Arancha, Carlos y Miguel. No hubiera sido posible finalizar este trabajo sin vuestra guía y apoyo que, por otro lado, me ha brindado la oportunidad de aprender enormemente de vuestro profundo conocimiento en las materias que hemos tratado.

Muchas gracias a mis padres, Belén y José, por vuestro cariño y ayuda en el recorrido que ha sido el desarrollo del proyecto. Porque sé que, aún no entendiendo en profundidad los detalles de mi TFG, os lo habéis leído y ojeado en más de una ocasión.

Querría agradecer también el apoyo que me ha dado Alfon. Buena compañía ha sido el mejor remedio a tantos momentos en los que, al dejar de trabajar en el proyecto, me desazonaba al pensar en la larga lista de quehaceres.

Por último y no por ello menos importante me gustaría dar las gracias a mi hermana Lucía, abuelo Jesús y abuela Julia y a mis amigos, especialmente a los miembros de Teatro Horizon. Todos me habéis ayudado de alguna forma en estos meses de trabajo.

Índice general

1. Introducción	7
1.1. Descripción del proyecto	7
1.2. Objetivos del proyecto	8
1.2.1. Objetivos específicos del Trabajo de Fin de Grado de Ingeniería Informática	8
1.3. Estructura de la memoria	9
2. Planificación temporal	11
2.1. Lista inicial de tareas del proyecto	11
2.2. Planificación inicial del proyecto	13
2.3. Estructura temporal seguida en el proyecto	15
3. Antecedentes	19
3.1. Prácticas en empresa	19
3.2. Reuniones previas al desarrollo del TFG	19
4. Descripción de los datos	21
4.1. Glosario de defectos	21
4.1.1. Defectos negros	21
4.1.2. Defectos blancos	22
4.1.3. Defectos Topográficos	22
4.2. Corpus de imágenes	24
4.2.1. Corpus I: Imágenes “defectuosas”	25
4.2.2. Corpus II: Imágenes “sin defectos”	28
4.3. Imágenes de falsos negativos de “Smart Eyes”	29
5. Tratamiento de las imágenes	31
5.1. Sistema “Smart Eyes”	31
5.1.1. Extracción de zona de interés	32
5.1.2. Tratamiento de la imagen	32
5.2. Nuestra propuesta	33
5.2.1. Extracción de zona de interés	33
5.2.2. Tratamiento de la imagen	33
5.2.3. Optimización del filtrado	34
6. Extracción de características	37
6.1. Variables extraídas	37
6.1.1. Áreas de error relativo en negro y blanco	37
6.1.2. Caracterizaciones de las distribuciones de grises	38
6.1.3. Transformada Discreta del Coseno (DCT)	39
6.2. Conjuntos de variables consideradas	40

7. Metodología	43
7.0.1. Definiciones previas	43
7.1. Sistema de referencia	47
7.2. Regresión Logística	47
7.3. Support Vector Machine (SVM)	50
7.3.1. Núcleo lineal	52
7.3.2. Núcleo polinómico	53
7.3.3. Núcleo de base radial	53
7.4. Redes Neuronales (Neural Networks)	55
7.4.1. Perceptrón multicapa	56
8. Resultados	61
8.1. Sistema “Smart Eyes”	61
8.2. Sistema de referencia	63
8.2.1. Corpus I	64
8.2.2. Corpus II	66
8.3. Regresión Logística	68
8.4. Support Vector Machine	73
8.4.1. Núcleo Lineal	74
8.4.2. Núcleo polinómico	76
8.4.3. Núcleo de base radial (RBF)	80
8.5. Redes Neuronales	86
8.5.1. Perceptrón Multicapa (MLP)	86
9. Discusión general de resultados	95
9.1. Comparativa de los modelos según AUC y EER	95
9.2. Comparativa de los modelos según precisión, especificidad y sensibilidad	100
9.3. Discusión sobre modelos	102
9.3.1. Corpus I	102
9.3.2. Corpus II	105
9.4. Discusión de relevancia de las variables	107
9.4.1. Variables relativas al filtrado	107
9.4.2. Caracterizaciones de la distribución de grises	107
9.4.3. Componentes extraídas de la DCT	108
9.5. Conclusiones	109
10. Conclusiones y trabajo futuro	111
10.1. Relación con los contenidos del grado	111
10.2. Objetivos alcanzados	111
10.3. Trabajo Futuro	112
Bibliografía	115

Capítulo 1

Introducción

1.1. Descripción del proyecto

Sonae Arauco (Figura 1.1) es una empresa internacional de comercialización de tablero de fibra de densidad media. Producen tableros que son usados para todo tipo de utilidades, desde los tableros que conforman los muebles producidos por empresas como IKEA hasta aquellos que son empleados como protección en el transporte de productos. La empresa, además, fue de las primeras que hizo una incursión muy temprana a la industria 4.0 con sistemas inteligentes y autorregulados.



Figura 1.1: Logo de la empresa.

Cuentan con unidades de producción esparcidas por España, Portugal, Alemania y Sudáfrica que les permiten abastecer a clientes a lo largo de la geografía europea y africana, tal y como podemos observar en la Figura 1.2. A mayores, una planta en Canadá provee de tableros a los consumidores norteamericanos y sudamericanos [1].

La planta de producción Tradema de Valladolid, antigua planta de Tafisa, es una de las pioneras en la implantación de la industria inteligente dentro de Sonae Arauco. Adaptar su proceso de producción en tiempo real a los resultados de los análisis de datos de los parametros de fabricación les ha permitido ser galardonados en varias ocasiones con distinciones como el “Premio mejor iniciativa empresarial Big Data de España” de Telefónica y Synergic Partners en el año 2016 [2].

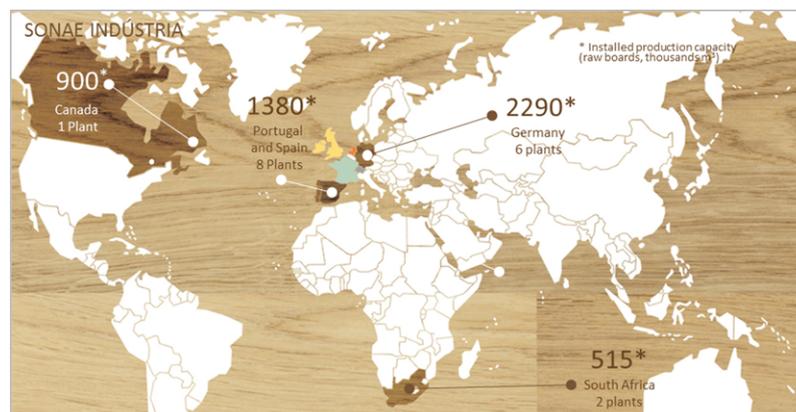


Figura 1.2: Líneas de producción del grupo.

Este proyecto surge como evolución natural a las prácticas de empresa que desarrollé allí. Aprovechando el conocimiento adquirido me pareció interesante intentar crear una evolución pareja a su desarrollo de sistemas inteligentes para su sistema “Smart Eyes”.

“Smart Eyes” se trata de una herramienta de control de calidad de las imperfecciones superficiales de los tableros creada en el año 2014 por la empresa ISDN Group. Se basa en la aplicación de filtros a las imágenes captadas por unas cámaras situadas en la línea de producción. El sistema funciona bien, aunque admiten que haría falta dedicar cierto tiempo a refinarlo. Sigue siendo necesario que un operario revise los tableros y el sistema a veces capta demasiados tableros en buen estado como defectuosos. En este sentido, también es relevante comentar que no se ha realizado un estudio objetivo del rendimiento de este sistema, por lo tanto, no se conoce su fiabilidad real.

El objetivo de este proyecto es diseñar un sistema de detección de defectos en los tableros siguiendo la filosofía más reciente en tableros Tradema: el uso del aprendizaje automático y el análisis de datos. Es, por lo tanto, una excelente ocasión para crear un proyecto que aúne lo aprendido a lo largo del doble grado así como conocimientos adquiridos a lo largo del periodo de prácticas en empresa.

Este trabajo constará de dos memorias, una correspondiente al Trabajo de Fin de Grado de Ingeniería Informática y otra del grado de Estadística [3]. Para una comprensión clara y completa del proyecto, es necesaria la lectura de ambos textos.

1.2. Objetivos del proyecto

El objetivo general del proyecto es crear un sistema de detección de defectos superficiales en los tableros con las imágenes obtenidas por las cámaras de la línea de producción de Tradema aplicando técnicas de tratamiento de imágenes, análisis de datos y Machine Learning. Se trabajará con dos Corpus de imágenes de diferentes características de los que se extraerán dos juegos diferentes de variables que servirán de entrada a los clasificadores.

1.2.1. Objetivos específicos del Trabajo de Fin de Grado de Ingeniería Informática

- Obtener un corpus o base de datos de imágenes adecuada para el trabajo a realizar.
- Realización de un planificación temporal aproximada del desarrollo del proyecto.
- Clasificar, mediante visualización, los datos obtenidos según las diferentes clases a reconocer.
- Analizar y depurar los datos obtenidos.
- Analizar el funcionamiento y rendimiento del sistema actualmente empleado por la empresa (“Smart Eyes”).
- Realizar un preprocesamiento de las imágenes (filtrado) de manera que se resalten los fallos a detectar.
- Extraer características de la imagen procesada para ser usadas como entrada a los clasificadores.
- Emplear análisis supervisado para clasificar la imagen, usando procedimientos como:
 - Regresión logística.
 - Support Vector Machines.
 - Redes Neuronales.
- Análisis posterior y extracción de conclusiones relevantes en base a la discusión general de los modelos de análisis supervisado.

1.3. Estructura de la memoria

Los documentos que recogen el desarrollo del proyecto son dos memorias, una correspondiente a la parte de Trabajo de Fin de Grado de Ingeniería Informática y otra correspondiente al Grado en Estadística [3]. La Tabla 1.1 muestra cada uno de los capítulos de las memoria de Trabajo de Fin de Grado de ingeniería informática.

Para la comprensión completa del desarrollo del proyecto será necesario la lectura de las partes comunes de esta memoria así como los capítulos de metodología, resultados, discusión de resultados y conclusiones exclusivos de la memoria de estadística.

Memoria Ingeniería Informática	
Introducción	El presente capítulo sirve de preludeo a la memoria del proyecto. Detalla objetivos y estructura.
Planificación temporal	Tareas a desarrollar en el proyecto y planificación temporal de estas inicial y seguida.
Antecedentes	En esta primera parte aparece sintetizada toda la obtención de información y recursos previa al comienzo práctico del proyecto.
Descripción de los datos	Análisis de las características de las imágenes entregadas por parte de la empresa. En este capítulo también se ha desarrollado un glosario de defectos presentes en las imágenes entregadas.
Tratamiento de las imágenes	Estudio del sistema de filtrado en funcionamiento en la empresa así como desarrollo de una propuesta propia más ligera para el filtrado de imágenes.
Extracción de características	Descripción de las variables a extraer de las imágenes en bruto y filtradas que servirán para conformar la entrada de los clasificadores.
Metodología	Desarrollo de los clasificadores usados para la discriminación de imágenes con defectos con respecto a las que carecen de ellos. En esta memoria se han creado modelos de regresión logística, de Support Vector Machine y redes neuronales.
Resultados	Resultados obtenidos a partir de los modelos desarrollados en el capítulo de metodología de la memoria de Ingeniería Informática.
Discusión general de resultados	Discusión global de los resultados obtenidos en ambas memorias relativa metodologías, variables, modelo óptimo,...
Conclusiones y trabajo futuro	Exposición de las conclusiones extraídas a partir de los resultados así como el desarrollo de posibles líneas de trabajo futuras.
Bibliografía	

Tabla 1.1: Estructura general del proyecto dividida según el contenido que aparece en la memoria de ingeniería informática.

Capítulo 2

Planificación temporal

Este capítulo establece las tareas a completar con el desarrollo del proyecto. Aquí se desarrolla la planificación temporal inicial y la seguida.

2.1. Lista inicial de tareas del proyecto

La Tabla 2.1 especifica las tareas generales necesarias para el desarrollo de ambos Trabajos de Fin de Grado.

Tareas comunes a ambos Trabajos de Fin de Grado		
Tarea	Horas	Descripción
I. Información Previa	25	Esta tarea incluye las primeras aproximaciones al proyecto en forma de la puesta en contacto con los tutores así como el personal responsable de la empresa. Con diversas reuniones se puso en conocimiento a los implicados de los objetivos marcados para el proyecto. En esta etapa se obtiene el Corpus I de imágenes de tableros.
II. Corpus I: etiquetado	40	Etiquetado manual de las imágenes del Corpus I en imágenes sin defectos e imágenes con defectos negros, blancos o topográficos. Posteriormente se contrastará con un equipo de expertos de la empresa si el etiquetado se había hecho correctamente.
III. Corpus II: etiquetado	20	Obtención de las imágenes del Corpus II. Etiquetado manual de éstas en imágenes sin defectos e imágenes con defectos negros, blancos o topográficos. Posteriormente se contrastará con un equipo de expertos de la empresa si el etiquetado se había hecho correctamente.
IV. Análisis de datos del Corpus I y II	15	Análisis y estudio estadístico de las características extraídas del Corpus I y II para conocer en profundidad su naturaleza. Definición del glosario de defectos existentes dentro del conjunto de imágenes entregado por la empresa.
V. Sistema de referencia	5	Definición de un sistema discriminatorio de imágenes con defectos de las que carecen de ellos en base al área de error relativa de la imagen que servirá de referencia para la comparación de los modelos de análisis de datos posteriores.
VI. Actualización y revisión de los documentos I	20	Análisis de las memorias del proyecto para la modificación de la documentación así como la corrección de posibles erratas en las mismas después de la definición de los clasificadores básicos. Actualización de la planificación con las posibles desviaciones dadas en las tareas previas.
VII. Conclusiones	20	Estudio y comparativa de los modelos en base a los resultados obtenidos a lo largo del desarrollo del proyecto. Estudio de variables más relevantes de forma global. Definición de conclusiones obtenidas en base al desarrollo de los sistemas y trabajo futuro a realizar.
VIII. Actualización y revisión de los documentos II	20	Análisis de las memorias del proyecto para la modificación de la documentación así como la corrección de posibles erratas en las mismas después de la definición de todos los modelos a estudiar. Actualización de la planificación con las posibles desviaciones dadas en las tareas previas.

Tabla 2.1: Listado de tareas generales para ambos Trabajos de Fin de Grado.

Las Tablas 2.2 y 2.3 enumeran las tareas concretas necesarias para la finalización de los Trabajos de Fin de Grado de Ingeniería Informática y Estadística respectivamente.

Tareas específicas al Trabajo de Fin de Grado de Ingeniería Informática		
Tarea	Horas	Descripción
IX. Procesamiento de imágenes	40	Aprendizaje de las funciones de Matlab empleadas para el procesamiento de imágenes. Elección de la secuencia de filtros adecuados para aplicar a las imágenes con el fin de destacar los defectos presentes en estas.
X. Optimización del filtrado	10	Optimización de los parámetros implicados en el filtrado definido previamente en base a un barrido de valores con un criterio de selección adecuado.
XI. Extracción de características	15	Extracción de variables de posible relevancia en la discriminación de imágenes con defectos de las que carecen de ellos. Creación de diferentes juegos de variables que servirán posteriormente como entrada a los modelos de análisis supervisado.
XII. Regresión Logística	20	Obtención de los modelos de regresión logística optimizando el número de variables con los datos del Corpus I y II. Estudio de resultados relativos a la capacidad clasificadora de los modelos en función del uso de norma L1 o L2.
XIII. Support Vector Machines	30	Uso de modelos de máquina vector soporte con diferentes núcleos para la creación de sistemas capaces de discriminar adecuadamente las imágenes de los dos Corpus con defectos de las que carecen de ellos. Estudio del número de variables óptimo y de resultados relativos a la capacidad clasificadora de los modelos.
XIV. Redes Neuronales	20	Definición de la arquitectura y estructura de los modelos de perceptrón multicapa con mejor capacidad para distinguir imágenes con defectos de las que carecen de ellos con los datos del Corpus I y II. Estudio de resultados relativos a la capacidad discriminadora de los modelos.
XV. Redes Neuronales II	30	Aplicación de redes neuronales recurrentes a los datos extraídos del Corpus I y II. Estudio de arquitectura y estructura de las redes óptimas para el problema. Estudio de los resultados estimados para medir la capacidad clasificadora de los modelos creados.

Tabla 2.2: Listado de tareas específicas del Trabajo de Fin de Grado de Ingeniería Informática.

Tareas específicas al Trabajo de Fin de Grado de Estadística		
Tarea	Horas	Descripción
XVI. Análisis Discriminante	30	Ajuste de los modelos de discriminante lineal y cuadrático para los atributos extraídos de los Corpus I y II de imágenes. Estudio del subconjunto de variables que den lugar al clasificador de resultado óptimo. Estudio de resultados relativos a la capacidad clasificadora de los modelos.
XVII. Árboles de decisión I	20	Inducción de los modelos de árboles de decisión estilo C4.5 con las características extraídas de las imágenes del Corpus I y II. Estudio de resultados relativos a la capacidad clasificadora del modelo así como de las variables que emplea el modelo para discriminar.
XVIII. Árboles de decisión II	30	Modelos de agregación de árboles para discriminar imágenes con defectos de aquellas carentes de ellos. Bagging (Random Forest) y Boosting (Adaptive Boosting) aplicados a los datos extraídos de los Corpus I y II. Estudio de relevancia de las variables así como de los resultados relativos a la capacidad discriminadora del modelo.

Tabla 2.3: Listado de tareas específicas del Trabajo de Fin de Grado de Estadística.

2.2. Planificación inicial del proyecto

La planificación temporal seguida ha sido secuencial. La Figura 2.2 refleja una Tabla con el planteamiento temporal del proyecto a fecha de 1 de Noviembre del 2017. La Figura 2.1 muestra el diagrama de Gant asociado a esta planificación.

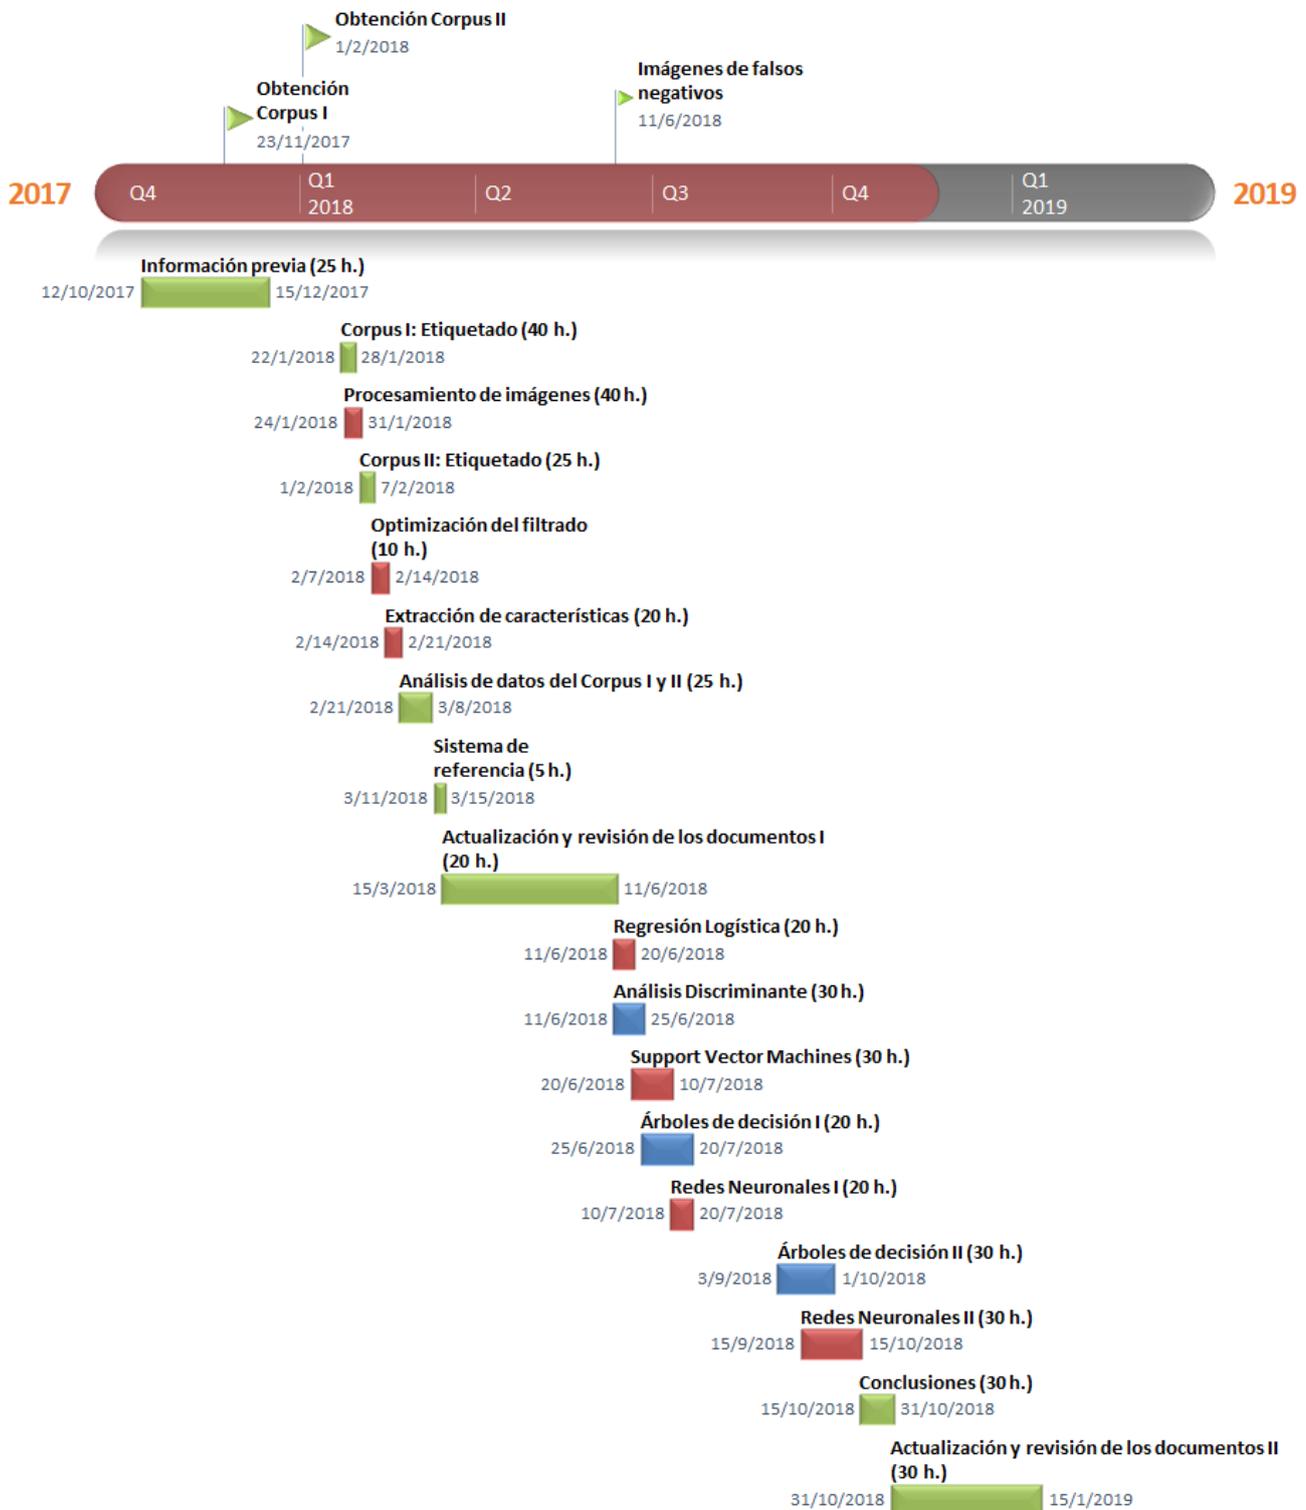


Figura 2.1: Diagrama de Gant con la planificación inicial del proyecto.

Hitos principales			
Fecha	Descripción		
11/23/2017	Obtención Corpus I		
01/02/2018	Obtención Corpus II		
06/11/2018	Imágenes de falsos negativos		

Tareas			
Duración (en días)	Fecha de inicio	Fecha de fin	Descripción
65	10/12/2017	12/15/2017	Información previa (25 h.)
7	01/22/2018	01/28/2018	Corpus I: Etiquetado (40 h.)
8	01/24/2018	01/31/2018	Procesamiento de imágenes (40 h.)
7	02/01/2018	02/07/2018	Corpus II: Etiquetado (25 h.)
8	02/07/2018	02/14/2018	Optimización del filtrado (10 h.)
8	02/14/2018	02/21/2018	Extracción de características (20 h.)
16	02/21/2018	03/08/2018	Análisis de datos del Corpus I y II (25 h.)
5	03/11/2018	03/15/2018	Sistema de referencia (5 h.)
89	03/15/2018	06/11/2018	Actualización y revisión de los documentos I (20 h.)
10	06/11/2018	06/20/2018	Regresión Logística (20 h.)
15	06/11/2018	06/25/2018	Análisis Discriminante (30 h.)
21	06/20/2018	07/10/2018	Support Vector Machines (30 h.)
26	06/25/2018	07/20/2018	Árboles de decisión I (20 h.)
11	07/10/2018	07/20/2018	Redes Neuronales I (20 h.)
29	09/03/2018	10/01/2018	Árboles de decisión II (30 h.)
31	09/15/2018	10/15/2018	Redes Neuronales II (30 h.)
17	10/15/2018	10/31/2018	Conclusiones (30 h.)
77	10/31/2018	01/15/2019	Actualización y revisión de los documentos II (30 h.)

Figura 2.2: Tabla que especifica la planificación inicial del proyecto.

Este planteamiento se ha hecho teniendo en cuenta que la disposición de tiempo no es homogénea a lo largo del año académico. Por ejemplo, se ha aprovechado con una alta dedicación horaria los periodos entre fin de exámenes y el comienzo del siguiente cuatrimestre. Las tareas desarrolladas en paralelo con el periodo de un cuatrimestre se han planificado de tal forma que con el transcurso del cuatrimestre la dedicación horaria en el proyecto fuese menor. Teniendo en cuenta esto último se han relegado tareas de revisión de documentos a los periodos con más actividad de los cuatrimestres.

2.3. Estructura temporal seguida en el proyecto

La Figura 2.4 refleja una Tabla con el planteamiento temporal del proyecto seguido tras la finalización del mismo. La Figura 2.1 muestra el diagrama de Gant asociado a esta planificación.

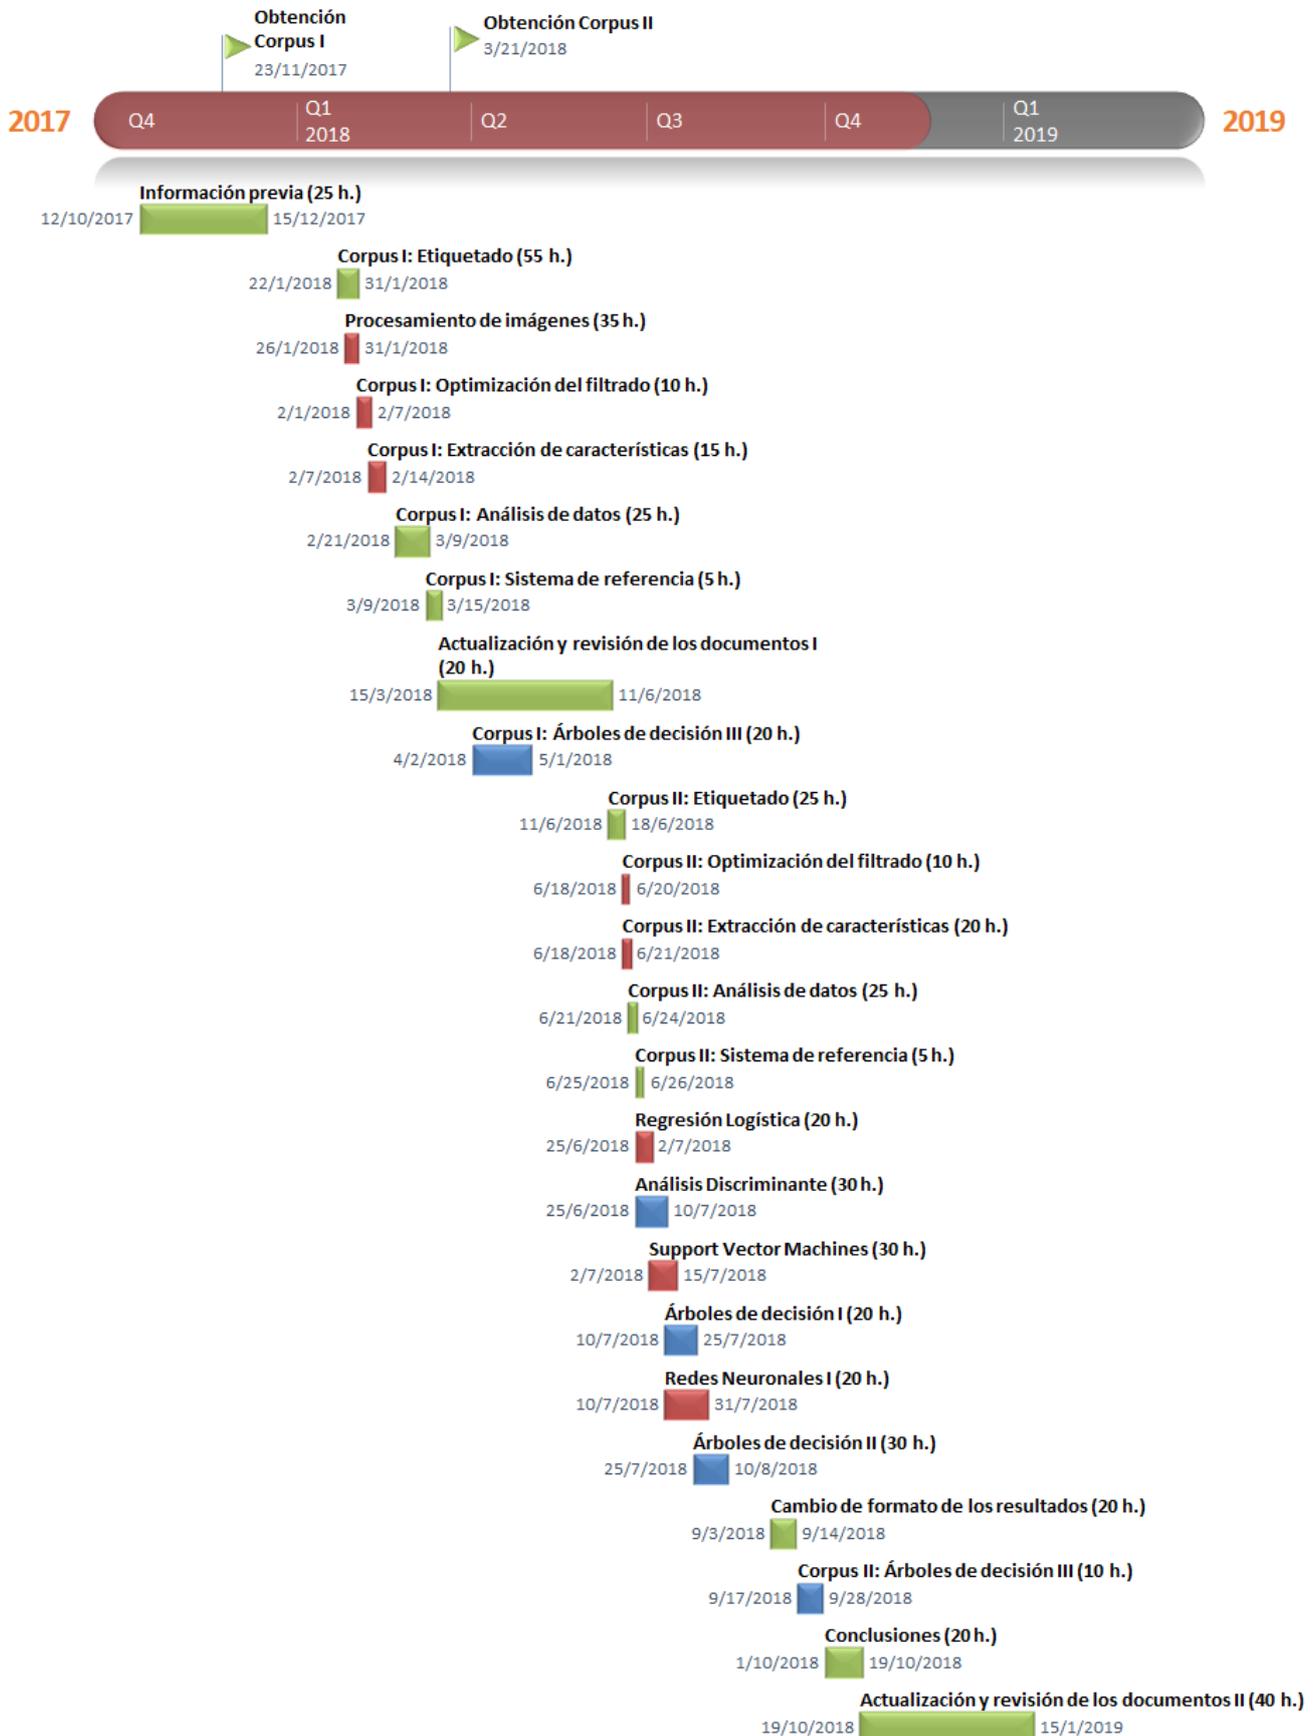


Figura 2.3: Diagrama de Gant con la planificación seguida en el proyecto.

Hitos principales			
Fecha	Descripción		
11/23/2017	Obtención Corpus I		
03/21/2018	Obtención Corpus II		

Tareas			
Duración (en días)	Fecha de inicio	Fecha de fin	Descripción
65	10/12/2017	12/15/2017	Información previa (25 h.)
10	01/22/2018	01/31/2018	Corpus I: Etiquetado (55 h.)
6	01/26/2018	01/31/2018	Procesamiento de imágenes (35 h.)
7	02/01/2018	02/07/2018	Corpus I: Optimización del filtrado (10 h.)
8	02/07/2018	02/14/2018	Corpus I: Extracción de características (15 h.)
17	02/21/2018	03/09/2018	Corpus I: Análisis de datos (25 h.)
7	03/09/2018	03/15/2018	Corpus I: Sistema de referencia (5 h.)
89	03/15/2018	06/11/2018	Actualización y revisión de los documentos I (20 h.)
30	04/02/2018	05/01/2018	Corpus I: Árboles de decisión III (20 h.)
8	06/11/2018	06/18/2018	Corpus II: Etiquetado (25 h.)
3	06/18/2018	06/20/2018	Corpus II: Optimización del filtrado (10 h.)
4	06/18/2018	06/21/2018	Corpus II: Extracción de características (20 h.)
4	06/21/2018	06/24/2018	Corpus II: Análisis de datos (25 h.)
2	06/25/2018	06/26/2018	Corpus II: Sistema de referencia (5 h.)
8	06/25/2018	07/02/2018	Regresión Logística (20 h.)
16	06/25/2018	07/10/2018	Análisis Discriminante (30 h.)
14	07/02/2018	07/15/2018	Support Vector Machines (30 h.)
16	07/10/2018	07/25/2018	Árboles de decisión I (20 h.)
22	07/10/2018	07/31/2018	Redes Neuronales I (20 h.)
17	07/25/2018	08/10/2018	Árboles de decisión II (30 h.)
12	09/03/2018	09/14/2018	Cambio de formato de los resultados (20 h.)
12	09/17/2018	09/28/2018	Corpus II: Árboles de decisión III (10 h.)
19	10/01/2018	10/19/2018	Conclusiones (20 h.)
89	10/19/2018	01/15/2019	Actualización y revisión de los documentos II (40 h.)

Figura 2.4: Tabla que especifica la planificación seguida en el proyecto.

Tal y como se puede observar, existen diversas variaciones sobre la planificación inicial del proyecto. Las principales fueron:

- Se han añadido las siguientes tareas:
- La obtención tardía del Corpus II supuso un retraso generalizado en las tareas del proyecto. Inicialmente se obtuvo una semana después de lo planificado. La observación detenida de las imágenes puso en evidencia diversos problemas relacionados con la captación de estas. Por ello fue preciso solicitar a la empresa implicada que grabase un nuevo juego de imágenes. Esto supuso retrasar la mayoría de hitos a cumplir desde el mes de febrero.
- El retraso en la entrega del Corpus II ocasiono que las siguientes tareas se tuviesen que desglosar en dos subtareas al no haberse podido realizar estas simultáneamente para el Corpus I y II. Las siguientes tareas se

Tareas añadidas			
ID	Tarea	Horas	Descripción
XIX.	Corpus I: Árboles de decisión III	30	El desarrollo de un trabajo relacionado con la asignatura ‘Métodos Estadísticos de Computación Intensiva’ permitió el desarrollo de un tipo de Boosting con naturaleza bayesiana de árboles de decisión: los Bayesian Additive Regression Trees (BART). Aplicación sobre Corpus I.
XX.	Cambio de Formato de los resultados	20	Una vez obtenidos los resultados provisionales de diversos procedimientos, se optó por incluir nuevos resultados en las memorias para que la comparativa desde más criterios se pudiese realizar.
XXI.	Corpus II: Árboles de decisión III	30	Desarrollo de los BART con los datos obtenidos a partir del Corpus II

tuvieron que subdividir en dos, una relacionada con el Corpus I y otra con el Corpus II:

- IV. Análisis de datos del Corpus I y II
 - V. Sistema de referencia
 - X. Optimización del filtrado
 - XI. Extracción de características .
- Variaciones con respecto al tiempo estimado:
- II. Corpus I: etiquetado (55 horas en vez de 40). El etiquetado manual supuso más tiempo debido a la dificultad existente en la clasificación de alguna de las imágenes.
 - IV. Análisis de datos del Corpus I y II (30 horas en vez de 15). Se debe principalmente a la necesidad de haber analizado por separado el Corpus I y II y a la abstracta interpretabilidad de las características extraídas.
 - Sistema de referencia (15 horas en vez de 5). Una etapa de recuerdo del manejo de Python combinada con la necesidad de establecer dos sistemas de referencia (uno por Corpus) hizo que esta tarea requiriese más tiempo.
 - VIII. Actualización y revisión de los documentos II (40 horas en vez de 20). El aumento de horas se debió principalmente a una mayor cantidad de contenido a modificar.
 - IX. Procesamiento de imágenes (35 horas en vez de 40). La primera puesta en contacto con las funciones de Matlab de filtrado de imágenes fue más sencilla de lo esperado.
 - X. Optimización del filtrado (15 horas en vez de 10) y XI. Extracción de características (20 horas en vez de 15), debido a la necesidad de optimizar y estudiar las características por separado en el Corpus I y II.
- La tarea XV. Redes Neuronales II se ha suprimido por falta de tiempo.

Capítulo 3

Antecedentes

Previo al desarrollo del proyecto, cabe destacar dos periodos claves en cuanto a recopilación de información para el posterior desarrollo del mismo.

3.1. Prácticas en empresa

Desarrollé mis prácticas curriculares en empresa a lo largo del primer semestre del año 2017. Me sirvió para conocer el entorno laboral de Tradema así como diversas técnicas que emplean en sus sistemas de captación de medidas en tiempo real a lo largo de la línea de producción. Estos datos, combinados con otros que obtienen del estudio empírico de los tableros, les permiten crear diversos sistemas inteligentes que predicen y controlan otras variables significativas en el proceso de producción.

Las prácticas me permitieron profundizar y desarrollar mis conocimientos sobre metodologías como el análisis de componentes principales o el k-vecinos más próximos. Además pude usar redes neuronales de diversa índole que me posibilitaron familiarizarme con sus conceptos y metodologías.

El equipo relacionado con el Machine Learning de la empresa estaba constantemente desbordado con trabajo: había que desarrollar software concreto para adecuarse a las necesidades que iban surgiendo en la empresa. Este proceso de creación constante no les permite, en general, tener tiempo para refinar sistemas que ya funcionan relativamente bien en la empresa. Conocí entonces el sistema “Smart Eyes”, el cual llevaba en funcionamiento desde el año 2014. El equipo de análisis de datos había intentado reservar parte de su tiempo para “actualizarlo” en base a conceptos de Machine Learning. Sin embargo, debido a la carencia de tiempo y a que el sistema con un enfoque de filtros simples funciona relativamente bien hizo que la actualización no se llegara a realizar.

Cuando acabé las prácticas, me ofrecieron como proyecto futuro la actualización del sistema evolución de “Smart Eyes”. Fue así como surgió el proyecto que aquí presentamos.

3.2. Reuniones previas al desarrollo del TFG

La metodología empleada para la recogida de información previa al comienzo del proyecto fue la realización de diversas reuniones con los tutores así como entrevistas con distintos empleados de la empresa.

El día 16 de octubre visitamos las instalaciones de tableros Tradema. Conocimos de primera mano la línea de producción así como el sistema de control de calidad ya implementado en la fábrica, “Smart Eyes”. Es un sistema que siempre está en funcionamiento en segundo plano. No hace un control de calidad exhaustivo del tablero (es siempre necesaria la labor de un operario para revisar que los pedidos estén en buen estado) y, aunque parece que detecta muchas de las incidencias en los tableros, detecta también muchos en perfecto estado como defectuosos (falsos positivos).

El número de tableros que clasifica mal (tanto falsos positivos como falsos negativos) es en principio desconocido. Por lo tanto, se trata de un sistema en el que no existe ningún tipo de medida de rendimiento; sí contamos con el número de devoluciones por estar defectuoso el producto. La empresa está contenta con su funcionamiento y reconoce que existen mejoras del sistema que no se han aplicado o estudiado, principalmente por falta de tiempo.

También se mantuvieron varias conversaciones con ISND Group, empresa responsable de la creación del Software de “Smart Eyes”. Nos comentaron que el sistema hace para las imágenes por separado de cada cámara dos filtrados independientes, uno para detectar los defectos “negros” y otro para los “blancos” (apartado 4.1). También recorta puntos sin interés de la imagen y puntos ciegos de la cámaras. Las imágenes laterales se ajustan, además, al tamaño del tablero, información que proporciona el propio sistema de gestión de órdenes de producción de la fábrica. Nos facilitaron también una lista de los algoritmos empleados por el sistema.

Capítulo 4

Descripción de los datos

En este capítulo se describen los conjuntos de datos recibidos por parte de Tradema.

4.1. Glosario de defectos

Se les ha dado una nomenclatura acorde a la clasificación creada en el desarrollo del sistema “Smart Eyes” de la empresa. Existen tres tipos de defectos según su apariencia: negros, blancos y topográficos.

4.1.1. Defectos negros

Estos defectos los denominamos así por el color de su apariencia, que en general será de un tono de gris muy oscuro o negro completamente. Estos defectos constituyen cerca del 85 % de los defectos que podremos encontrar en los tableros. En este tipo de defectos, la causa de la aparición de la mancha puede ser por diversos motivos:

- Aparición de una mancha circular o elíptica de tamaño variable en la superficie del tablero, tal y como aparece en las Figuras 4.1 y 4.2. Suele deberse al derramamiento puntual de aceite de alguna de las máquinas o a resina que no ha sido previamente eliminada en el proceso de creación de la astilla para el tablero. Suponen más del 90 % de los defectos negros presentes en las muestras empleadas para el estudio del sistema.

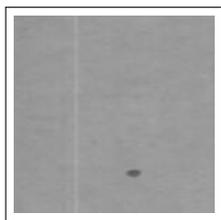


Figura 4.1: Defecto negro de tamaño pequeño.

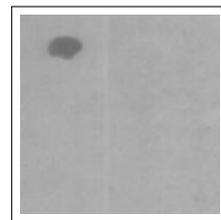


Figura 4.2: Defecto negro grande.

- A veces las manchas oscuras van acompañadas de una especie de estela o rastro. En estas imágenes, aparecerá un punto negro oscuro seguido de una raya grisácea (Figura 4.3). Estos defectos se deberán a la ceniza que sale despedida de la planta de energía de la fábrica.



Figura 4.3: Imagen de un defecto provocado por la ceniza.

- Aparición de dos figuras concéntricas, una interior de color más oscuro y otra exterior alrededor más clara. De nuevo, suelen ocasionarse por el derramamiento de aceite. Un ejemplo aparece en la Figura 4.4.

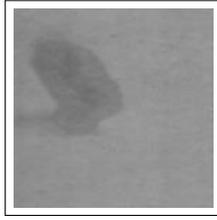


Figura 4.4: Imagen de un defecto con zonas más oscuras y más claras.

4.1.2. Defectos blancos

Estos defectos son causados por la existencia de fibras en la superficie del tablero. Toman un color completamente blanco en las imágenes. Son el defecto detectado algo por encima del 6 % de los tableros que aparecen en las muestras entregadas. Requieren de una buena iluminación presente en la toma de imágenes. Sólo en aquellas imágenes donde la luz es homogénea y adecuada se detectan con facilidad estos defectos. Al estudiar las muestras de imágenes de los Corpus hemos observado cómo en los laterales de las imágenes (zonas más iluminadas de estas) aparecen la mayoría de los defectos de este tipo. En las Figuras 4.5 y 4.6 aparecen ejemplos de este tipo de defecto.

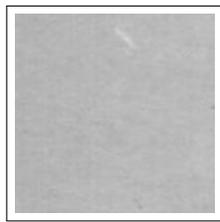


Figura 4.5: Fibra de tamaño pequeño.

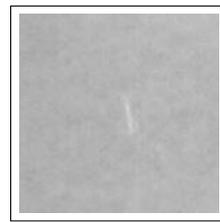


Figura 4.6: Fibra de tamaño grande.

4.1.3. Defectos Topográficos

Denominación asignada a los defectos debido a su naturaleza (con cierto contorno o relieve) que requieren de la aplicación de dos filtrados distintos en búsqueda de puntos más claros y más oscuros que el resto de la imagen. Son de naturaleza muy diversa, representando cerca del 9% de las taras halladas en las imágenes de las muestras. De acuerdo a su aspecto, podemos clasificar los defectos topográficos en diversos tipos:

4.1.3.1. Hendiduras

Presencia de golpes, mellas y surcos en la imagen de la superficie del tablero. Se suelen deber a fallos en el transporte del tablero en zonas previas a la zona de supervisión de cámaras. Es un defecto grave en el tablero así como uno de los defectos topográficos más comunes. Existen surcos que debido a que con su relieve forman contornos más oscuros serán más fácilmente detectados de forma más habitual por el filtrado en negros, como es el caso de la Figura 4.7. Otros, sin embargo, aparecen en la imagen con tonos más claros y su detección dependerá más del filtrado de blancos. La Figura 4.8 es un ejemplo de esto.

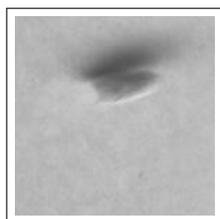


Figura 4.7: Defecto cuyo contorno es más oscuro.



Figura 4.8: Defecto de contorno más claro.

4.1.3.2. Grietas de separación y de unión

Brechas y fisuras aparecen en la superficie del tablero. Distinguimos dos tipos de grietas:

- Grietas de separación: aquellas en las que el tablero se parte en dos trozos que se van separando. Son las más comunes y dependiendo de su amplitud y longitud pueden ser más o menos difíciles de detectar. Tienen una morfología variable, tal y como podemos ver las Figuras 4.9 y 4.10.

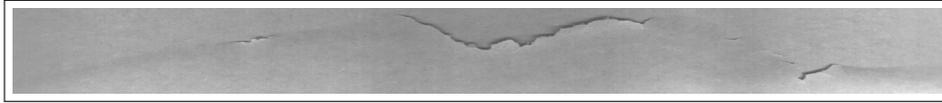


Figura 4.9: Imagen de una grieta de separación: resquebrajamiento simple.

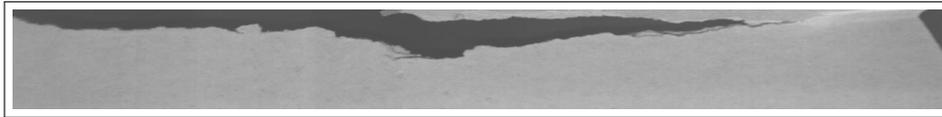


Figura 4.10: Imagen de una grieta de separación amplia.

- Grietas de unión: aquellas en la que los dos trozos del tablero se van juntando progresivamente. Son menos comunes y presentan ciertas dificultades a la hora de ser detectadas. Un ejemplo de grieta de unión lo podemos observar en la Figura 4.11.



Figura 4.11: Imagen de una grieta de unión.

4.1.3.3. Roturas

Huecos generados en el tablero. Pueden ser o laterales, correspondientes a algún defecto en la terminación del tablero en la cámara derecha o izquierda (tal y como vemos en las Figuras 4.12 y 4.13) o longitudinales en el tablero (Figura 4.14).

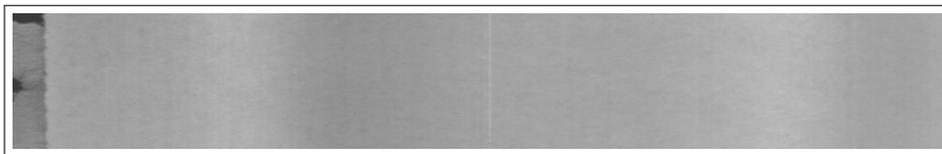


Figura 4.12: Imagen de una rotura en el lateral derecho del tablero.



Figura 4.13: Imagen de una rotura en el lateral izquierdo del tablero.



Figura 4.14: Imagen de una rotura longitudinal en el tablero.

4.1.3.4. Humedades

Gotas de agua y surcos formados por humedades presentes en el tablero. Generan diversidad de problemas, como imposibilitar el cumplimiento de especificaciones técnicas del hinchamiento del tablero. Las Figuras 4.15 y 4.16 son ejemplos de esto.

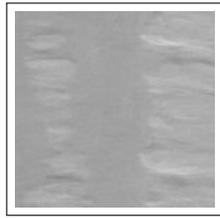


Figura 4.15: Rastro de agua en la superficie del tablero.

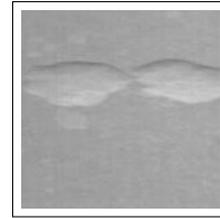


Figura 4.16: Gotas de agua en el tablero.

4.1.3.5. Bolsas de aire

Contornos en el tablero rellenos de aire creados por error en el prensado de los tableros. Son defectos de alta dificultad a detectar, ya que el gradiente de grises de la imagen que refleja la existencia de relieve es de poca amplitud. Son defectos que requieren de nuevo de una buena iluminación. En la Figura 4.17 podemos ver una bolsa de aire claramente por la diferencia de grises de la imagen. En la Figura 4.18 vemos una bolsa de aire de detección mucho más compleja.

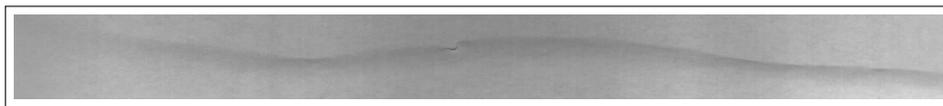


Figura 4.17: Bolsa de aire acompañada de una pequeña grieta.



Figura 4.18: Bolsa de aire cuya detección es más compleja.

4.2. Corpus de imágenes

Llamamos corpus a un conjunto cerrado de datos empleados en una investigación científica. En nuestro caso, este se compondrá de imágenes procedentes de dos fuentes de imágenes con distintas características y con ciertas diferencias en su naturaleza. La disposición de clases conjunta presente en las imágenes empleadas en el trabajo aparecen reflejadas en la Tabla 4.1:

Conjunto de imágenes empleado			
	Corpus I	Corpus II	Total
Sin defectos	709	3893	4602
Con defectos	6458	107	6565
Total	7167	4000	11167

Tabla 4.1: Distribución de observaciones en el total de imágenes empleadas.

Los defectos observados podemos desglosarlos empleando la categorización descrita en el glosario de defectos (Sección 4.1) tal y como aparece en la Tabla 4.2:

Conjunto de imágenes empleado			
Defecto	Corpus I	Corpus II	Total
Negro	5497	91	5588
Blanco	546	15	561
Topográfico: Bolsas de aire	41	0	41
Topográfico: Gotas de agua	17	0	17
Topográfico: Grietas de separación	64	0	64
Topográfico: Grietas de unión	46	0	46
Topográfico: Hendiduras	94	1	95
Topográfico: Rotura horizontal	66	0	66
Topográfico: Rotura lateral	71	0	71
Topográfico: Surcos de Agua	55	0	55
Total	6458	107	6565

Tabla 4.2: Distribución de los defectos en el conjunto total de imágenes.

La fila de totales no es como tal la suma del número de observaciones de cada tipo de defectos, ya que en ciertas imágenes están presentes más de un tipo de defecto.

A lo largo de las dos siguientes sub-secciones se describe la naturaleza de los dos corpus, detallando su obtención, composición, etc.

4.2.1. Corpus I: Imágenes “defectuosas”

Este corpus, recibido el 23 de noviembre del 2017, consta de 8754 imágenes que el sistema en funcionamiento de la empresa ha etiquetado como pertenecientes a tableros con defectos. Después de la eliminación de imágenes cuyo grabado ha sido incorrecto, el conjunto de imágenes se reducirá a 7167 imágenes. Las imágenes recibidas corresponden a distintos periodos de grabado en los que se han mantenido constantes los parámetros de la toma de datos, aunque no corresponden los datos a ningún marco de muestreo pre-planteado.

Cada imagen pertenece a una de las cuatro cámaras que graban el proceso de producción, pero no conocemos a qué cámara pertenece cada imagen. Todas las imágenes tienen la misma altura (144 píxeles) y una anchura variable. La anchura variable se debe al proceso de pre-tratamiento de las imágenes.

Cada imagen se ha recibido como una dupla, de tal modo que tenemos:

1. Imagen ‘original’: no se han aplicado aún los filtros del sistema “Smart Eyes”. Tiene un ligero pre-tratamiento en el que se eliminan las zonas correspondientes a los puntos ciegos y a las zonas sin tableros. En la Figura 4.19 se puede ver un ejemplo.
2. Imagen procesada: Imagen filtrada por el sistema. La figura 4.20 es el resultado del filtrado de la imagen correspondiente a la Figura 4.19. El proceso de filtrado de las imágenes se encuentra detallado en el apartado del sistema de “Smart Eyes” (Sección 5.1)).

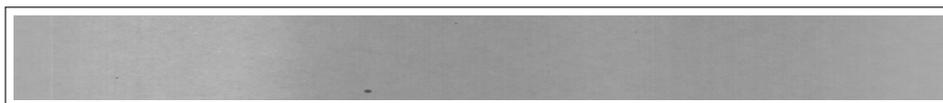


Figura 4.19: Ejemplo de imagen ‘original’ del Corpus I.



Figura 4.20: Ejemplo de imagen ‘procesada’ del Corpus I.

Como ya se ha comentado previamente en el documento, el sistema “Smart Eyes” clasifica imágenes cómo defectuosas sin serlo a veces. En una de las reuniones celebradas por los integrantes del equipo observamos cómo esto podía deberse a la creación de ruido en las imágenes filtradas, como podemos ver en la Figura 4.22 tras aplicar el filtrado a la Figura 4.21. Esto puede deberse a varios problemas. El principal, parece ser un problema de iluminación en los laterales de las imágenes, que el sistema “Smart Eyes” no está debidamente tratando. En el apartado 8.1 se muestran las medidas del rendimiento del sistema “Smart Eyes” realizadas a partir de las imágenes de este corpus.

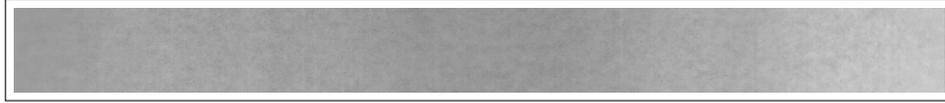


Figura 4.21: Imagen del Corpus I con problemas en la homogeneidad de la iluminación.



Figura 4.22: Imagen filtrada. Observamos el ruido a la derecha.

Del conjunto de imágenes original, no se prosiguió trabajando con 1587 imágenes sobre el total. Las imágenes en cuestión no habían sido correctamente clasificadas por el sistema. Estas imágenes se han eliminado después de consultar a la empresa. Estas imágenes no eran válidas por diversos motivos:

1. Incorrecta especificación del tamaño del tablero por parte del sistema de control de ordenes de producción de la empresa dio lugar a que la imagen no se tomase de forma correcta. En la Figura 4.19 se puede ver un ejemplo.

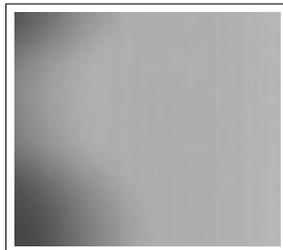


Figura 4.23: Ejemplo de imagen eliminada del estudio por errores en la toma de la imagen.

2. Grabación tomada durante una parada técnica. Una imagen estática es captada de forma repetida a lo largo del tiempo. En algunos casos las cámaras graban directamente la cinta de transporte del tablero, ya que en algunas paradas se retiran los tableros de la línea de producción. Dentro de estos casos se incluyen capturas en los que el foco de una de las cámaras está siendo limpiado, tal y cómo podemos observar en la Figura 4.24.



Figura 4.24: Imagen eliminada: la sombra indica que la cámara estaba siendo limpiada en el momento de la captura de la imagen.

3. Retirada de imágenes en las que aparece un resto de madera con forma esférica. Estos restos sueltos por encima del tablero aparecen por culpa del mal funcionamiento del aspirador después de la zona de las sierras. Están previstas mejoras en la zona en la que se aspira que harán desaparecer prácticamente por completo estos residuos, por lo que no existe interés en que nuestro sistema desarrolle un comportamiento para este tipo de imágenes. La figura 4.25 es un ejemplo de este tipo de imagen.

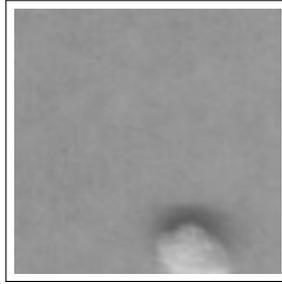


Figura 4.25: Ejemplo de una imagen con un resto esférico sobre la superficie del tablero.

Cuidadosamente y con un estudio visual de cada una de las imágenes, hemos podido hacer una clasificación del conjunto de datos. Algunas imágenes, al ser de dudosa naturaleza, se han etiquetado de tal forma que su clasificación sea aquella que parece ser más probable. En diversas ocasiones, se ha acudido a pedir opinión a expertos en las imágenes de la empresa. El conjunto se compone del número de observaciones reflejadas en la Tabla 4.3.

Cabe destacar cómo 709 imágenes, cerca del 10 % del conjunto, corresponden a falsos positivos. No significa por esto que el sistema “Smart Eyes” detecte erróneamente el 10 % de las imágenes que recibe. La tasa de error podría ser mayor o menor, ya que no tenemos información respecto a las imágenes que clasifica como sin defectos. Podría ser un sistema con una tasa de falsos negativos significativa o prácticamente nula.

Corpus I	
Observaciones	
Sin defectos	709
Con defectos	6458
Total	7167

Tabla 4.3: Distribución de observaciones del Corpus I.

Los defectos se pueden clasificar a su vez en tres tipos a mayores (defectos negros, blancos y topográficos), tal y como podemos observar en la Tabla 4.4. Los defectos topográficos dan lugar a relieves detectables en negro y blanco por lo que se pueden clasificar como imágenes con defectos negros y blancos. Existen imágenes en el Corpus en las que están presentes más de un tipo de defecto, lo que provoca que la suma de las observaciones de los tipos de defectos no sea el total de observaciones con defectos del Corpus.

Corpus I	
Defecto	Observaciones
Negro	5497
Blanco	546
Topográfico: Bolsas de aire	41
Topográfico: Gotas de agua	17
Topográfico: Grietas de separación	64
Topográfico: Grietas de unión	46
Topográfico: Hendiduras	94
Topográfico: Rotura horizontal	66
Topográfico: Rotura lateral	71
Topográfico: Surcos de Agua	55

Tabla 4.4: Distribución de defectos observados en el Corpus I.

4.2.2. Corpus II: Imágenes “sin defectos”

El corpus se recibió en forma de cuatro vídeos, uno por cada cámara lineal de la línea, el día 21 de marzo del año 2018. Esta muestra ha sido difícil de grabar por parte de la empresa: el software que va captando y recopilando las imágenes de defectos en su base de datos no tenía una modificación sencilla para que grabase el tablero en buen estado. Además, el uso del software que grabó la muestra inhabilitaba temporalmente al control de calidad realizado por “Smart Eyes”. Esto ha requerido pedir varios permisos al equipo de dirección de la producción de la empresa.

A través de 4 vídeos (uno por cámara) de duración superior a 15 minutos se han podido obtener más 30000 imágenes. Las imágenes obtenidas están en bruto, será necesario en una fase de pre-procesamiento de las imágenes recortar los puntos ciegos de las cámaras así como eliminar en las cámaras laterales las secciones de la imagen sin tablero. Este proceso se encuentra descrito en el apartado de extracción de la zona de interés de la memoria de Ingeniería Informática. Un ejemplo de recortado de los puntos ciegos y zonas sin tablero aparece en la Figura 4.26.

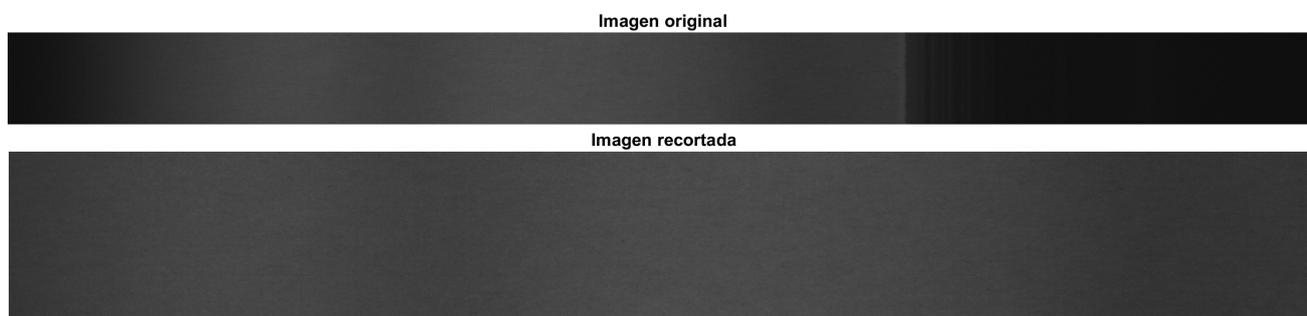


Figura 4.26: Ejemplo de proceso de recortado de zona de interés en una imagen captada por la cámara derecha.

Una vez eliminadas estas áreas no útiles, podemos observar cómo las imágenes no son idénticas a las del Corpus I por la ausencia del pre-tratado de “Smart Eyes”. El software empleado para grabarlas da lugar a imágenes que tienen menos luz que las imágenes del Corpus I proporcionadas por “Smart Eyes”. Esta falta de luminosidad en principio no supondrá mayor problema debido a la naturaleza del procesamiento empleado de sustracción de fondo descrito en la Sección 5.2.

Como la inmensa mayoría de estas 32660 imágenes carecen de defectos y son altamente similares en cuanto a aspecto, se han tomado como muestra 4000 imágenes sobre el total que compondrán el Corpus II. La distribución de procedencia y clase de las imágenes aparece en la tabla 4.5:

Corpus II					
Cámara:	Izquierda	Centro-izquierda	Centro-derecha	Derecha	Total
Sin defectos	934	1069	841	1049	3893
Con defectos	11	9	48	39	107
Total	945	1078	889	1088	4000

Tabla 4.5: Distribución de clases observadas en el Corpus II.

Así mismo podemos etiquetar las imágenes con defectos del mismo modo que hicimos con el Corpus I atendiendo a la clasificación expuesta en el glosario de defectos. La Tabla 4.6 muestra la distribución de defectos del Corpus II:

Corpus II					
Defecto	Izquierda	Centro-izquierda	Centro-derecha	Derecha	Total
Negro	8	9	43	31	91
Blanco	3	0	4	8	15
Topográfico: Hendiduras	0	0	1	0	1

Tabla 4.6: Distribución de defectos observados en el Corpus II.

Tal y como ya habíamos comentado, el Corpus II se compone en su mayoría de imágenes sin defectos. Al tratarse de una grabación de más de una orden de producción, podemos hacer ciertas afirmaciones generales. Los defectos negros son los más comunes y habituales mientras que los defectos blancos son bastante más escasos. Los defectos topográficos son muy poco comunes.

4.3. Imágenes de falsos negativos de “Smart Eyes”

La obtención de imágenes con defectos no detectados por “Smart Eyes” supone diversas dificultades, como pueden ser las siguientes:

- Imposibilidad del grabado de los falsos negativos. Estas imágenes no podrían ser grabadas por “Smart Eyes” de pasar los tableros de nuevo por la línea de producción, ya que este seguiría sin detectar este defecto. Otra opción sería emplear el sistema de grabado del Corpus II. Requeriría trabajo a mayores por parte de la empresa, por lo que esta opción se ha desestimado.
- Indeterminación con respecto a su identidad como falso negativo. “Smart Eyes” notifica la detección de un defecto al operario en el puesto de control. Posteriormente este retira el tablero con el defecto si en el estudio del mismo desde el puesto de control halla el defecto. En este proceso existen varias fuentes de error: equivocarse de tramo (el tablero que quite el operario puede no ser el que ha detectado como defectuoso “Smart Eyes”), falta de agilidad del operario para retirarlo (dispone de cerca de 10 segundos para retirarlo), etc. Esto podría dar lugar a un trozo de tablero que fomarí parte de la orden de producción final que consideraríamos como falso negativo sin realmente serlo. “Smart Eyes” puede haber detectado correctamente la ausencia de defectos en la superficie y, en el fondo, hallarse la fuente de error en el operario que se encargue del puesto de control al haber retirado el trozo de tablero que no correspondía.
- ¿Defecto de fábrica o de transporte, manufacturación,...? Los supuestos falsos negativos que nos podría proporcionar la empresa provendrán de devoluciones de clientes. El defecto puede ser un genuino falso negativo de “Smart Eyes”, pero podría ser también un defecto provocado en el transporte de los tableros, en la elaboración del producto con estos tableros,...

Por estos motivos, las imágenes de estos posibles falsos negativos no se han podido tomar. Debido a su incertidumbre en cuanto a que sean realmente falsos negativos, su escasez según la organización de la empresa y su imposibilidad para ser grabados por el sistema “Smart Eyes”, hemos considerado que el estudio de estas imágenes no aportaba nada más que información incierta y de poca utilidad.

Capítulo 5

Tratamiento de las imágenes

5.1. Sistema “Smart Eyes”

El sistema de pre-procesamiento de imágenes actualmente en funcionamiento en la línea de producción de Tafisa se desarrolló por ISND Group. Se trata de un sistema de filtrado simple que toma las imágenes captadas por las cuatro cámaras dispuestas en la línea de producción (figura 5.1) y las procesa de tal forma que detecta y avisa de la posible presencia de defectos en la superficie de tableros de una orden de producción en tiempo real.



Figura 5.1: Caja contenedora de las cámaras.

Las cámaras son lineales y captan las imágenes del flujo del tablero de forma continua. Las cuatro cámaras son contiguas y están dispuestas de forma perpendicular al paso del tablero (figura 5.2). Se encuentran localizadas después del área de prensado de la línea y justo antes de la zona donde se secan los tableros. Están protegidas por unos paneles para evitar que un golpe o algún fallo en la línea las rompan.

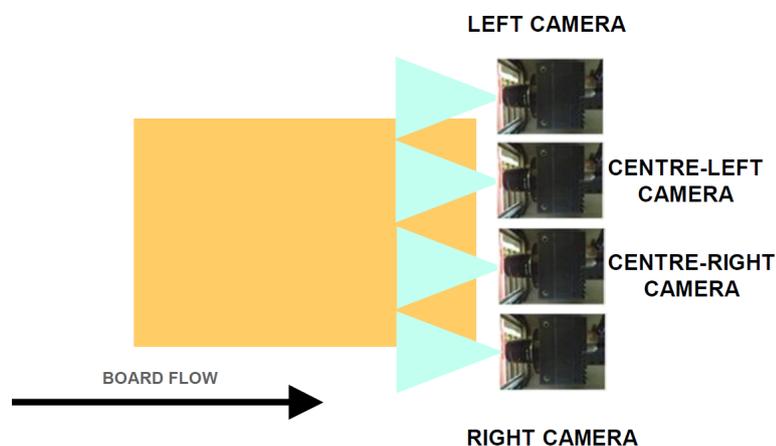


Figura 5.2: Funcionamiento del sistema. A la izquierda se encuentra el tablero avanzando hacia el lado derecho. A la derecha las cuatro cámaras.

Como ya se ha comentado, es un sistema del que no se tiene una medida del rendimiento, ya que no se conoce el porcentaje de falsos negativos. De hecho, la detección de muchos falsos positivos hace que la decisión final de desechar un tablero sea siempre manual, es decir, el sistema avisa de un posible defecto, pero es un operario el que, tras visionar el tablero, decide si se retira o no. La empresa está contenta con su funcionamiento, aunque reconoce que el sistema se puede mejorar.

5.1.1. Extracción de zona de interés

Previamente a lo que sería en sí el tratamiento de la imagen, se eliminan los tramos sin tablero (cinta de transporte) y los puntos ciegos de las cámaras. Lo primero es posible gracias a que el software de planificación de la empresa provee la anchura de los tableros de cada orden de producción. Esto les permite calcular qué región de las imágenes captadas por las dos cámaras laterales no es útil. La eliminación de los puntos ciegos se debe a que las cámaras graban imágenes con cierto solapamiento: podremos eliminar tramos que una cámara no graba con suficiente resolución con la garantía de que la contigua lo grabará mejor. La retirada de los puntos ciegos se hace de tal forma que se retire lo mínimo imprescindible de la imagen, dando preferencia a que se detecte el mismo error por dos cámaras distintas que a que realmente queden puntos ciegos en el sistema por los que puedan pasar inadvertidas las taras.

A mayores se estudia en las imágenes si existen rayas horizontales negras, como podemos ver en la figura 5.3. Estas se deben a la alta frecuencia de grabado exigida a las cámaras. Estos fotogramas con rayas no son filtrados ni tratados, sencillamente se descartan.



Figura 5.3: Imagen con raya horizontal negra.

5.1.2. Tratamiento de la imagen

La imagen se procesa de dos formas independientes: una responsable de detectar los errores que hemos clasificado como “blancos” y otra capaz de detectar los “negros”. El tratamiento de la imagen conlleva fases en las que se reducen las gamas de tonos de la imagen, procedimiento llamado posterización, así como un proceso de conteo de formas en la imagen. Se detectan bordes con la ayuda de varios operadores, uno diferencial y otro relacionado con el algoritmo de Canny, a la vez que se busca si hay intersecciones entre las distintas formas de la imagen. La aplicación de un algoritmo de suavizado permite reducir el ruido presente en la imagen. Finalmente se usa un ‘Threshold’ o umbral para binarizar la imagen de la forma más adecuada. El proceso de detección de defectos blancos es muy similar sólo que, en vez de trabajar con la imagen original, se trabaja con la imagen invertida, es decir, se sustituye cada valor por la diferencia entre el valor máximo -255- y el valor original de la imagen para cada píxel [4].

Una vez que el sistema ha binarizado cada imagen como una matriz con valores 0 y 1, no-error y error, hace una aproximación del área de error posible en la imagen. Si supera un umbral asignado a esta área, la imagen se etiqueta como correspondiente a tablero defectuoso. Las imágenes van pasando por un Buffer para ir procesando paulatinamente las imágenes y determinar su naturaleza. En la figura 5.4 podemos observar el resultado del tratamiento de una imagen pre-procesada con defectos negros:

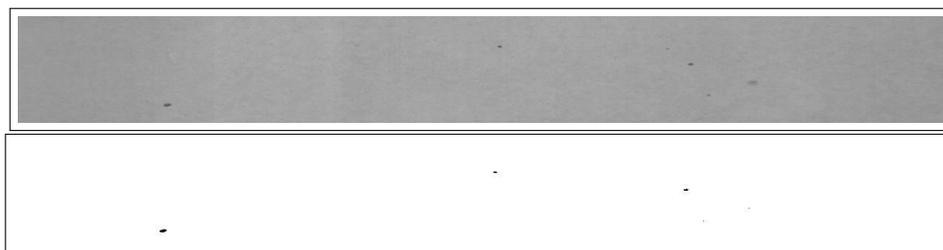


Figura 5.4: Imagen filtrada por Smart Eyes con defectos negros antes y después de ser procesada.

Con ello se logra un sistema robusto, especialmente para la detección de defectos negros. Sin embargo, el filtrado de blancos del algoritmos crea mucho ruido en las imágenes que tienen problemas de homogeneidad en la iluminación, tal y como vemos en la imagen con defecto blanco de la figura 5.5. Esto da lugar a muchos falsos positivos.

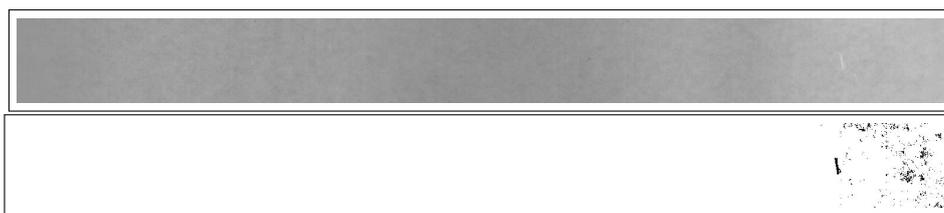


Figura 5.5: Imagen filtrada por Smart Eyes con defecto blanco antes y después de ser procesada. Se crea ruido a la derecha.

En el apartado 8.1 se muestra el rendimiento de este sistema.

5.2. Nuestra propuesta

Nuestro sistema de pre-procesamiento de la imagen ha sido desarrollado en Matlab. El lenguaje de programación nos ofrece versátiles herramientas para el tratamiento de la imagen.

5.2.1. Extracción de zona de interés

Tenemos que hacer distinción entre las imágenes del Corpus I y del Corpus II. Con respecto a las primeras, las imágenes ya han sido pre-tratadas por “Smart Eyes”, por lo que tienen ya retirados los puntos ciegos y los tramos sin tablero. Con respecto a las segundas, hemos intentado emular el procedimiento empleado por “Smart Eyes” de retirada de puntos ciegos y zonas sin tablero. Al no contar con las medidas reales del tablero, el corte ha sido en cierto modo aproximado. Todo el proceso de recorte de imagen se ha hecho con Matlab, siguiendo un procedimiento similar al que aparece en el apartado de recorte de imágenes de la web de MathWorks [5]. En la siguiente figura (5.6) vemos un ejemplo de imagen de una de las cámaras laterales, en el que se han eliminado la parte izquierda sin tablero y el punto ciego a la derecha:



Figura 5.6: La imagen inferior es el resultado de extraer la zona de interés de la superior.

5.2.2. Tratamiento de la imagen

Hemos optado por seguir un esquema general similar al procedimiento de “Smart Eyes” con el uso de dos procesos de filtrado, uno para defectos negros y otro para defectos blancos. Una vez cargada la imagen, se modifica para pasarla a escala de grises. La imagen ya consta solo de degradados de gris, pero el formato en que están guardadas (JPG) codifica las imágenes por defecto en un modelo tricolor RGB.

Después intentamos emplear distintas estrategias para normalizar u homogeneizar la luz como la ecuación de histogramas o la versión adaptativa de este procedimiento. Buscan que la distribución de cada nivel de gris en el histograma de la imagen siga una distribución uniforme, maximizando el contraste y conservando la entropía o información. Estos enfoques no resultaron adecuados porque las imágenes, en general, contienen una gama de grises pequeña.

El procedimiento óptimo que hemos hallado para la detección defectos blancos ha resultado ser la sustracción del fondo de la imagen [6]. Esta técnica se emplea en imágenes cuya iluminación de fondo no es uniforme. Se pueden aplicar distintas formas, aunque la elegida es una circunferencia de radio constante. Posteriormente se procede a binarizar la imagen haciendo uso de un valor umbral, quedando la imagen codificada en dos valores: 0 y 255, correspondientes a negro y blanco. Con la matriz (imagen) resultante, podremos calcular de forma aproximada cuánto vale el área del defecto con el número de píxeles que tomen el color blanco.

La detección de defectos negros es análoga, sólo que en vez de trabajar con la imagen original se trabaja con la invertida. En la figura 5.7 vemos cómo se ha procesado una de las imágenes del conjunto:

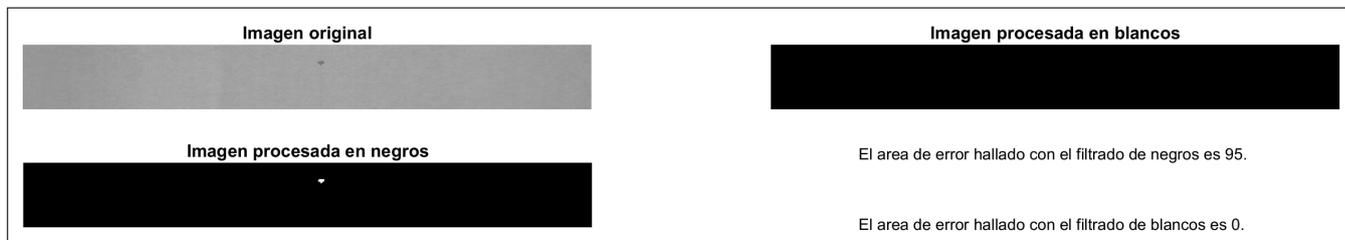


Figura 5.7: Salida básica del procesamiento de las imágenes.

La binarización parece funcionar correctamente: destaca aquellas zonas que pueden ser error y deja blancas aquellas que parecen estar correctas. Funciona correctamente con ejemplos en los que hay defectos negros, blancos y otros defectos. Parece que los falsos positivos de “Smart Eyes” nuestro sistema no los detecta como positivos. Sin embargo, los defectos relacionados con el hinchamiento del tablero no son detectados correctamente.

5.2.3. Optimización del filtrado

Nuestra propuesta de refinado de las imágenes consta de dos filtrados (negro y blanco) cada uno de los cuales depende de dos parámetros: uno relacionado con la sustracción del fondo y otro con el procedimiento de binarización.

Cada uno de los dos parámetros de los filtrados se han optimizado de forma independiente mediante un procedimiento iterativo empleando distintos valores para estos. Para estimar la calidad del filtrado resultante, se ha empleado la tasa de equierror. Se ha considerado óptimo aquel filtrado cuya tasa de equierror fuese mínima.

Tasa de Equierror

La tasa de equierror (EER - Equal Error Rate) es una medida de evaluación de sistemas de clasificación empleado comúnmente en dispositivos de biometría. Se define como el punto en el que se igualan la tasa de falsos positivos y la tasa de falsos negativos. Estas dos tasas son probabilidades condicionadas definidas a partir de la matriz clásica dos por dos. En la Tabla 5.1 vemos un ejemplo de matriz dos por dos, particularmente una matriz de confusión [7]. En horizontal se define la clase verdadera de la observación, mientras que en vertical aparece la clase predicha o etiqueta.

		Clase	
		Sin defecto	Con defecto
Etiqu.	Sin defecto	TN	FN
	Con defecto	FP	TP

Tabla 5.1: Matriz de confusión dos por dos.

En la diagonal de esta matriz aparecen las observaciones bien clasificadas [8]: los verdaderos positivos (True Positive - TP), en nuestro caso las imágenes con defectos clasificadas como con defectos, y los verdaderos negativos (True Negative - TN), imágenes sin defectos clasificadas como tal. En la posición inferior izquierda están los tableros sin defectos clasificados como si los tuviesen (falsos positivos, False Positive - FP) y en la posición derecha superior los tableros con defectos clasificados como si no los tuviesen (falsos negativos, False Negative - FN).

Llamamos tasa de falsos positivos (False Positive Rate - FPR) a la probabilidad existente de que una observación, condicionada a que no tenga defectos, sea clasificada como si los tuviese.

$$FPR = P(\text{Etiqueta=Defectuoso}|\text{Clase=Sin defectos}) = \frac{FP}{TN + FP}$$

De forma análoga definimos la tasa de falsos negativos (False Negative Rate - FNR) como la probabilidad existente de que una observación, condicionada a que tenga defectos, sea clasificada como si no los tuviese.

$$FNR = P(\text{Etiqueta=Sin defectos}|\text{Clase=Defectuoso}) = \frac{FN}{TP + FN}$$

El umbral que seleccionaremos será aquel que permita que se iguallen la tasa de falsos positivos y falsos negativos tal y como podemos ver en la Figura 5.8. El umbral se ha seleccionado por separado en el Corpus I que en el II para seguir una línea de trabajo similar a la desarrollada con los clasificadores.

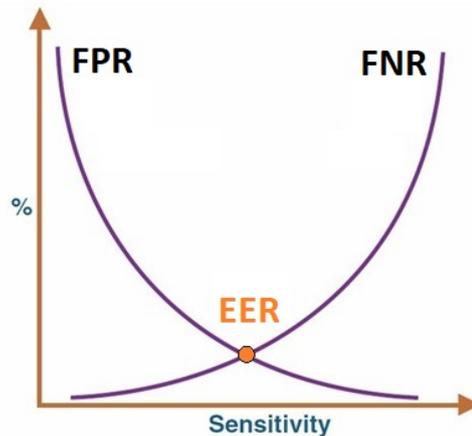


Figura 5.8: Representación gráfica de la definición de tasa de equierror (EER - Equal Error Rate). En la figura se representan la tasa de falsos positivos (FPR) y la tasa de falsos negativos (FNR) en función de la sensibilidad.

Se ha realizado la optimización del filtrado de los Corpus I y II por separado debido a las diferencias existentes en ellos en cuanto a propiedades (diferencia de luminosidad, resolución de las imágenes, etc.).

Capítulo 6

Extracción de características

A lo largo de este capítulo se detallan las diferentes características o variables extraídas a partir de las imágenes en bruto que componen los Corpus así como las resultantes de aplicar dos filtrados sobre éstas. Los filtrados sirven para realzar las zonas notoriamente oscuras -posible defecto negro- o muy claras -posible defecto blanco-. En la memoria de trabajo de fin de grado de ingeniería informática se ha detallado más en profundidad la naturaleza de los filtrados.

Una segunda parte de este capítulo describe los conjuntos de variables, compuestos por las características extraídas desarrolladas previamente, que servirán como entrada a los modelos de clasificación que se crearán posteriormente.

6.1. Variables extraídas

6.1.1. Áreas de error relativo en negro y blanco

Las características base extraídas tras al procedimiento de filtrado realizado serán las áreas de error relativa en blanco y negro. Estas variables se calculan como la suma de píxeles que son marcados como defectuosos después del filtrado y la binarización entre el total de píxeles de la imagen.

$$\text{Area Error} = \frac{\text{Píxeles marcados como con defecto}}{\text{Area}} = \frac{\text{Píxeles marcados como con defecto}}{\text{Anchura} \times \text{Altura}}$$

Este área se ha calculado por separado para el filtrado de negros y el de blancos. Al tomar estas variables valores muy bajos se han multiplicado por un factor de escala constante de 1000. Provenirán de las imágenes binarizadas después del filtrado blanco o negro, por lo tanto, estas dos variables.

La Figura 6.1 muestra ejemplos de imágenes filtradas en blanco y negro y cómo a partir de ellas se han calculado las áreas de error relativas.

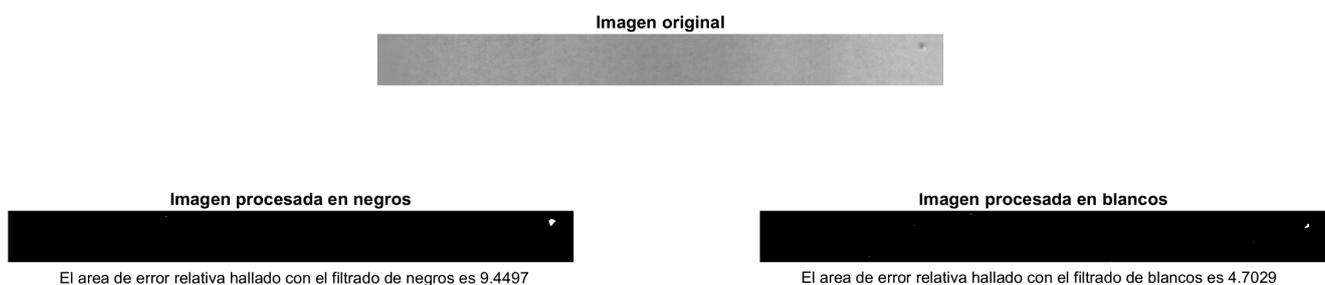


Figura 6.1: Salida del cálculo del área de error relativa en negro y en blanco en una imagen. El valor ha sido multiplicado por un factor de escala.

6.1.2. Caracterizaciones de las distribuciones de grises

El siguiente conjunto de variables relevantes está relacionado con la distribución de grises de las imágenes. Llamamos distribución de grises de una imagen a la frecuencia de aparición de cada uno de los tonos de gris dentro de la imagen. Esta frecuencia de aparición se ha medido de forma relativa, es decir, como proporción (dividiendo entre el total de píxeles de la imagen). Existen 256 tonos de grises codificados en valores entre 0 y 255, correspondiendo el 0 al color negro y el 255 al blanco y quedando entremedias las diferentes tonalidades de gris.

En la Figura 6.2 se puede observar una representación gráfica (histograma de grises) de la distribución de grises de una imagen en bruto de los Corpus. Este ejemplo refleja claramente cómo en la mayoría de las imágenes en bruto una proporción muy alta de los píxeles de la imagen se encuentran comprendidos entre 140 y 200 en la escala de grises.

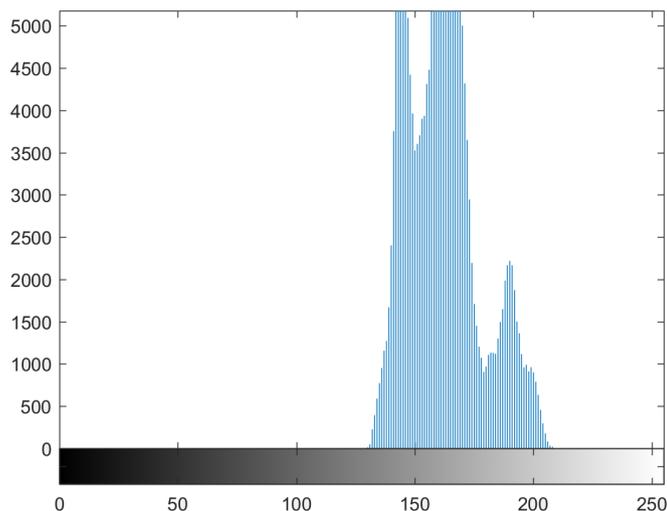


Figura 6.2: Histograma de grises asociado a la distribución de grises de una imagen en bruto perteneciente a uno de los Corpus.

Para evitar trabajar con las 256 variables que genera la distribución, se han utilizado dos caracterizaciones diferentes de la distribución de grises. Formarán parte de dos conjuntos de variables independientes con los que se trabajará simultáneamente. Las caracterizaciones en cuestión son:

- Conjunto A - PCA: se emplea el análisis de componentes principales [9] con las 256 variables de la distribución relativa de grises para así reducir de forma muy notoria la dimensionalidad. Antes de realizar el análisis de componentes principales se ha eliminado una de las variables: ésta era dependiente del resto al tratarse de variables en tanto por uno que suman uno en total.
- Conjunto B - Estadísticos: se hace uso de los estadísticos característicos de la distribución de valores tomados en escala de grises por los píxeles de la imagen. Supone una reducción de dimensionalidad menor que podría dar lugar a un conjunto de datos con más variabilidad útil para la posterior clasificación de las imágenes. Los estadísticos empleados de las distribuciones han sido los siguientes: media, varianza, asimetría, kurtosis, mediana, cuartil-10% y cuartil-90%.

Estas variables se han extraído de la imagen original (en bruto) así como de las imágenes filtradas en negro y blanco sin binarizar.

6.1.3. Transformada Discreta del Coseno (DCT)

A mayores se ha añadido un último juego de variables: la DCT [10] (transformada discreta del coseno). Se emplea especialmente en la compresión de sonido e imágenes dando lugar a conocidos formatos como MP3 o JPEG. La Figura 6.3 muestra un ejemplo de cómo la DCT es capaz de resumir la información contenida en una imagen en unos pocos dígitos.

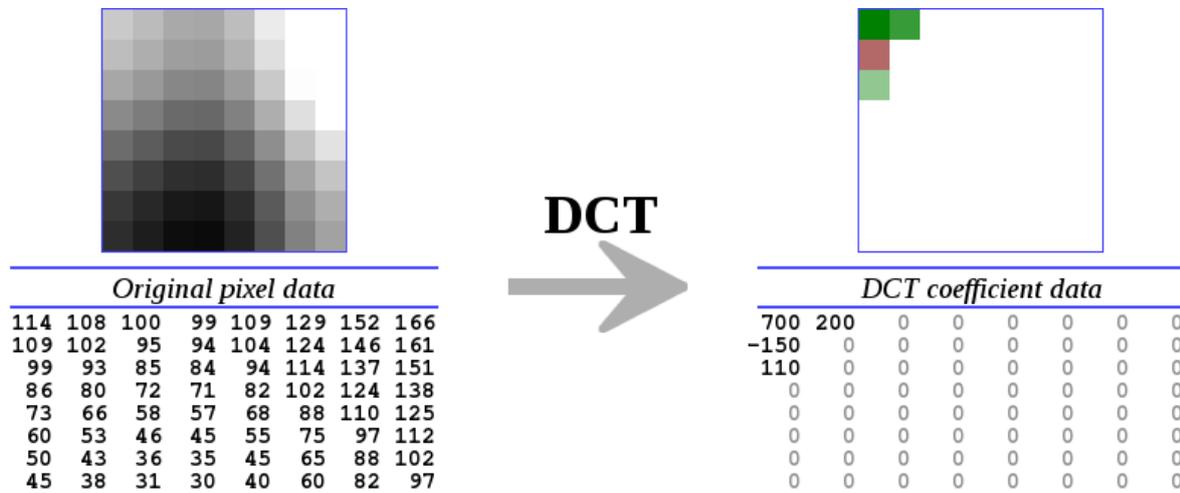


Figura 6.3: Aplicación de la transformada discreta del coseno a una imagen en escala de grises. Debajo de las imágenes aparece la matriz correspondiente [11].

Se trata de la una técnica capaz de expresar información como suma de funciones coseno oscilando a diferentes frecuencias. Es una función muy relacionada con la transformada de Fourier (DFT). Lo que las distingue es que, mientras que la DFT emplea tanto funciones seno como coseno, la DCT solo trabaja con cosenos y, por lo tanto, con números reales. La definición formal de la transformada discreta del coseno empleada [12] (DCT-II) expresa cada píxel de la imagen original en escala de grises ($x[n]$) como una suma de cosenos con diferentes coeficientes:

$$x[n] = \begin{cases} \frac{1}{N} \sum_{k=0}^{N-1} w[k] C_x[k] \cos\left(\frac{\pi}{2N} k(2n+1)\right) & \text{si } 0 \leq n < N \\ 0 & \text{en otro caso} \end{cases}$$

$$w[k] = \begin{cases} \frac{1}{2} & \text{si } k = 0 \\ 1 & \text{si } 0 < k < N \end{cases}$$

Los coeficientes de los cosenos se puede calcular con las siguientes expresiones analíticas a partir de los valores de las $x[n]$:

$$C_x[k] = \begin{cases} \sum_{n=0}^{N-1} 2x[n] \cos\left(\frac{\pi}{2N} k(2n+1)\right) & \text{si } 0 \leq k < N \\ 0 & \text{en otro caso} \end{cases}$$

Sobre las componentes extraídas de la DCT (los coeficientes $C_x[k]$) se han aplicado dos transformaciones sucesivas: se han elevado al cuadrado (para hacer que sean positivos los valores) y se ha aplicado después el logaritmo (para que la distribución subyacente fuese más suave y cumplierse de forma más fuerte las hipótesis de normalidad). Se han extraído los 30 términos más relevantes de la transformada discreta del coseno de la imagen filtrada binarizada y sin binarizar, añadiendo a los conjuntos de variables previamente descritos 60 variables.

La imagen filtrada sin binarizar surge como la suma elemento a elemento de las matrices correspondientes a las imágenes filtradas en blanco y en negro. Esta adición se acota de tal forma que ningún elemento pueda superar el valor 255, el máximo en la escala de grises definida. La extracción de 30 elementos se ha hecho a la vista de cómo en muchas imágenes a partir de la componente 30 los valores eran prácticamente nulos.

La Figura 6.4 muestra en forma de esquema las imágenes con las que se ha trabajado así como las variables extraídas de cada una de ellas.

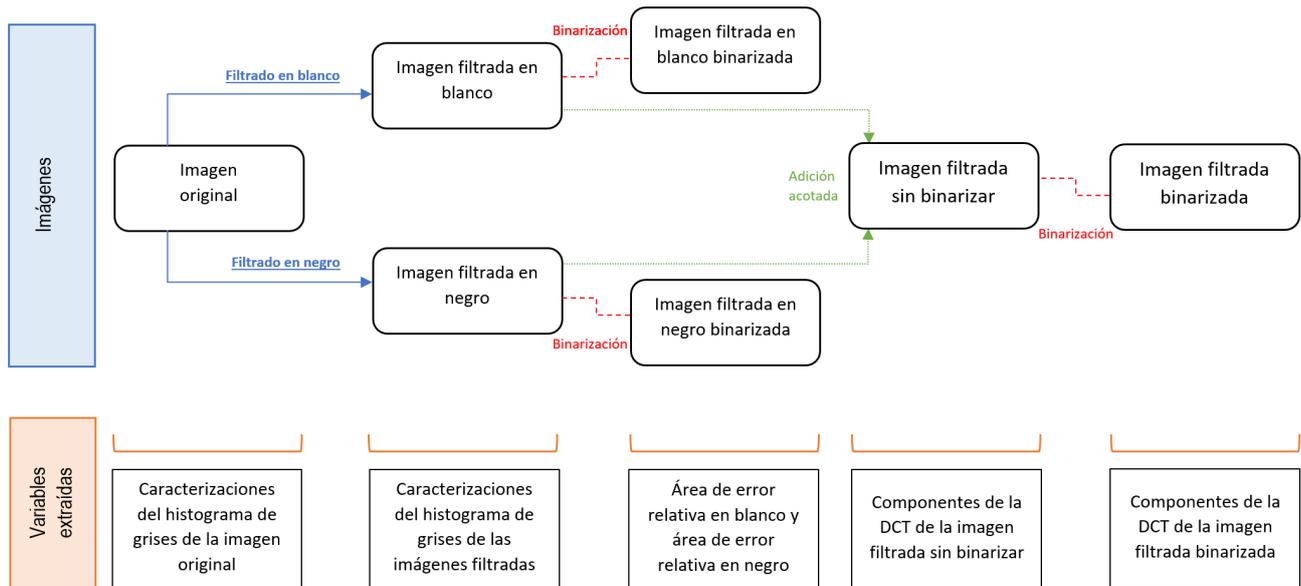


Figura 6.4: Representación esquemática de las imágenes con las que se ha trabajado y variables que se extraen en cada fase.

6.2. Conjuntos de variables consideradas

Las siguientes subsecciones describen con detalle las variables que componen los dos conjuntos de datos empleados en la clasificación de imágenes, caracterizados por su uso de estadísticos o componentes principales como ya se ha mencionado. Las áreas de error relativa en negro y en blanco y las componentes extraídas de transformada discreta del coseno completan los conjuntos de datos.

Se estudió posteriormente completar el estudio con un tercer conjunto de variables C, integrado únicamente por las variables de área de error y las componentes de la transformada discreta del coseno extraídas. La obtención de resultados peores que con el conjunto A y el B hizo que esta vía de trabajo fuese descartada en los primeros estadios de este proyecto.

Conjunto A: uso de PCA

(2 + 8 + 60 variables)

Las variables que conforman este conjunto son:

- Área de error relativa en la imagen procesada en negros y en la imagen procesada en blancos. Tomarán valores naturalmente bajos entre 0 y 1 (2 variables).
- A través del análisis de componentes principales extraemos:
 - Componentes 1-4 de la distribución de grises de la imagen original. En las imágenes del Corpus I, cuatro componentes recogen una inercia del 80.20%. El resto de componentes son residuales. En el Corpus II la inercia alcanza el valor de 88.53% con 4 componentes. (4 variables).
 - Componentes 1-2 de la distribución de grises de la imagen tratada en blancos. La varianza explicada con 2 componentes en el Corpus I es del 96.91% mientras que en el Corpus II es del 97.46%. (2 variables).
 - Componentes 1-2 de la distribución de grises de la imagen tratada en negros. La inercia recogida por dos componentes en el caso del Corpus I ha sido del 96.30%. En el Corpus II este valor es del 97.13% (2 variables).
- DCT de la imagen tratada sin binarizar y binarizada (30×2 variables)

La Tabla 6.1 muestra de forma resumida las variables que componen este conjunto de datos.

Variables del conjunto de variables A (70)					
Area de Error (2)		AreaErrorB	AreaErrorN		
PCA	Img. original (4)	CompPrinOr1	CompPrinOr2	CompPrinOr3	CompPrinOr4
	Img. filtrada en blanco (2)	CompPrinTratB1	CompPrinTratB2		
	Img. filtrada en negro (2)	CompPrinTratN1	CompPrinTratN2		
DCT	Img. filtrada sin binarizar (30)	Componentes de la 1 a la 30 extraídas.			
	Img. filtrada binarizada (30)	Componentes de la 1 a la 30 extraídas.			

Tabla 6.1: Variables del conjunto de datos A.

Conjunto B: uso de estadísticos

(2 + 21 + 60 variables)

Las variables que conforman este conjunto son:

- Área de error relativa en la imagen procesada en negros y en la imagen procesada en blancos. Tomarán valores naturalmente bajos entre 0 y 1 (2 variables).
- Media, varianza, asimetría (skewness), kurtosis, mediana, cuartil-10% y cuartil-90% de las distribuciones de grises de la imagen original, tratada en blancos y tratada en negros. Serán valores entre 0 y 255 (7×3 variables).
- DCT de la imagen tratada sin binarizar y binarizada (30×2 variables)

La Tabla 6.2 muestra de forma resumida las variables que componen este conjunto de datos.

Variables del conjunto de variables B (83)					
Area de Error (2)		AreaErrorB	AreaErrorN		
Estadísticos	Img. original (7)	MediaOr MedianaOr	VarianzaOr P10Or	SkewnessOr P90Or	KurtosisOr
	Img. filtrada en blanco (7)	MediaTratadaB MedianaTratadaB	VarianzaTratadaB P10TratadaB	SkewnessTratadaB P90TratadaB	KurtosisTratadaB
	Img. filtrada en negro (7)	MediaTratadaN MedianaTratadaN	VarianzaTratadaN P10TratadaN	SkewnessTratadaN P90TratadaN	KurtosisTratadaN
DCT	Img. filtrada sin binarizar (30)	Componentes de la 1 a la 30 extraídas.			
	Img. filtrada binarizada (30)	Componentes de la 1 a la 30 extraídas.			

Tabla 6.2: Variables del conjunto de datos B.

Capítulo 7

Metodología

En este capítulo se expondrán cada uno de los modelos desarrollados en el proyecto y que posteriormente serán evaluados en el Capítulo de los resultados (Capítulo 8).

La línea de trabajo seguida es la siguiente: se comenzará con un sencillo sistema de referencia que dará paso a clasificadores básicos como la regresión logística. Posteriormente se desarrollarán diferentes tipos de Support Vector Machines variando el núcleo para dar paso finalmente a redes neuronales de diversa índole. Por lo tanto, la complejidad de los clasificadores aumentará gradualmente acorde al desarrollo del proyecto.

De cada uno de los clasificadores se hará una breve contextualización de su origen. Posteriormente se desarrollará el fundamento formal de la técnica así como posibles aplicaciones prácticas ya implementadas en las que el procedimiento en cuestión ha logrado resultados altamente satisfactorios. A mayores se desarrolla un apartado sobre la implementación utilizada con cada uno de los procedimientos.

Sobre cada uno de los distintos tipos de clasificadores se estudiará el área bajo la curva ROC asociada, la tasa de equierror, la sensibilidad, la especificidad y precisión conseguidas con los siguientes modelos:

- **Modelo A:** desarrollo de un único clasificador (imagen con defecto-sin defecto) con el conjunto de variables A (PCA). Se trata de un conjunto de variables más reducido en dimensionalidad que el B.
- **Modelo B:** desarrollo de un único clasificador (imagen con defecto-sin defecto) con el conjunto de variables B (Estadísticos). Se trata de un conjunto con más variables que el A que podrían aportar una mayor varianza explicada.

En cada uno de los clasificadores se hará una selección de características o un estudio de la relevancia de las variables empleadas. La selección de modelos óptimos se realizará utilizando como criterio la tasa de acierto (7.0.1.1), a excepción de que el modelo no sea balanceado en cuanto a distribución de clases y tenga una fuerte preferencia por una de ellas. En tal caso la medida de referencia será el F-Score(7.0.1.2), media armónica de la sensibilidad y la especificidad, que permitirá la elección teniendo en cuenta tanto la clasificación de imágenes con defectos como las que carecen de ellos.

En los casos de clasificadores cuya salida sea probabilística o acotada se expondrán las curvas ROC (7.0.1.3), tasa de equierror (5.2.3), tasa de acierto y la matriz de confusión (7.0.1) de frecuencias relativas de los modelos estimadas mediante validación cruzada de 10 particiones. En caso contrario, se expondrán tan solo la tasa de acierto estimada y la matriz de confusión de frecuencias relativas aproximadas mediante validación cruzada (10 particiones).

7.0.1. Definiciones previas

Para el estudio de resultados así como en la selección de modelos óptimos se han utilizado una serie de conceptos definidos a partir de la matriz dos por dos básica que, en nuestro caso, corresponde a una matriz de confusión de clasificación binaria.

En la Tabla 7.1 vemos un ejemplo de matriz de confusión dos por dos tal y como empleamos en la definición de tasa de equierror. En horizontal se define la clase verdadera de la observación, mientras que en vertical aparece la clase predicha o etiqueta.

		Clase	
		Sin defecto	Con defecto
Etiqu.	Sin defecto	TN	FN
	Con defecto	FP	TP

Tabla 7.1: Matriz de confusión dos por dos.

En la diagonal de esta matriz aparecen las observaciones bien clasificadas: los verdaderos positivos (True Positive - TP), en nuestro caso las imágenes con defectos clasificadas como con defectos, y los verdaderos negativos (True Negative - TN), imágenes sin defectos clasificadas como tal. En la posición inferior izquierda están los tableros sin defectos clasificados como si los tuviese (falsos positivos, False Positive - FP) y en la posición derecha superior los tableros con defectos clasificados como sino no los tuviese (falsos negativos, False Negative - FN).

Llamamos tasa de verdaderos positivos o sensibilidad (True Positive Rate - TPR) a la probabilidad existente de que una observación, condicionada a que tenga defectos, sea clasificada como tal.

$$\text{Sensibilidad} = \text{TPR} = P(\text{Etiqueta}=\text{Defectuoso}|\text{Clase}=\text{Defectuoso}) = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

De forma análoga definimos la tasa de verdaderos negativos o especificidad (True Negative Rate - TNR) como la probabilidad existente de que una observación, condicionada a que no tenga defectos, sea clasificada correctamente como que no los tuviese.

$$\text{Especificidad} = \text{TNR} = P(\text{Etiqueta}=\text{Sin defectos}|\text{Clase}=\text{Sin defectos}) = \frac{\text{TN}}{\text{TN} + \text{FP}}$$

Las tasas de falsos negativos (False Negative Rate - FNR) y de falsos positivos (False Positive Rate - FPR) ya se definieron previamente cuando se realizó la definición de tasa de equierror en la Sección correspondiente 5.2.3.

$$\text{FNR} = P(\text{Etiqueta}=\text{Sin defectos}|\text{Clase}=\text{Defectuoso}) = \frac{\text{FN}}{\text{TP} + \text{FN}}$$

$$\text{FPR} = P(\text{Etiqueta}=\text{Defectuoso}|\text{Clase}=\text{Sin defectos}) = \frac{\text{FP}}{\text{TN} + \text{FP}}$$

7.0.1.1. Tasa de acierto

La tasa de acierto o precisión es una medida de evaluación de sistemas de referencia [8]. Se define como la proporción de observaciones bien clasificadas entre el total de las mismas. En base a las posiciones definidas en la matriz dos por dos básica, podemos definir la tasa de acierto:

$$\text{Tasa de acierto} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

La tasa de error es la probabilidad complementaria a la tasa de acierto y se calcula como la proporción de observaciones mal clasificadas entre el total de las mismas. Se emplean estimaciones de ésta para seleccionar modelos ante un conjunto de los mismos, siempre y cuando los modelos obtenidos sean balanceados clasificando en las dos clases. De no darse esto, se pueden emplear medidas relacionadas con la especificidad y sensibilidad como es el F-Score, definido más adelante en la Subsección 7.0.1.2.

Para la estimación de la verdadera tasa de acierto de un modelo se suele emplear un conjunto de datos test sobre el que se evalúa la misma. Ante la falta de datos suficientes para hacer esto, se emplean diversas técnicas basadas en repeticiones de muestreos aleatorios como es el Leave-One-Out (LOO) o la validación cruzada de k particiones [13]. Esta última técnica, con 10 particiones, es la que se ha empleado para estimar la tasa de acierto a lo largo del proyecto.

En los resultados relativos a la tasa de acierto se ha aportado a mayores un intervalo de confianza. Ante la falta de independencia de las particiones de la validación cruzada, el intervalo se basa en una distribución t de Student con 9 (k-1) grados de libertad. Si llamamos \bar{e} a la tasa de acierto media de las particiones, S_e^2 al estimador de la varianza muestral y $t_{\alpha/2,9}$ al valor de una distribución t de Student que deja a su derecha una probabilidad $\alpha/2$, la expresión del intervalo de confianza $1 - \alpha$ será:

$$\bar{e} \mp t_{\alpha/2,9} \frac{S_e}{\sqrt{10}}$$

7.0.1.2. F-Score

El F-Score es una medida de precisión para tests y clasificadores empleada especialmente en casos donde la tasa de acierto no aporta información precisa. Esto se deberá al desbalance entre clases en el conjunto de entrenamiento: clasificar solo a la clase mayoritaria dará lugar a una tasa de acierto elevada y sin embargo la capacidad clasificadora del clasificador será nula. Esto es sinónimo de que o la sensibilidad o la especificidad alcanzan un valor muy bajo. Su valor está acotado entre el cero y el uno.

La definición empleada del F-Score es la media armónica de la sensibilidad y especificidad. La expresión analítica es la siguiente:

$$F_1 = \frac{2}{\frac{1}{\text{Sensibilidad}} + \frac{1}{\text{Especificidad}}} = 2 \cdot \frac{\text{Sensibilidad} \cdot \text{Especificidad}}{\text{Sensibilidad} + \text{Especificidad}}$$

7.0.1.3. Curvas ROC (Receiver Operating Characteristic)

Las curvas ROC son representaciones gráficas de la tasa de verdaderos positivos (sensibilidad) frente a la tasa de falsos positivos (uno menos la especificidad) en un sistema de clasificación binaria según se varía el umbral que separa entre clases [8]. Se emplea mucho para valorar la calidad de tests de diagnóstico de enfermedades así como para evaluar comparativamente clasificadores. La Figura 7.1 muestra lo que sería el espacio sobre el que se definen las curvas ROC [14].

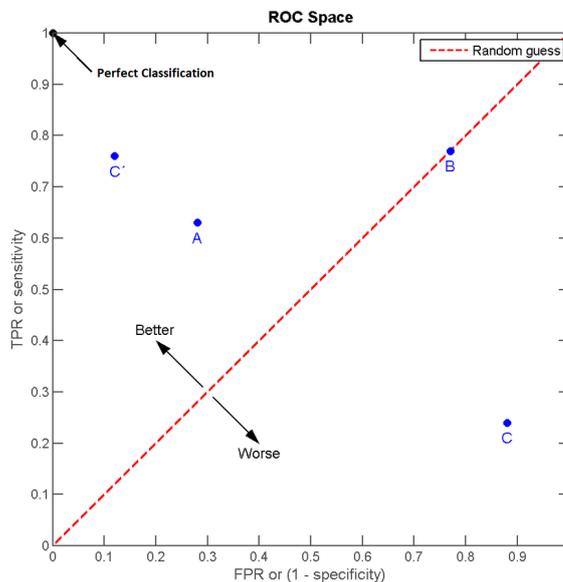


Figura 7.1: Representación gráfica del espacio de una curva ROC así como diversos puntos relevantes [15].

Se trata de una representación que cuenta con dos partes claramente diferenciadas. Esta división se da por la línea discontinua de color rojo en la Figura. Esta frontera supone la asignación al azar en un sistema de clasificación con dos clases. Los puntos por encima suponen que el clasificador es capaz de discriminar de cierta forma entre las clases mientras que si queda por debajo la asignación al azar es más efectiva. Si se alcanzase el punto (0,1), correspondiente a que tanto la sensibilidad como la especificidad sean uno, la clasificación perfecta sería posible.

Para medir la calidad de un clasificador en función de su curva ROC se emplea normalmente la AUC (Area Under Curve), que se define como el área recogida bajo la curva ROC. Su valor máximo es uno y cuanto mayor sea, mejor será la precisión del clasificador en cuestión.

Una clasificación simple para calificar el funcionamiento de un test o clasificador puede ser la que muestra la Tabla 7.2.

AUC	Calidad del clasificador
0.00-0.50	La asignación al azar es más eficaz.
0.50	Equivalente a asignar al azar.
0.50-0.60	Malo.
0.60-0.70	Pobre.
0.70-0.80	Bueno.
0.80-0.90	Muy bueno.
0.90-1.00	Excelente.

Tabla 7.2: Calidad de un sistema de clasificación según el valor de la AUC definida a partir de una curva ROC [16].

Cada uno de los puntos de la curva ROC representados así como el valor de la AUC se han estimado por validación cruzada de diez particiones para aproximarse al verdadero valor, empleando la media (μ_{AUC}) de estos como estimación. También se ha estimado la desviación estándar del AUC (σ_{AUC}) a partir de las diez particiones. Esta ha servido para crear los intervalos de confianza del 95 % ($\alpha = 0.05$) que aparecen en las tablas de resultados del documento de la siguiente forma:

$$\mu_{AUC} \mp z_{1-\frac{0.05}{2}} \sigma_{AUC} = \mu_{AUC} \mp 1.96 \sigma_{AUC}$$

La Figura 7.2 muestra el formato de curva ROC empleado. El azar aparece representado en gris y la curva como tal está en morado. A mayores, se han representado las curvas ROC medias correspondientes al defecto blanco y al defecto negro. Éstas en las Figuras aparecerán en azul y rojo respectivamente. En la leyenda aparece indicado el valor medio del AUC y su desviación estándar para las tres curvas (defecto general, defecto blanco y defecto negro).

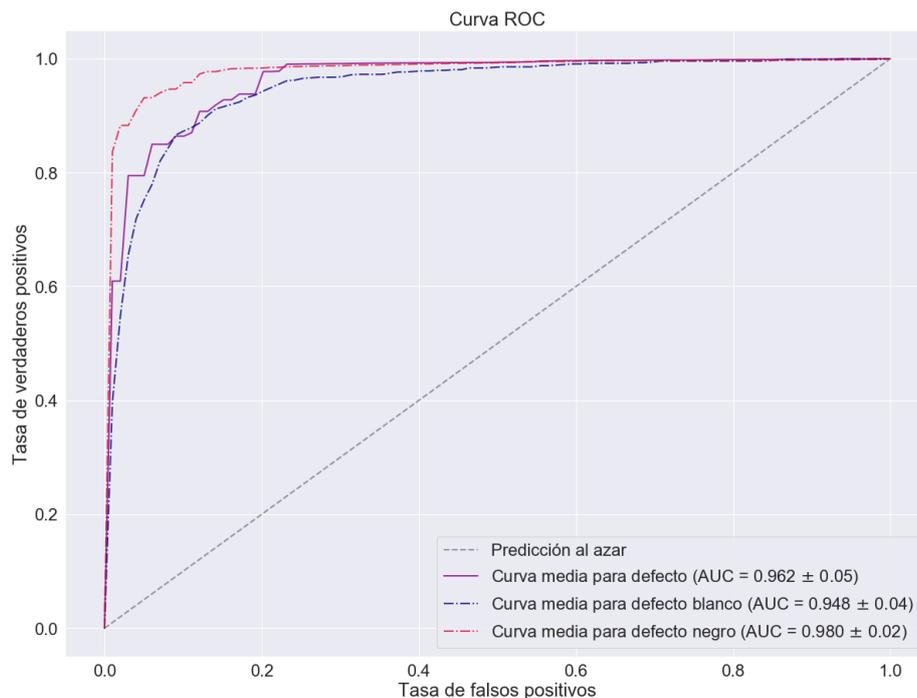


Figura 7.2: Ejemplo de curva ROC. El azar queda representado en gris y la curva como tal en morado. Las curvas ROC medias de defecto blanco y negro aparecen de color azul y rojo respectivamente.

7.1. Sistema de referencia

Con las imágenes procesadas con nuestros filtros como describe el apartado correspondiente 5.2, una primera aproximación consiste en hacer un cálculo aproximado del área de error y etiquetar como defectuosos en base a un umbral. Aquellos que superen este determinado valor umbral serán clasificados como defectuosos. Recordemos que la salida del proceso de filtrado serán dos imágenes cuyas matrices se compondrán solo de ceros y unos, correspondientes a la posible ausencia o presencia estimada de defecto respectivamente.

El área relativa se puede calcular aproximadamente de forma sencilla contando con las propiedades de la imagen (altura y anchura de la misma) así como con el total de píxeles de potenciales errores, tal y como se describió en la Sección 6.1.1.

Como estudio preliminar se desarrollarán dos posibles vías de trabajo en cuanto al sistema de referencia:

- **Dos umbrales:** se trabajará con un modelo de dos variables. Se definirán dos umbrales diferentes para clasificar en imagen con defecto negro-sin defecto negro (con el área de error relativa obtenida del procesamiento en negro) y en imagen con defecto blanco-sin defecto blanco (con el área de error relativa obtenida del procesamiento en blanco). La disyunción de ambas será la clasificación a tener en cuenta para definir la tasa de error.
- **Un umbral:** se trabajará con un modelo de una única variable. Un umbral desarrollado con la suma de áreas de error relativas halladas nos permitirá clasificar en imagen con defecto-sin defecto.

Se ha empleado para la selección del umbral la tasa de equierror (Sección 5.2.3). El umbral se ha seleccionado por separado en el Corpus I y en el II para seguir una línea de trabajo similar a la desarrollada con los clasificadores. Los resultados obtenidos aparecen reflejados a lo largo del correspondiente apartado en el capítulo de resultados (Sección 8.2).

7.2. Regresión Logística

La regresión logística es un modelo lineal generalizado empleado en aprendizaje supervisado [17]. Fue creado en 1958 por David Cox y se usa principalmente en casos en los que se busca hacer una clasificación binaria.

Para este modelo será básica la función logit, que definiremos como el logaritmo neperiano de la ventaja (odd) de un suceso. La Figura 7.3 muestra cómo la función en cuestión cuenta con dos asíntotas verticales situadas en el cero y en el uno.

$$\text{logit}(p) = \log\left(\frac{p}{1-p}\right)$$

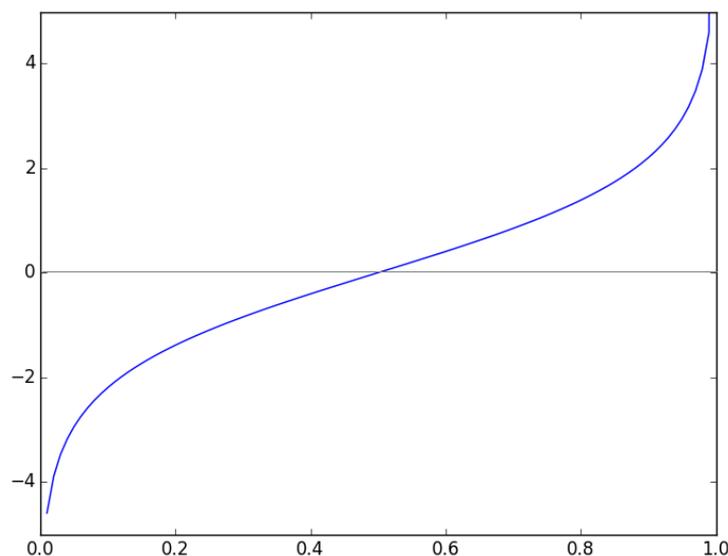


Figura 7.3: Representación de la función logit de p [18].

La regresión logística establece que la función logit de probabilidad de ocurrencia de un suceso (p) se puede expresar como la combinación lineal de una serie de variables regresoras [13]. El sumatorio de estas variables por lo tanto será ponderado por unos pesos o parámetros a ajustar. Suponiendo que disponemos de m variables de entrada al clasificador, podemos denominar a los parámetros como $\Theta = (\theta_0, \theta_1, \dots, \theta_m)$. El modelo incluye un parámetro θ_0 correspondiente al término independiente.

La expresión explícita del modelo a ajustar será:

$$\text{logit}(p) = \log\left(\frac{p}{1-p}\right) = \Theta X = \theta_0 + \theta_1 x_1 + \dots + \theta_m x_m$$

Con una sencilla transformación exponencial, podemos llegar a una expresión explícita del modelo que explique la probabilidad en vez de la función logit de esta:

$$\frac{p}{1-p} = e^{\theta_0 + \theta_1 x_1 + \dots + \theta_m x_m}$$

$$p = \frac{1}{1 + e^{-\theta_0 - \theta_1 x_1 - \dots - \theta_m x_m}}$$

Los parámetros se buscarán cumpliendo el criterio de máxima verosimilitud según el cual se optimizan los parámetros de tal forma que los resultados observados sean los más probables. No existe una expresión cerrada con la que trabajar para su optimización, por lo que se tiene que recurrir a métodos iterativos como el algoritmo de Newton-Raphson, el gradiente descendiente o el IRWLS. Los parámetros óptimos $\hat{\Theta}$ serán aquellos que minimicen la Log-verosimilitud ($\log L$), la cual depende además de los parámetros de los datos observados $(x, y) = (\bar{x}_1, y_1), \dots, (\bar{x}_n, y_n)$:

$$\hat{\Theta} = \underset{\Theta}{\text{mín}} - \log L(\Theta|x, y)$$

En la Figura 7.4 podemos ver la frontera definida por un procedimiento de regresión logística sencillo. Una de las características de esta técnica es que la salida del clasificador es una probabilidad. Esto nos permite refinar el clasificador con un parámetro umbral a mayores para realizar la separación de imágenes con defecto de las que no lo tienen.

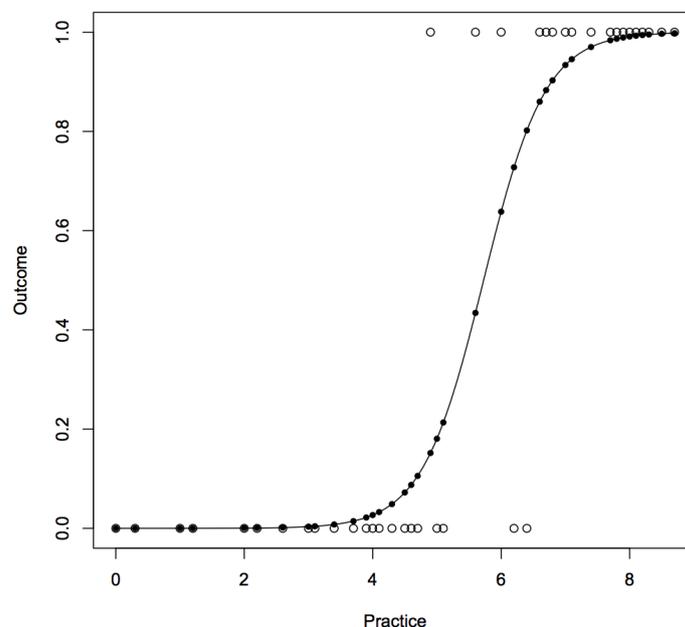


Figura 7.4: Representación de una regresión logística en un ejemplo sencillo: con más práctica, más probabilidades de éxito [19].

La regresión logística se utiliza en múltiples campos, sobre todo aquellos en los que se puede sacar partido a la propiedad de la salida en forma de probabilidad previamente mencionada. En medicina se emplea para analizar el estado del paciente [20]. Se ha empleado también para predecir resultados electorales así como en estudios de probabilidad de devolución de un préstamo [21].

Regularización

Para evitar problemas relacionados con el sobreajuste en los que el error de generalización es superior a la tasa de error observada en el conjunto de entrenamiento, se añade un término de regularización para los parámetros $R(\Theta)$ que depende a mayores de un nuevo parámetro λ .

$$\hat{\Theta} = \underset{\Theta}{\text{mín}} -\log L(\Theta|x, y) + \lambda R(\Theta)$$

Esto impide que los parámetros adquieran valores elevados y con ello el sobreajuste. Los dos términos de regularización más comunes dependen de la norma dos y la norma uno de un vector. Mientras que la norma dos resulta ser más sencilla de optimizar, la norma uno da lugar a parámetros dispersos. Esto supone que algunos sean nulos y con ello se haga una selección de variables.

- Regularización L1. Haciendo uso de la norma 1:

$$\hat{\Theta} = \underset{\Theta}{\text{mín}} -\log L(\Theta|x, y) + \lambda \|\Theta\|_1 = \underset{\Theta}{\text{mín}} -\log L(\Theta|x, y) + \lambda \sum_{i=0}^n |\theta_i|$$

Esta regularización da lugar a regiones en el espacio de soluciones con forma romboidal. En la Figura 7.5 se puede observar un ejemplo en un caso bidimensional.

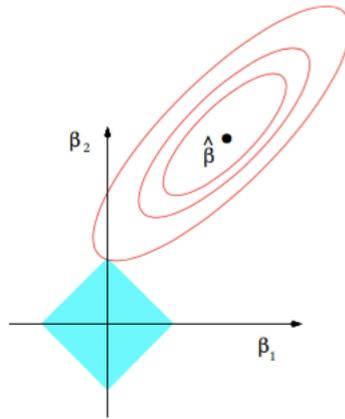


Figura 7.5: Regularización L1. Las regiones de soluciones factibles aparecen en azul claro mientras que las elipses rojas representan el contorno de la función de error [22].

- Regularización L2. Haciendo uso de la norma 2:

$$\hat{\Theta} = \underset{\Theta}{\text{mín}} -\log L(\Theta|x, y) + \frac{\lambda}{2} \|\Theta\|_2^2 = \underset{\Theta}{\text{mín}} -\log L(\Theta|x, y) + \frac{\lambda}{2} \sum_{i=0}^n \theta_i^2$$

Esta regularización da lugar a regiones en el espacio de soluciones con forma esferoidal. En la Figura 7.6 se puede observar un ejemplo en un caso bidimensional.

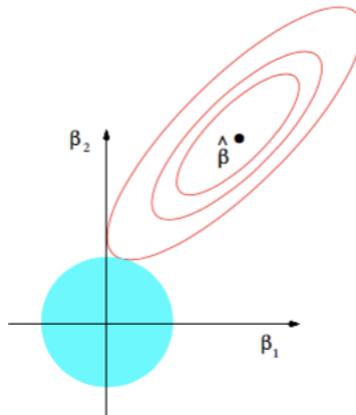


Figura 7.6: Regularización L2. Las regiones de soluciones factibles aparecen en azul claro mientras que las elipses rojas representan el contorno de la función de error [22].

Implementación usada

Se ha empleado Python junto al paquete sklearn [23] con la función de regresión logística correspondiente así como las funciones de estimación de curvas ROC y tasa de equierror por validación cruzada.

Previamente al entrenamiento del clasificador se han normalizado todos los datos de tal forma que cada una de las variables tuviese media cero y varianza uno.

En cada uno de los conjuntos de datos de los Corpus se ha estudiado la precisión alcanzada por dos modelos distintos, cada uno correspondiente a un tipo de regularización:

- Regularización L1. Se hace una búsqueda del parámetro λ óptimo que minimice la tasa de error estimada mediante validación cruzada. Se hace intrínsecamente la selección de variables con el entrenamiento del modelo al quedar algunos parámetros reducidos a cero.
- Regularización L2. Previamente al entrenamiento del clasificador se hace una selección recursiva de variables con la función RFE de sklearn. Posteriormente se entrena el clasificador optimizando el parámetro λ de regularización.

El modelo óptimo en cada uno de los conjuntos de datos de los Corpus, seleccionado entre el resultado óptimo de la regularización L1 y la regularización L2, aparece desarrollado en la Sección 8.3.

7.3. Support Vector Machine (SVM)

Algoritmos de aprendizaje asociados a problemas de clasificación y regresión [13]. Se basan en la definición del hiperplano de separación máxima entre las envolventes convexas de las clases. Alexey Ya. Chervonenkis y Vladimir N. Vapnik crearon este algoritmo en 1963. Este último desarrolló el potencial actual de los Support Vector Machines con las investigaciones sobre la función núcleo que publicó en 1992. El modelo original de SVM no permitía salidas probabilísticas. Sin embargo, desarrollos posteriores hacen posible esta salida.

El procedimiento básico de los Support Vector Machines se puede ilustrar de forma sencilla mediante un ejemplo bidimensional. En la Figura 7.7 podemos observar el diagrama de dispersión de dos tipos de individuos o clases, representados con cuadrados y círculos respectivamente.

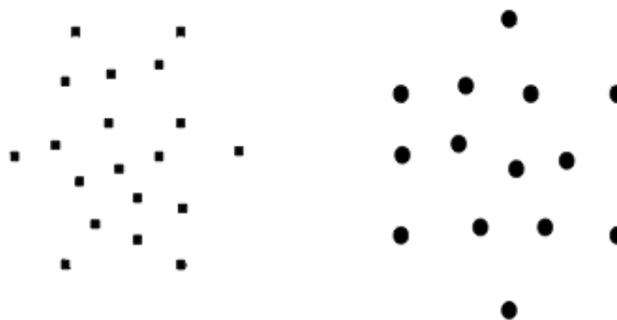


Figura 7.7: Representación bidimensional con dos clases [24].

El primer paso consistirá en trazar las envolventes convexas que cercan los puntos de cada una de las clases de individuos. Llamamos envolvente convexa de X a la intersección de todas las regiones convexas que contienen a S . En el caso de un plano, se puede definir como el polígono convexo que contiene a todos los puntos de X y cuyos vértices son algunos de estos puntos. La Figura 7.8 muestra las envolventes convexas correspondientes a nuestro ejemplo bidimensional.

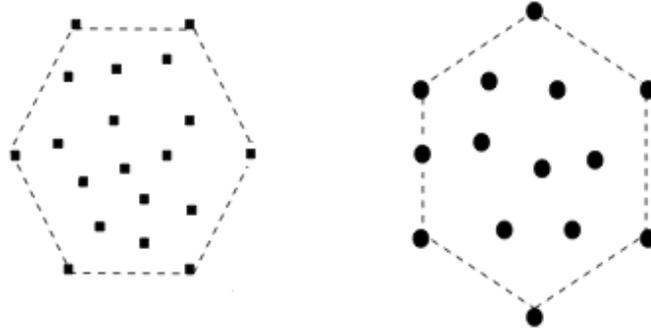


Figura 7.8: Definición de la envolvente convexa de cada una de las clases [24].

Posteriormente se toman una serie de puntos como referencia, los vectores o puntos soporte (Support Vectors), que permiten definir la frontera o hiperplano que discrimina entre clases en problemas de clasificación. Normalmente son las observaciones de las clases que perteneciendo a la envolvente se encuentran más próximas a la envolvente de la otra clase. La Figura 7.9 ilustra este paso en el caso de nuestro ejemplo de dos dimensiones.

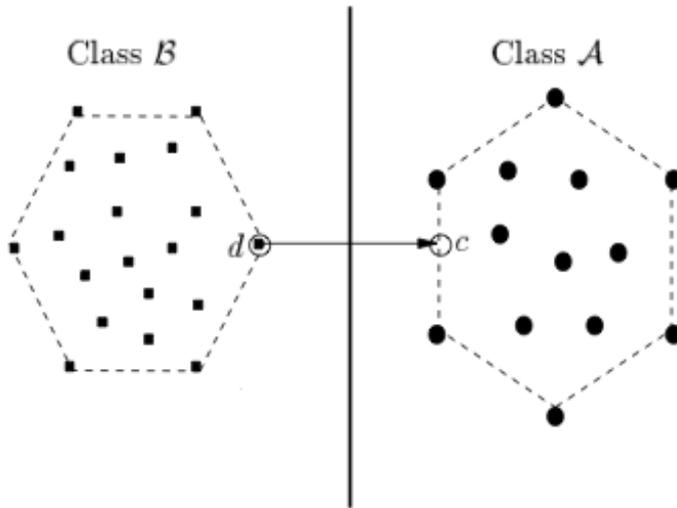


Figura 7.9: Definición de los Support Vectors (destacados con un círculo) y el hiperplano separador de margen máximo haciendo uso de las envolventes convexas [24].

Son modelos muy flexibles principalmente por la existencia del “kernel trick” o truco del núcleo [17], que permite separar puntos no linealmente separables proyectándolos a espacios de mayor dimensionalidad. Las funciones núcleo están relacionadas con el producto escalar y transforman una matriz en otra semidefinida positiva, es decir, con autovalores no negativos.

Se trata de clasificadores robustos y precisos cuyo coste computacional escala relativamente rápido. Son muy resistentes al sobreajuste y permiten que el modelo sea fácilmente almacenable al constar únicamente de los vectores soporte.

Han sido utilizados para la categorización de textos [25], en problemas de distinción de correo Spam por ejemplo, y en ámbitos relacionados con el reconocimiento de imágenes, como puede ser el problema de reconocimiento de dígitos escritos a mano [26]. Usos recientes apuntan a su utilidad en campos relacionados con la biología como es la clasificación proteica automática [27].

Los núcleos con los que se ha trabajado en este proyecto son el núcleo lineal, polinómico y de base radial. Otros núcleos populares son el sigmoide, el perceptrón o el de la tangente hiperbólica.

7.3.1. Núcleo lineal

Dado un conjunto de entrenamiento de datos $(\bar{x}_1, y_1), \dots, (\bar{x}_n, y_n)$ en los que las x son los vectores de variables explicativas de cada una de las observaciones y la variable y representa una clasificación dicotómica (-1 y 1), el núcleo lineal busca aquel hiperplano lineal cuyo margen de separación sea máximo.

Podemos definir un hiperplano cualquiera de la siguiente forma, siendo \bar{w} un vector de pesos normal al hiperplano separador y b un término independiente.

$$\bar{w} \cdot \bar{x} - b = 0$$

El objetivo se puede definir fácilmente con una expresión cerrada:

$$y_i(\bar{w} \cdot \bar{x} - b) \geq 1 \text{ para todo } 1 \leq i \leq n$$

Sin embargo, cuando los datos no son linealmente separables hace falta introducir una función de pérdida

$$l(y) = \max(0, 1 - y_i(\bar{w} \cdot \bar{x} - b))$$

La expresión a minimizar tomará la siguiente forma:

$$\frac{1}{n} \sum_{i=1}^n \max(0, 1 - y_i(\bar{w} \cdot \bar{x} - b))$$

A mayores se define un parámetro de regularización. Dependiendo de la norma utilizada, tiene un efecto u otro. La más utilizada es la norma dos, lo que da lugar a una regularización Ridge.

$$\left[\frac{1}{n} \sum_{i=1}^n \max(0, 1 - y_i(\bar{w} \cdot \bar{x} - b)) \right] + \lambda \|\bar{w}\|_2$$

Sin embargo en este proyecto se ha usado la norma uno o penalización Lasso cuya principal ventaja es la posibilidad de anular coeficientes de parámetros y de este modo hacer un procedimiento de selección de variables.

$$\left[\frac{1}{n} \sum_{i=1}^n \max(0, 1 - y_i(\bar{w} \cdot \bar{x} - b)) \right] + \lambda \|\bar{w}\|_1$$

La elección del parámetro de regularización supone calibrar el modelo ajustado y evitar el sobreajuste. También supone una definición de márgenes diferentes, pudiéndose con la modificación de λ estrecharse o ampliarse estos. La Figura 7.10 muestra la diferencia que supone aplicar el núcleo lineal con y sin regularización en el conjunto de datos sobre flores Iris.

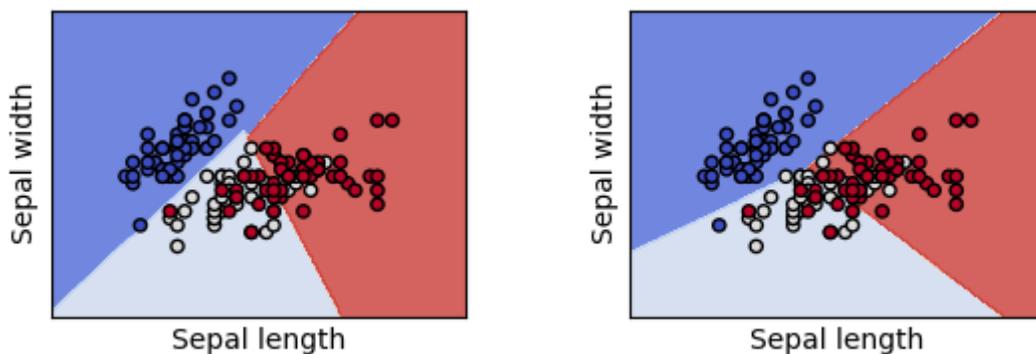


Figura 7.10: Representación de los tipos de flores Iris en función del tamaño y anchura de su sépalo acompañados del margen definido por un SVM de núcleo lineal. En la izquierda se ha aplicado sin regularización, mientras que en la derecha se ha regularizado [28].

7.3.2. Núcleo polinómico

El núcleo polinómico busca hiperplanos cuyo margen de separación sea equivalente a una función de un determinado grado. Este grado se tendrá que definir previamente como un parámetro p . Valores altos de p dan lugar a sobreajuste, por lo que conviene que no se alcancen valores muy elevados con este parámetro.

En los Support Vector Machines en los que se emplea el núcleo que no es lineal se sustituye el producto escalar por otras funciones. En el caso del núcleo polinómico, la función núcleo empleada es:

$$K(\bar{x}_i, \bar{x}_j) = (\bar{x}_i \cdot \bar{x}_j)^p$$

El núcleo lineal previamente explicado sería un caso particular de este núcleo en el que $p = 1$.

Al igual que ocurría con el núcleo lineal, existe la posibilidad de añadir un término de regularización λ para controlar el sobreajuste. Se ha aplicado la norma dos o cuadrática en el caso de la regularización de los SVM de núcleo polinómico.

La Figura 7.11 muestra la diferencia que supone aplicar el núcleo lineal y el polinómico con $p = 3$ en el conjunto de datos sobre flores Iris. La frontera ha adquirido en el caso del núcleo polinómico la forma propia de una función de tercer grado.

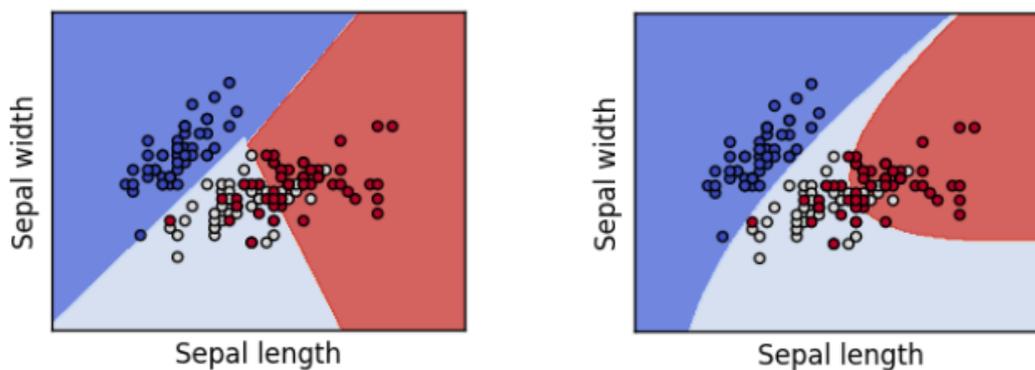


Figura 7.11: Representación de los tipos de flores Iris en función del tamaño y anchura de su sépalo acompañados del margen definido por un SVM de núcleo lineal sin regularización (izquierda) y un SVM de núcleo polinómico de grado tres (derecha) [28].

7.3.3. Núcleo de base radial (Radial Based Function - RBF)

El núcleo de base radial busca un hiperplano cuyo margen de separación sea máximo cuya frontera pueda ser más flexible que la que resulta de usar un núcleo lineal o polinómico. Llamamos función de base radial a una función en la que el valor depende de un origen o centro de coordenadas. Emplean normalmente la norma euclídea para el cálculo de distancias y tienen multitud de usos dentro del análisis de datos, como puede ser las redes neuronales de base radial.

La nueva función núcleo que emplearemos con los SVM de base radial empleará la norma euclídea, como ya se ha mencionado, y un parámetro σ . El núcleo se definirá de la siguiente forma:

$$K(\bar{x}_i, \bar{x}_j) = e^{-\frac{\|\bar{x}_i - \bar{x}_j\|^2}{2\sigma^2}}$$

Esta función toma un valor más pequeño según la distancia y toma valores entre 0 y 1. Una interpretación directa de este valor es la medida de similitud entre observaciones.

Aparece también un nuevo parámetro que ajustar σ . Este parámetro mide la apertura de la forma acampanada que surge como frontera al usar esta técnica. Un valor pequeño de σ hará más grandes las disimilaridades entre observaciones, mientras que uno grande las reducirá.

El término de regularización acompañado del parámetro λ existe también en este tipo de núcleo. En el caso del núcleo de base radial normalmente el término de regularización que se aplica emplea la norma dos (regularización L2). Esto se debe principalmente a la complejidad del problema, que no escala adecuadamente con la regularización L1 cuando el número de muestras es elevado.

La Figura 7.12 muestra la diferencia que supone aplicar un núcleo lineal y uno radial en el conjunto de datos sobre flores Iris. Tal y como podemos ver, las fronteras que define el núcleo radial son más flexibles debido a su forma curva.

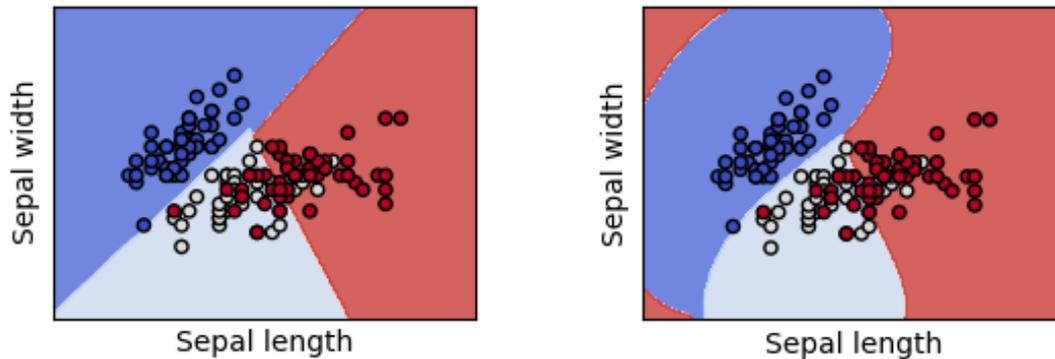


Figura 7.12: Representación de los tipos de flores Iris en función del tamaño y anchura de su sépalo acompañados del margen definido por un SVM de núcleo lineal sin regularización (izquierda) y un SVM de núcleo radial (derecha) [28].

Implementación utilizada

Se ha desarrollado haciendo uso del lenguaje de programación Python con ayuda del paquete de aprendizaje sklearn [23]. Se ha empleado la función SVC para la creación de los Support Vector Machines de núcleo de base radial y los de núcleo polinómico, mientras que la función LinearSVC ha servido para la creación de los de núcleo lineal. Previamente al entrenamiento del clasificador se han normalizado todos los datos de tal forma que cada una de las variables tuviese media cero y varianza uno.

El parámetro γ del núcleo de base radial y el grado del polinomio p del núcleo polinómico se han optimizado mediante la función de validación cruzada GridSearchCV. Este parametro equivale a:

$$\gamma = \frac{1}{2\sigma^2}$$

El parámetro de regularización C también se ha optimizado con esta función. Con los Support Vector Machines creados con núcleo lineal se ha utilizado penalización L1 mientras que los de base radial y polinómico se han regularizado mediante norma 2. La relación del parámetro C con λ es la siguiente:

$$C = \frac{1}{\lambda}$$

Las tasas de error y las matrices de confusión se han estimado mediante funciones de validación cruzada (10 particiones) propias de sklearn, al igual que la estimación de curvas medias ROC (y áreas subyacentes) y tasa de equierror.

7.4. Redes Neuronales (Neural Networks)

Sistemas de computación cuya arquitectura original se basa en el funcionamiento del cerebro [13]. Son modelos capaces de obtener excelentes resultados en complejas tareas a través del cómputo intensivo de una colección de datos suficientemente grande.

A la unidad básica de cómputo de las redes neuronales se la llama neurona. Esto se debe principalmente a su similitud con lo que sería la morfología de una célula nerviosa del cerebro animal, tal y como podemos ver en la Figura 7.13.

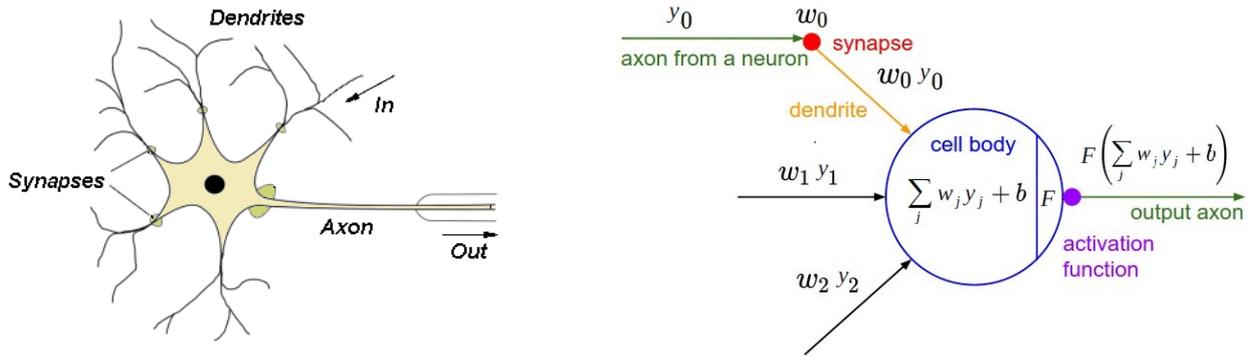


Figura 7.13: Estructura de la unidad básica de una red neuronal (derecha) comparada con la célula biológica (izquierda) [29].

El diseño original de estas redes fue lo que se denominó el modelo de McCulloch-Pitts (1943) en el que el funcionamiento unitario de la neurona consta de dos operaciones básicas. Primero se realiza la suma de la ponderación de las m entradas $Y = (y_1, \dots, y_m)$ por unos pesos que denominaremos $W = (w_1, \dots, w_m)$. A esta suma se le añade un término independiente (b). Las entradas Y pueden ser las variables de entrada al clasificador o pueden ser la salida de otras neuronas dependiendo de la capa en la que este situada la neurona en cuestión. La función de propagación de la neurona j situada en una capa de la red neuronal será el resultado de la suma ponderada de sus entradas más un término independiente:

$$u_j = \sum_{i=1}^m w_i y_i + b$$

Al tratarse de una suma ponderada de términos es de vital importancia la normalización o estandarización de los datos. De no hacerse podría dar lugar a un problema en el que no hubiese convergencia hacia una solución.

Posteriormente se aplica a la función de propagación una función que acota la salida de la neurona. Esta función se la denomina de activación. Son monótonas crecientes y la característica de que sean derivables monótonas es deseable.

$$y_j = F(u_j) = F\left(\sum_{i=1}^m w_i y_i + b\right)$$

Las funciones de activación más empleadas son:

- Identidad. Recorrido = $(-\infty, \infty)$.

$$F(x) = x$$

- Unitaria. Recorrido = $\{0, 1\}$.

$$F(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$$

- Sigmoide. Recorrido = $(0, 1)$.

$$F(x) = \frac{1}{1 + e^{-x}}$$

- Tangente hiperbólica. Recorrido = $(-1, 1)$.

$$F(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

- Arco tangente. Recorrido = $(\frac{-\pi}{2}, \frac{\pi}{2})$.

$$F(x) = \tan^{-1}(x)$$

- Unidad de raíz cuadrada inversa (Inverse Square Root Unit). Recorrido = $(\frac{-1}{\sqrt{\alpha}}, \frac{1}{\sqrt{\alpha}})$.

$$F(x) = \frac{x}{\sqrt{1 + \alpha x^2}}$$

- Unidad lineal rectificada (Rectified Linear Unit - ReLU). Recorrido = $[0, \infty)$.

$$F(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$$

Existen muchos tipos de redes neuronales y se clasifican de distintas formas. Una posible forma es si son redes sin realimentación o con realimentación. Llamamos realimentación a la existencia de arcos conectores entre neuronas de una capa con otras pertenecientes a otra capa anterior. Las redes con realimentación suelen tener hipótesis más complejas y precisas en los problemas a cambio de una mayor opacidad en el funcionamiento del algoritmo. La Figura 7.14 muestra esta clasificación básica en el caso de varios tipos de redes neuronales.

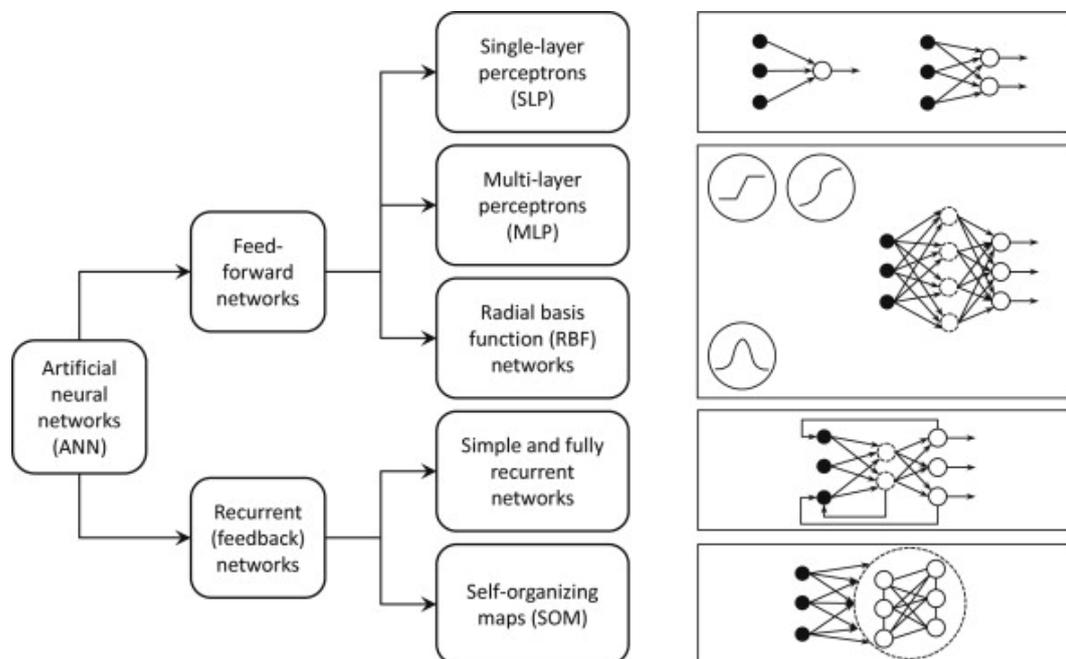


Figura 7.14: Clasificación básica de las redes neuronales sin realimentación y con realimentación [30].

Este proyecto se ha centrado principalmente en un tipo de red neuronal: los perceptrones de múltiples capas como tipo de red neuronal artificial de propagación sin realimentación.

7.4.1. Perceptrón multicapa (Multi-Layer Perceptron - MLP)

Red neuronal sin realimentación que consta de una capa de entrada, una o varias capas ocultas y una capa de salida, tal y como podemos ver en la Figura 7.15.

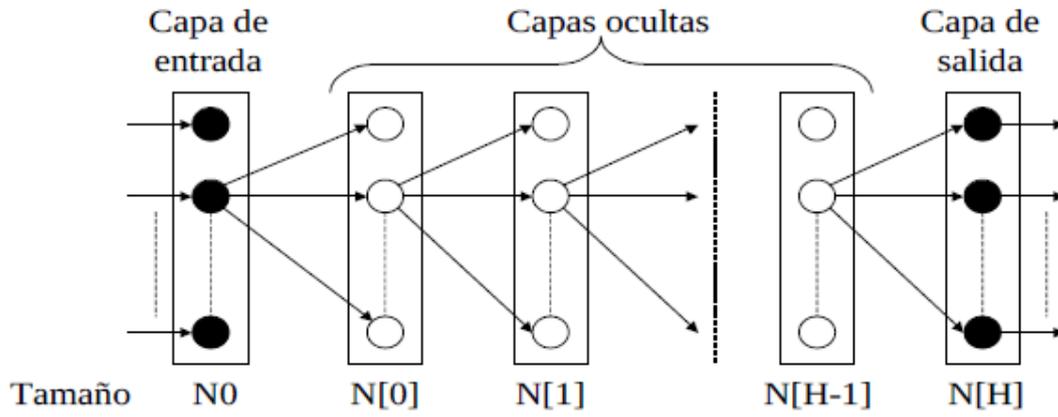


Figura 7.15: Estructura general de un perceptrón multicapa [13].

- La capa de entrada constará de tantas neuronas como variables de entrada tenga el clasificador (N_0 variables de entrada).
- Las capas ocultas, plenamente conectas, tendrán una arquitectura que habrá que determinar en función de los resultados obtenidos. El número de capas ocultas lo denominaremos H . El número de neuronas de la capa oculta i será $N[i - 1]$, pudiendo tomar i valores entre $1, 2, \dots, H$.
- La capa de salida tendrá tantas neuronas como salidas se deseen. El número de neuronas de la capa de salida lo denominaremos $N[H]$. En nuestro caso, al tratarse de un problema de clasificación binario la capa de salida tendrá una única neurona.

Las neuronas que los componen realizan una suma ponderada para posteriormente emplear cualquiera de las funciones de activación previamente mencionadas. Las dos más empleadas son la tangente hiperbólica y la sigmoide. La Figura 7.16 representa el funcionamiento básico de una neurona.

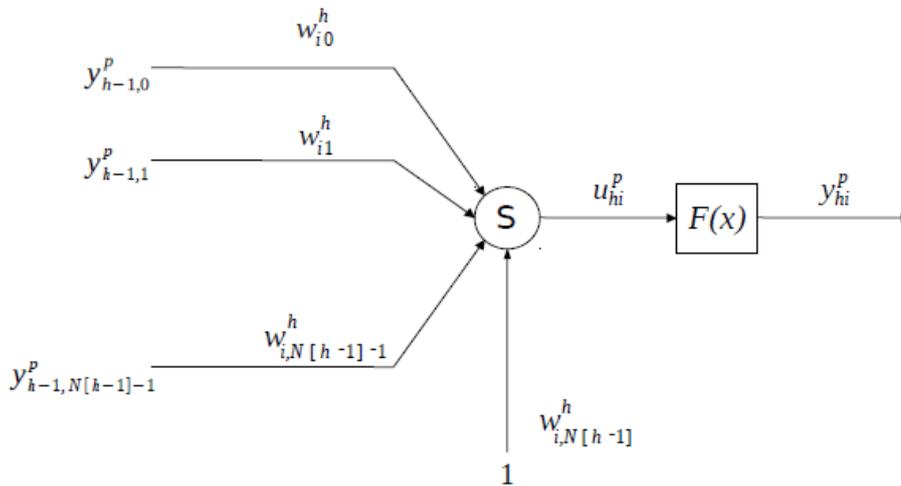


Figura 7.16: Procedimiento básico realizado por una neurona i de una capa oculta h con función de activación F procesando la observación p [13].

La salida y_{hi}^p de una neurona i que forma parte de una capa oculta h que está procesando la observación p cuya función de activación es F se puede expresar como:

$$y_{h,i}^p = F(u_{hi}^p)$$

$$u_{hi}^p = \begin{cases} \left(\sum_{j=0}^{N[h-1]-1} w_{ij}^h y_{h-1,j}^p \right) + w_{i,N[h-1]}^h & \text{si } \forall h = 1, 2, 3, \dots, H \\ \left(\sum_{j=0}^{N_0-1} w_{ij}^0 I_j^p \right) + w_{i,N_0}^h & \text{en la capa de entrada } (h = 0) \end{cases}$$

El complejo proceso de aprendizaje de estos sistemas se llama retropropagación del error. Si contamos con un conjunto de datos X de dimensiones n observaciones \times m variables y de variable respuesta y , podemos expresar el error cuadrático medio de la muestra p -ésima del conjunto de datos en función de la salida del perceptrón actual (que llamaremos d):

$$E_p = \frac{1}{2} \sum_{i=0}^{N[H]-1} (d_i^p - y_{Hi}^p)^2$$

Esto hará variar el peso de las neuronas. En el caso de la neurona i de la capa h :

$$\Delta_p w_{ij}^h = -\gamma \frac{\partial E_p}{\partial w_{ij}^h}$$

Si aplicamos la regla de la cadena, esto queda de la siguiente forma en la capa h :

$$\Delta_p w_{ij}^h = -\gamma \frac{\partial E_p}{\partial y_{hi}^p} \frac{\partial y_{hi}^p}{\partial w_{ij}^h} = -\gamma \frac{\partial E_p}{\partial y_{hi}^p} F'(u_{hi}^p) y_{h-1,j}^p \quad \forall h = 1, 2, 3, \dots, H$$

En la primera capa la expresión sería la siguiente:

$$\Delta_p w_{ij}^0 = -\gamma \frac{\partial E_p}{\partial y_{0i}^p} \frac{\partial y_{0i}^p}{\partial w_{ij}^0} = -\gamma \frac{\partial E_p}{\partial y_{0i}^p} F'(u_{0i}^p) I_j^p$$

Esta expresión tomará la siguiente forma en la capa de salida:

$$\Delta_p w_{ij}^h = \gamma (d_i^p - y_{Hi}^p) F'(u_{Hi}^p) y_{H-1,j}^p$$

Tal y como podemos ver esta variación de los pesos depende de un parámetro γ . Este parámetro controla la velocidad de aprendizaje del sistema y en función del algoritmo que se utilice se mantiene constante o se va variando según se procesa el conjunto de entrenamiento. La optimización de los pesos se realizará mediante diversas épocas (paso por todas las muestras del experimento).

Los perceptrones multicapa son capaces de hallar soluciones a complejos problemas, ya que son capaces de distinguir datos que no son separables linealmente. Permiten a través de un cómputo de cierta complejidad obtener modelos de alta capacidad para problemas como es el reconocimiento del habla [31] o el reconocimiento de imágenes [32]. Los perceptrones multicapa sentaron la base para lo que posteriormente se exploraría como el campo del Deep Learning o aprendizaje profundo.

Implementación utilizada

Se ha desarrollado haciendo uso del lenguaje de programación Python con ayuda del paquete de aprendizaje sklearn [23]. Se ha empleado la función MLPClassifier para la creación de los perceptrones multicapa.

Previamente al entrenamiento del clasificador se han normalizado todos los datos de tal forma que cada una de las variables tuviese media cero y varianza uno. Esto cobra especial importancia en el caso del perceptrón múltiple y al usar funciones de activación como la unidad lineal rectificadas. Si no se escalasen los datos, el procedimiento de entrenamiento podría no converger a una solución consistente.

La función de validación cruzada GridSearchCV ha servido para hallar los valores óptimos referentes a:

1. Arquitectura de las capas ocultas: número de capas ocultas y número de neuronas en estas.
2. Función de activación.
3. Parámetro de regularización α .
4. Tipo de aprendizaje.

Para cada uno de los modelos desarrollados se han creado visualizaciones de las arquitecturas de capas de los perceptrones [33].

La salida del perceptrón se ha establecido que fuese una probabilidad. El obtener la salida en esta forma permite diversas ventajas como es la definición de la curva ROC asociada al clasificador y medidas como el área bajo la curva o la tasa de equierror.

Las tasas de error y las matrices de confusión se han estimado mediante validación cruzada de 10 particiones con la precaución de la correcta estratificación según distribución de clases de cada una de las particiones empleadas.

Capítulo 8

Resultados

En esta sección se valorará el rendimiento obtenido por cada uno de los clasificadores, entendiendo el rendimiento como nivel de acierto obtenido con el modelo en cuestión correspondiente a uno de los Corpus. Será relevante comparar los resultados de los clasificadores con el rendimiento obtenido por “Smart Eyes”, el sistema en funcionamiento en Tradema, y con un sistema de clasificación de referencia. Esto será una clasificación sencilla con un umbral, tal y como aparece descrito en el Apartado 8.2.

8.1. Sistema “Smart Eyes”

El número de tableros que clasifica mal (tanto falsos positivos como falsos negativos) es en principio desconocido. Por lo tanto, se trata de un sistema en el que no existe ningún tipo de medida de rendimiento de forma inmediata. Aunque detecta muchos defectos, crea también muchos avisos que son falsos positivos.

Todos los resultados de rendimiento que obtendremos en este proyecto de este sistema están muy sesgados: son datos obtenidos únicamente por las observaciones del Corpus I. Este Corpus, tal y como se explica en el Apartado 4.2.1, se compone solo de imágenes que el sistema ha etiquetado como defectuosas. Definimos un tipo de defecto detectado a mayores que se da en la salida de “Smart Eyes”:

- **Defecto detectado por fallo lumínico:** deficiencia del sistema “Smart Eyes” relacionada con el filtrado de blancos del sistema en imágenes con problemas de heterogeneidad de luz. Se da de forma distinta en imágenes sin defectos que en las que los tienen:
 - En imágenes sin defectos, “Smart Eyes” detecta defectos por la diferencia de luz donde realmente no los hay como tal. Las Figuras 8.1 y 8.2 muestran un ejemplo de imagen sin defectos en la que el sistema filtrando ha cometido un error por fallo lumínico. Las Figuras 8.3 y 8.4 muestran otro caso más extremo donde la excesiva iluminación ha dado lugar a un incorrecto etiquetado de la imagen como defectuosa.

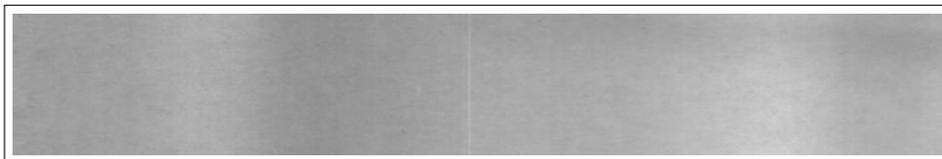


Figura 8.1: Imagen sin defectos con problemas en la homogeneidad de la iluminación.



Figura 8.2: Imagen filtrada. La zona con más brillo se detecta erróneamente como defectuosa.

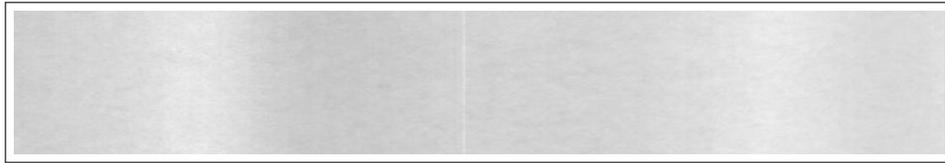


Figura 8.3: Imagen sin defectos con más problemas de homogeneidad de luz.

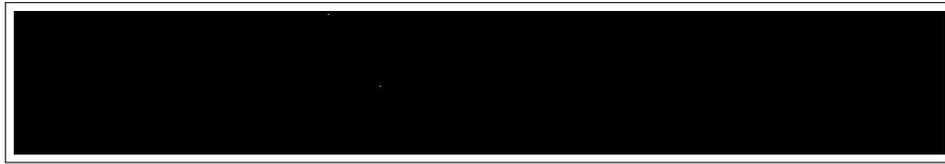


Figura 8.4: Imagen filtrada. El sistema tiene aquí un comportamiento errático.

- En los casos de imágenes con defectos, “Smart Eyes” la identifica correctamente como defectuosa. Sin embargo las áreas de error se marcan de forma errónea por lo que es en cierto modo una detección fortuita del defecto, tal y como podemos observar en las Figuras 8.5 y 8.6

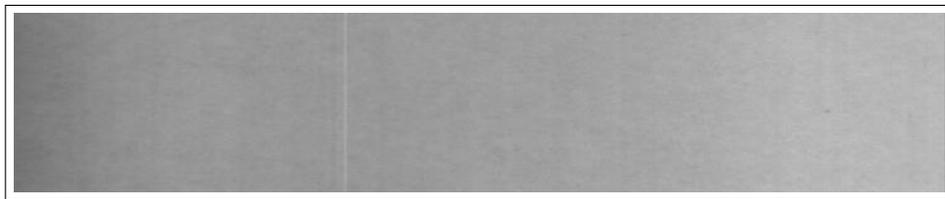


Figura 8.5: Imagen con problemas de iluminación que contiene un defecto negro de pequeño tamaño.



Figura 8.6: Imagen filtrada. El sistema detecta defecto, pero no ha marcado como defecto el auténtico defecto.

Con la definición de este error, podemos determinar la matriz de confusión de este sistema. La matriz de confusión aparece en la Tabla 8.1 así como su versión simplificada en la Tabla 8.2. Es relevante recordar que no tenemos acceso a las imágenes que ha detectado “Smart Eyes” como carentes de defectos, lo que da lugar a que ambas matrices de confusión tengan una fila sin datos.

		Defecto real en la imagen			
		Sin defectos	Negro	Blanco	Negro+Blanco
Defec. detectado	Sin defectos	-	-	-	-
	Negro	0	5475	0	2
	Blanco	61	1	520	1
	Negro+Blanco	0	0	0	451
	Fallo lumínico	648	13	4	5

Tabla 8.1: Matriz de confusión del sistema “Smart Eyes”.

Matriz de confusión simplificada de “Smart Eyes”			
		Clase	
		Sin defecto	Con defecto
Etiqu.	Sin defecto	-	-
	Con defecto	709	6458

Tabla 8.2: Matriz de confusión simplificada (clase de la imagen y clasificación asignada) del sistema “Smart Eyes”.

Podemos hacer algunas valoraciones con respecto al filtrado hecho por “Smart Eyes” a la vista de los resultados obtenidos:

- El filtrado de negro funciona bastante bien. Aún así detecta zonas especialmente oscuras y a veces zonas defectuosas más claras no son correctamente marcadas. Se genera ruido en el filtrado habitualmente. En las Figuras 8.7 y 8.8 podemos ver un ejemplo de estas dos particularidades mentadas.



Figura 8.7: Imagen del Corpus I con defectos negros de distinta oscuridad.



Figura 8.8: Imagen filtrada. Observamos ruido a la derecha y zonas no detectadas como defectuosas.

- El filtrado de blancos, aún siendo más complejo que el de negros, tiene muchos problemas con las imágenes en las que la luz no es homogénea. Esto da lugar al defecto por fallo lumínico previamente mencionado.

Teniendo en cuenta la matriz de confusión podemos hacer una estimación parcial altamente sesgada de la tasa de error. Este sesgo se deberá a la ausencia de datos de las imágenes sin defectos.

Tasa parcial de acierto estimada de “Smart Eyes”		
	Tasa de acierto	Intervalo de confianza del 95 %
Smart Eyes	90.107 %	(89.416, 90.798)

Tabla 8.3: Estimación altamente sesgada de la tasa de acierto para el sistema en funcionamiento en la fábrica -“Smart Eyes”-.

8.2. Sistema de referencia

Siguiendo las pautas expuestas en la sección 7.1, se han evaluado las curvas ROC y la tasa de equierror obtenidas empleando independientemente el área de error relativa hallada en el filtrado de negros y en el de blancos y la obtenida empleando la suma de ambas (área de error relativa en blanco + área de error relativa en negro). La definición de umbrales y de resultados obtenidos se hará por separado para el Corpus I y el II.

Posteriormente se han definido modelos con un umbral para el estudio más concreto sobre los que definir la tasa de acierto, especificidad y sensibilidad.

8.2.1. Corpus I

En el caso del Corpus I, se obtienen resultados básicos altamente satisfactorios, tal y como podemos observar en las curvas ROC (área de error relativa en blanco y área de error relativa en negro por separado Figura 8.9; con la suma de ambas: Figura 8.10) así como en los valores de la tasa de equierror y AUC (Tabla 8.4). Esto se debe primordialmente al excelente funcionamiento del filtrado en imágenes cuya resolución es muy alta.

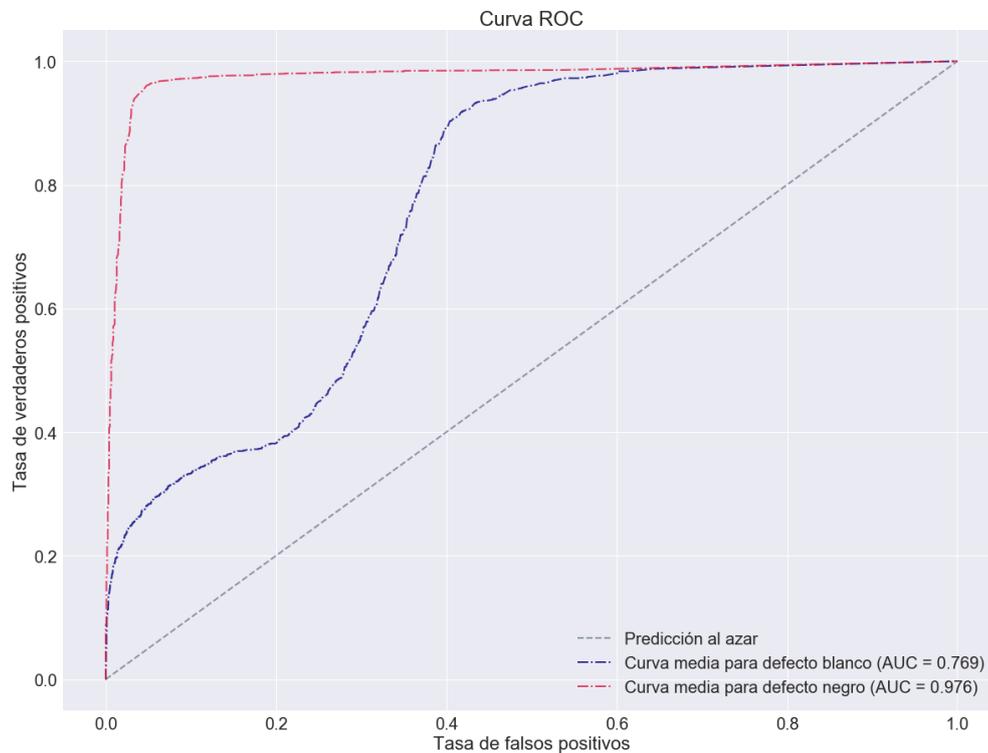


Figura 8.9: Curvas ROC del sistema de referencia empleando por separado área de error relativa en blanco (azul) y área de error relativa en negro (rojo) del Corpus I.

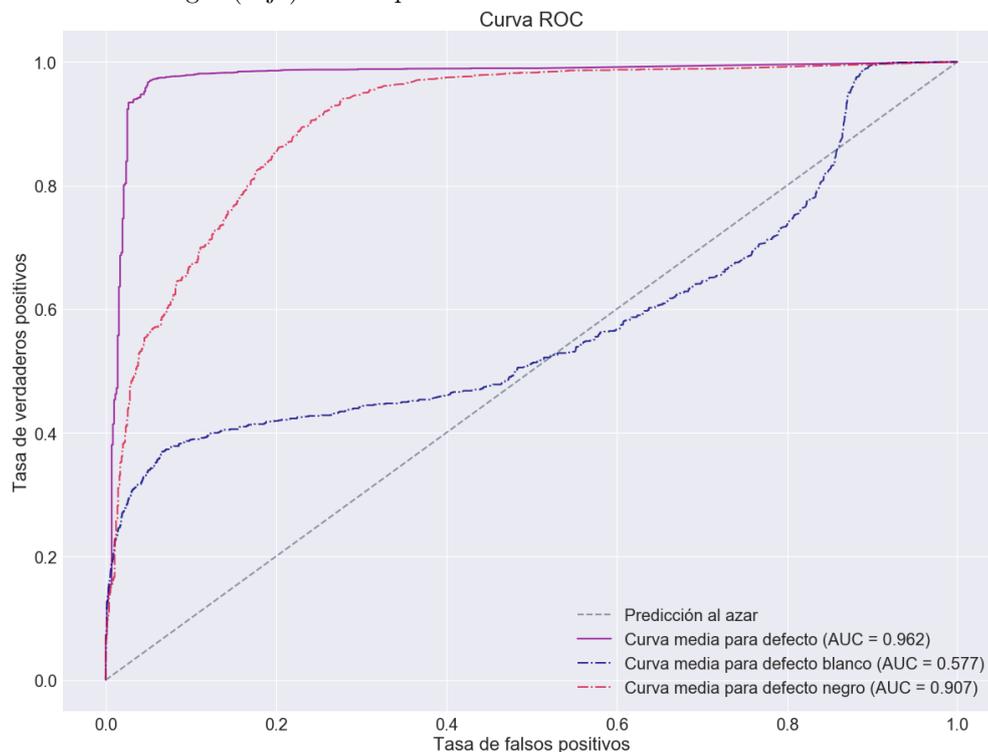


Figura 8.10: Curva ROC del sistema de referencia empleando la suma de las áreas de error relativas en negro y blanco para la clasificación con defecto - sin defecto del Corpus I.

Resultados del sistema de referencia en el Corpus I			
		Tasa de equierror (EER)	Area Under Curve (AUC)
Suma de áreas de error		0.046	0.962 { Negro: 0.907 Blanco: 0.577
Áreas de error por separado	Negro	0.044	0.976
	Blanco	0.333	0.769

Tabla 8.4: Estimación de la tasa de equierror y el área bajo la curva ROC del sistema de referencia con el Corpus I. En el caso de usarse la suma de áreas de error se ha calculado el AUC para cada clase de error.

En el caso del uso de la suma de las áreas de error relativas, los valores de la AUC y de la EER son excelentes. La posterior comparativa entre el área bajo la curva ROC de las clases con defecto negro-sin defecto negro y la correspondiente a con defecto blanco-sin defecto blanco pone en evidencia el funcionamiento deficiente del sistema con los defectos blancos.

Usando las dos áreas de error relativa por separado se obtiene un sistema de características similares al anterior. La discriminación de defectos blancos tan solo por el área de error relativa es compleja, llegando a mal clasificarse cerca del 30% de las observaciones al igualarse las tasas de falsos positivos y falsos negativos.

Los modelos de umbral ajustado según la tasa de equierror seleccionados obtienen resultados básicos altamente satisfactorios, tal y como podemos observar en las tablas de resultados (Tablas 8.5 y 8.6).

Sistema de referencia (1 umbral) -Corpus I-					
		Clase			
		Sin Defecto	Con defecto		
Etiqueta	Sin Defecto	676	271	947	<ul style="list-style-type: none"> ■ Tasa de acierto: 95.75 % Intervalo de confianza del 95 %: (95.28, 96.21) ● Sensibilidad: 95.80 % ● Especificidad: 95.34 %
	Con defecto	33	6187	6220	
		709	6458	7167	

Tabla 8.5: Matriz de confusión y tasa de acierto con el uso de 1 umbral (área relativa de error en negro + área relativa de error en blanco) en Corpus I.

Sistema de referencia (2 umbrales) -Corpus I-					
		Clase			
		Sin Defecto	Con defecto		
Etiqueta	Sin Defecto	684	286	970	<ul style="list-style-type: none"> ■ Tasa de acierto: 95.66 % Intervalo de confianza del 95 %: (95.19, 96.13) ● Sensibilidad: 95.57 % ● Especificidad: 96.47 %
	Con defecto	25	6172	6197	
		709	6458	7167	

Tabla 8.6: Matriz de confusión y tasa de acierto con el uso de 2 umbrales (uno para área relativa de error en negro y otro para la de blanco) en Corpus I.

Las matrices de confusión reflejan cómo con dos umbrales el número de falsos positivos es menor que con uno, mientras que la tasa de falsos negativos es inferior con un umbral. Las tasas de acierto nos indican que el uso de dos umbrales da lugar a resultados globales ligeramente mejores. La especificidad y sensibilidad de los modelos son elevadas y equilibradas.

8.2.2. Corpus II

Con el Corpus II los resultados que obtenemos con el sistema de referencia son menos satisfactorios, tal y como vemos en las curvas ROC (con dos umbrales: Figura 8.11; con un umbral: Figura 8.12) así como en los valores de la tasa de equierror y AUC (Tabla 8.7). Al haber sido la fuente de estas imágenes un vídeo, la resolución de los fotogramas extraídos es menor que la del Corpus I.

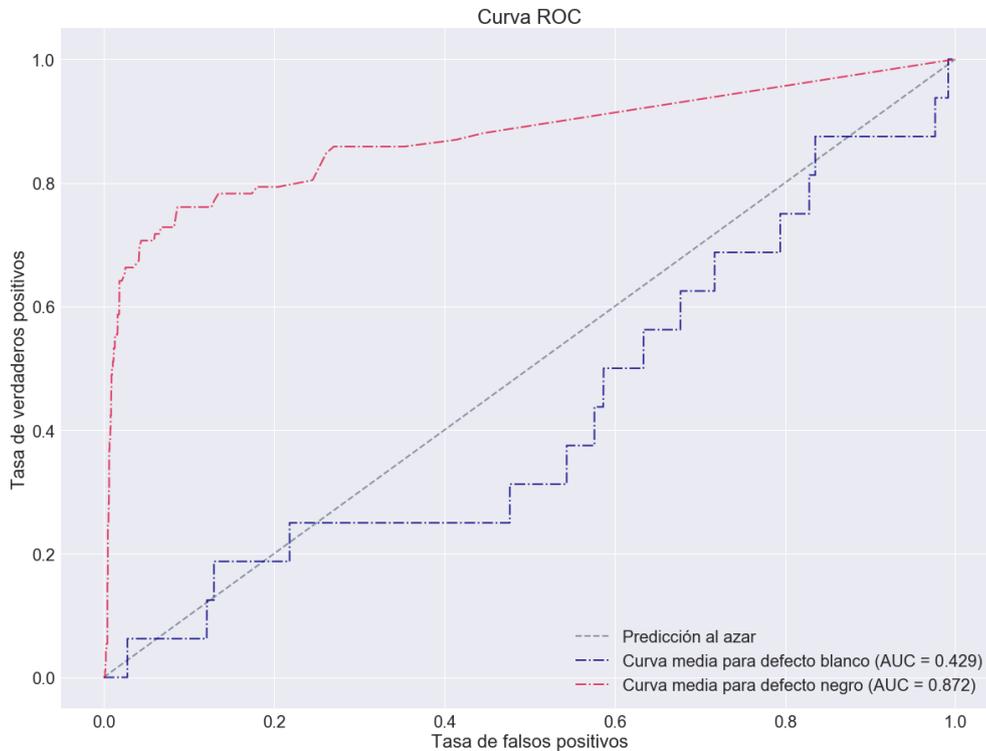


Figura 8.11: Curvas ROC del sistema de referencia empleando por separado área de error relativa en blanco (azul) y área de error relativa en negro (rojo) del Corpus II.

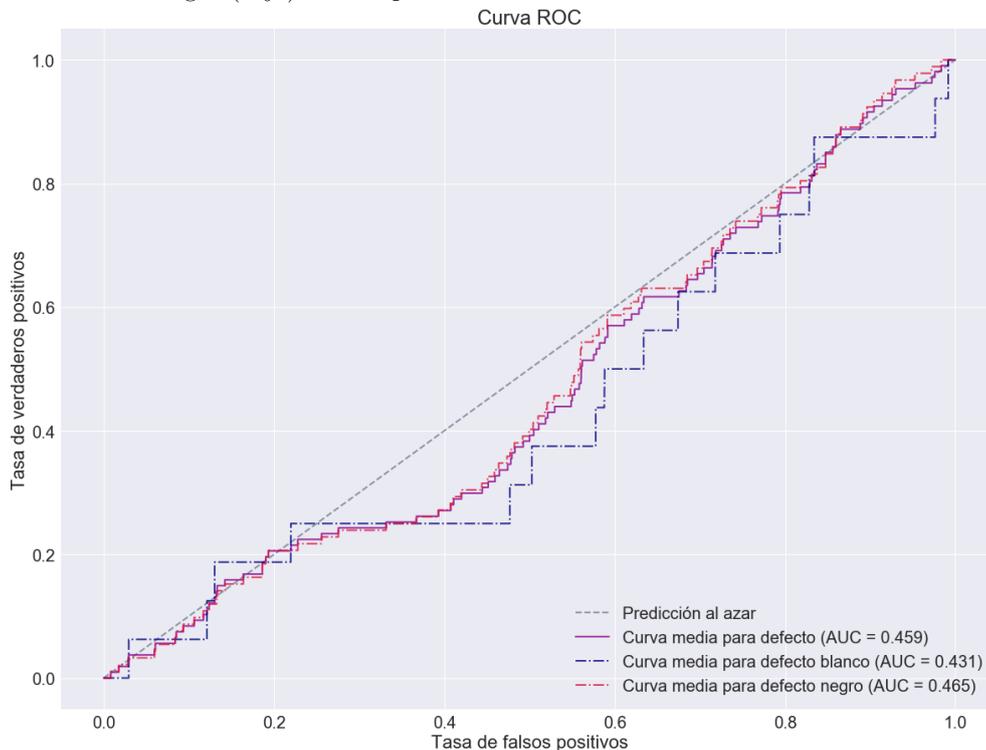


Figura 8.12: Curva ROC del sistema de referencia empleando la suma de las áreas de error relativas en negro y blanco para la clasificación con defecto - sin defecto del Corpus II.

Resultados del sistema de referencia en el Corpus II			
		Tasa de equierror (EER)	Area Under Curve (AUC)
Suma de áreas de error		0.551	0.459 { Negro: 0.465 Blanco: 0.431
Áreas de error por separado	Negro	0.205	0.872
	Blanco	0.576	0.429

Tabla 8.7: Estimación de la tasa de equierror y el área bajo la curva ROC del sistema de referencia con el Corpus II.

Empleando la suma de las áreas de error los valores del AUC y de la EER son bastante pobres, dando lugar a un sistema que clasificaría mal más del 50 % de las observaciones en el punto de la tasa de equierror. El uso por separado de las áreas de error relativas destaca de nuevo cómo la clasificación de los defectos blancos es mucho más complicada. La clasificación para los defectos negros es mejor atendiendo tanto al AUC como a la EER.

Los modelos de umbral ajustado seleccionados mediante tasa de equierror obtienen resultados mediocres, tal y como podemos observar en las matrices de confusión y en la tasa de acierto estimada (Tablas 8.8 y 8.9).

Sistema de referencia (1 umbral) -Corpus II-				
		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	1748	54	1802
	Con defecto	2145	53	2198
		3893	107	4000

- Tasa de acierto: 44.95 %
- Intervalo de confianza del 95 %: (40.07, 49.82)
- Sensibilidad: 49.53 %
- Especificidad: 44.90 %

Tabla 8.8: Matriz de confusión y tasa de acierto con el uso de 1 umbral (área relativa de error en negro + área relativa de error en blanco) en Corpus II.

Sistema de referencia (2 umbrales) -Corpus II-				
		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	1997	97	2094
	Con defecto	1896	10	1906
		3893	107	4000

- Tasa de acierto: 50.17 %
- Intervalo de confianza del 95 %: (45.27, 55.07)
- Sensibilidad: 9.34 %
- Especificidad: 51.29 %

Tabla 8.9: Matriz de confusión y tasa de acierto con el uso de 2 umbrales (uno para área relativa de error en negro y otro para la de blanco) en Corpus II.

Los resultados parecen indicarnos que emplear un umbral da lugar a una clasificación más equilibrada. Los valores de la sensibilidad y especificidad son bajos, especialmente en el modelo de dos umbrales dónde la especificidad roza el 10 %.

Por lo tanto, mientras que en el Corpus I se buscará refinar la precisión de un sistema que ya funciona bien por umbrales, en el Corpus II aún se puede mejorar mucho.

8.3. Regresión Logística

Siguiendo las pautas de la sección 7.2 se ha valorado la precisión de varios modelos de regresión logística. Tal y como se describió en este apartado, en las distintas secciones correspondientes a cada conjunto de datos de los Corpus aparecerá especificado el modelo óptimo seleccionado entre:

1. Selección recursiva de variables y la resolución de la optimización mediante penalización L2.
2. Usando la penalización L1. Esta ya cuenta con una capacidad intrínseca para crear coeficientes dispersos o nulos.

Corpus I

8.3.0.1. Conjunto de datos A

Modelo óptimo: 48 variables. Seleccionado bajo el criterio de máxima tasa de acierto estimada por validación cruzada. Obtenido mediante regularización L1.

- AreaErrorN y AreaErrorB.
- PCA: CompPrinOr1, CompPrinOr2, CompPrinOr3, CompPrinOr4, CompPrinTratB1, CompPrinTratB2, CompPrinTratN1, CompPrinTratN2.
- DCT: imagen sin binarizar: todas las componentes menos 26; imagen binarizada: 1, 6, 9, 12, 13, 15, 19, 25, 28.

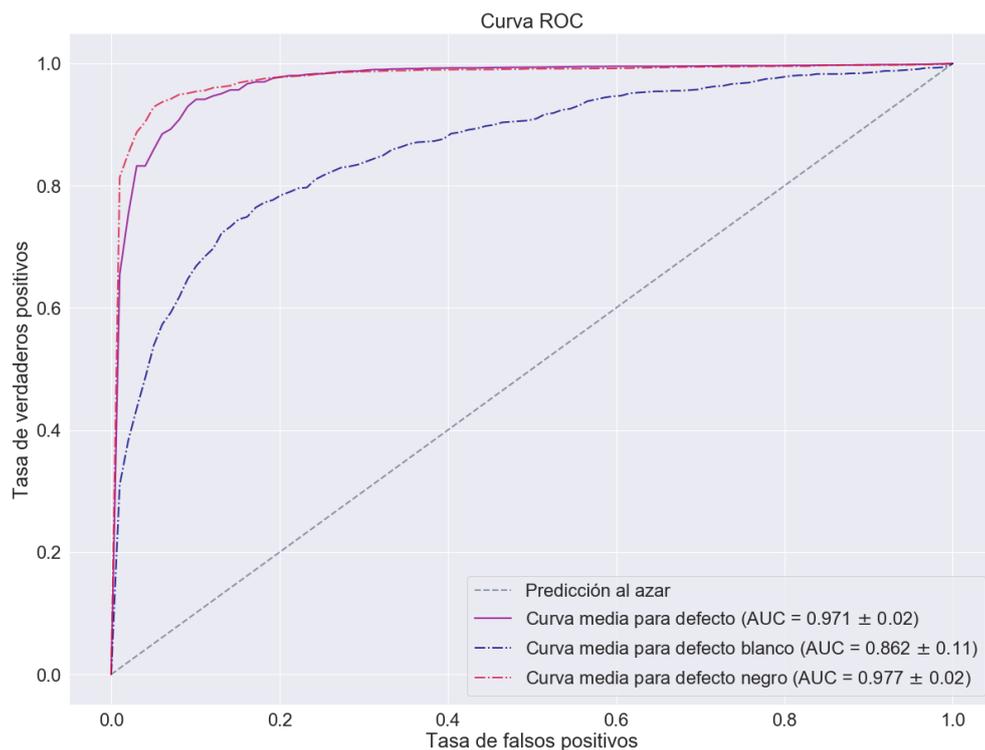


Figura 8.13: Curvas ROC de regresión logística empleando el conjunto de datos A del Corpus I.

Resultados de la Regresión Logística en el Corpus I			
	Tasa de equierror (EER)	Area Under Curve (AUC)	
Conjunto de datos A	0.070 ± 0.04	0.971 ± 0.02	$\left\{ \begin{array}{l} \text{Negro: } 0.977 \pm 0.02 \\ \text{Blanco: } 0.862 \pm 0.11 \end{array} \right.$

Tabla 8.10: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo de regresión logística creado a partir del conjunto A de datos del Corpus I.

Los resultados relacionados con la curva ROC y la tasa de equierror aparecen en la Figura 8.13 y en la Tabla 8.10. Los resultados son excelentes: la tasa de equierror es baja (cercana al 7%) y el área bajo la curva ROC es bastante grande. El AUC de la curva correspondiente a la clasificación de defectos blancos pone de manifiesto la dificultad de la detección de éstos.

El modelo de regresión logística con el conjunto de datos A del Corpus I da lugar a un clasificador cuya tasa de acierto es altamente similar a la del sistema de referencia (Tabla 8.11). El número de tableros etiquetados erróneamente como defectuosos ha aumentado -haciendo que la especificidad empeore notablemente- y han disminuido los falsos negativos.

Sistema de regresión logística -Conjunto de datos A, Corpus I-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	546	136	682
	Con defecto	163	6322	6485
		709	6458	7167

- Tasa de acierto: 95.82 %
- Intervalo de confianza del 95 %: (94.14, 97.52)
- Sensibilidad: 97.89 %
- Especificidad: 77.00 %

Tabla 8.11: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo de regresión logística del Corpus I con el conjunto de datos A obtenido con regularización L1.

8.3.0.2. Conjunto de datos B

Modelo óptimo: 63 variables. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada. Obtenido mediante regularización L1.

- AreaErrorB y AreaErrorN.
- Estadísticos: MediaOr, VarianzaOr, SkewnessOr, KurtosisOr, MedianaOr, P10Or, P90Or, MediaTratadaB, VarianzaTratadaB, SkewnessTratadaB, MedianaTratadaB, P10TratadaB, P90TratadaB, MediaTratadaN, SkewnessTratadaN, KurtosisTratadaN, MedianaTratadaN, P10TratadaN, P90TratadaN.
- DCT: imagen sin binarizar: todas las componentes menos la 24; imagen binarizada: 1, 7, 12, 13, 15, 17, 18, 19, 20, 23, 24, 25, 26.

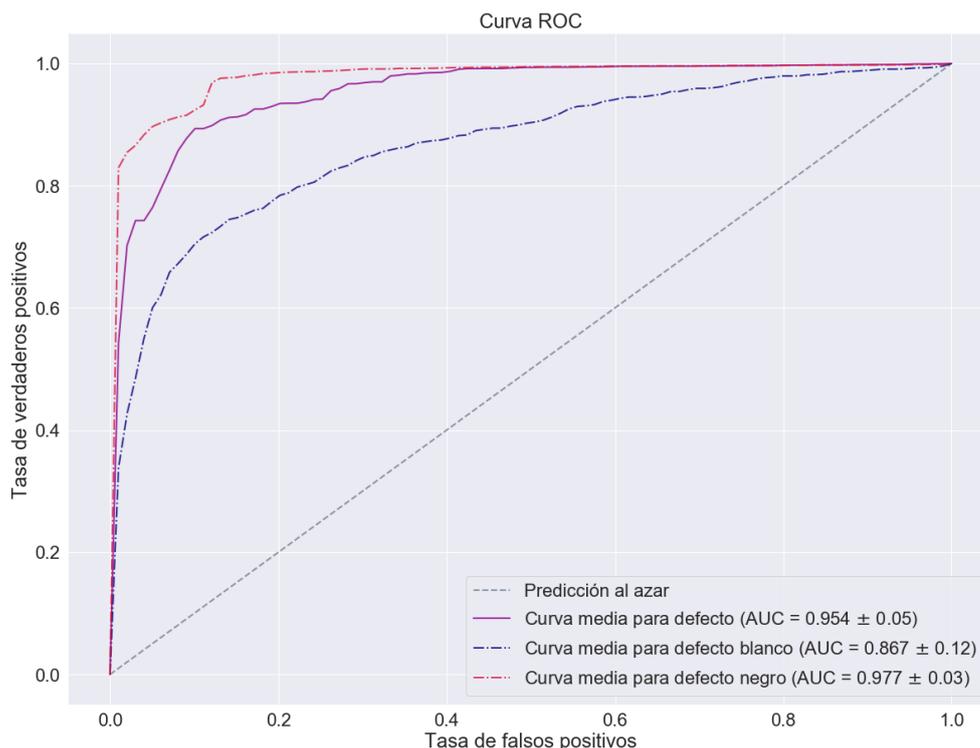


Figura 8.14: Curvas ROC de regresión logística empleando el conjunto de datos B del Corpus I.

Resultados de la Regresión Logística en el Corpus I			
	Tasa de equierror (EER)	Area Under Curve (AUC)	
Conjunto de datos B	0.090 ± 0.07	0.954 ± 0.05	<ul style="list-style-type: none"> Negro: 0.977 ± 0.03 Blanco: 0.867 ± 0.12

Tabla 8.12: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo de regresión logística creado a partir del conjunto B de datos del Corpus I.

Los resultados relacionados con la curva ROC y la tasa de equierror aparecen en la Figura 8.14 y en la Tabla 8.12. Se trata de resultados altamente similares a los del conjunto A, quizá algo peores al haber aumentado la tasa de equierror y disminuido el área bajo la curva ROC de defecto general.

El modelo seleccionado reitera las conclusiones sacadas a partir de la curva ROC y la EER en cuanto que los resultados son algo peores que con el conjunto de datos A. El conjunto de datos B logra un resultado aparentemente peor o muy similar al del sistema de referencia con el Corpus I (Tabla 8.13). Existe una diferencia notable entre la especificidad y la sensibilidad.

Sistema de regresión logística -Conjunto de datos B, Corpus I-				
		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	445	71	516
	Con defecto	264	6387	6651
		709	6458	7167

- Tasa de acierto: 95.32 %
- Intervalo de confianza del 95 %: (93.54, 97.10)
 - Sensibilidad: 98.90 %
 - Especificidad: 62.76 %

Tabla 8.13: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo de regresión logística del Corpus I con el conjunto de datos B obtenido con regularización L1.

Corpus II

8.3.0.3. Conjunto de datos A

Modelo óptimo: 49 variables. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada. Obtenido mediante regularización L1.

- AreaErrorB.
- PCA: CompPrinOr1, CompPrinOr2, CompPrinOr3, CompPrinOr4, CompPrinTratB1, CompPrinTratB2, CompPrinTratN1, CompPrinTratN2.
- DCT: imagen sin binarizar: todas las componentes; imagen binarizada: 4, 8, 9, 13, 17, 25, 26, 27, 29, 30.

Resultados de la Regresión Logística en el Corpus II			
	Tasa de equierror (EER)	Area Under Curve (AUC)	
Conjunto de datos A	0.428 ± 0.14	0.610 ± 0.18	<ul style="list-style-type: none"> Negro: 0.594 ± 0.23 Blanco: 0.624 ± 0.27

Tabla 8.14: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo de regresión logística creado a partir del conjunto A de datos del Corpus II.

Los resultados relacionados con la curva ROC y la tasa de equierror aparecen en la Figura 8.15 y en la Tabla 8.14. Se puede observar evidencia que podría indicar que este sistema es algo mejor que el sistema de referencia, como el aumento del AUC y la disminución de la EER. Esta es aún así muy elevada, siendo cercana al 40 %.

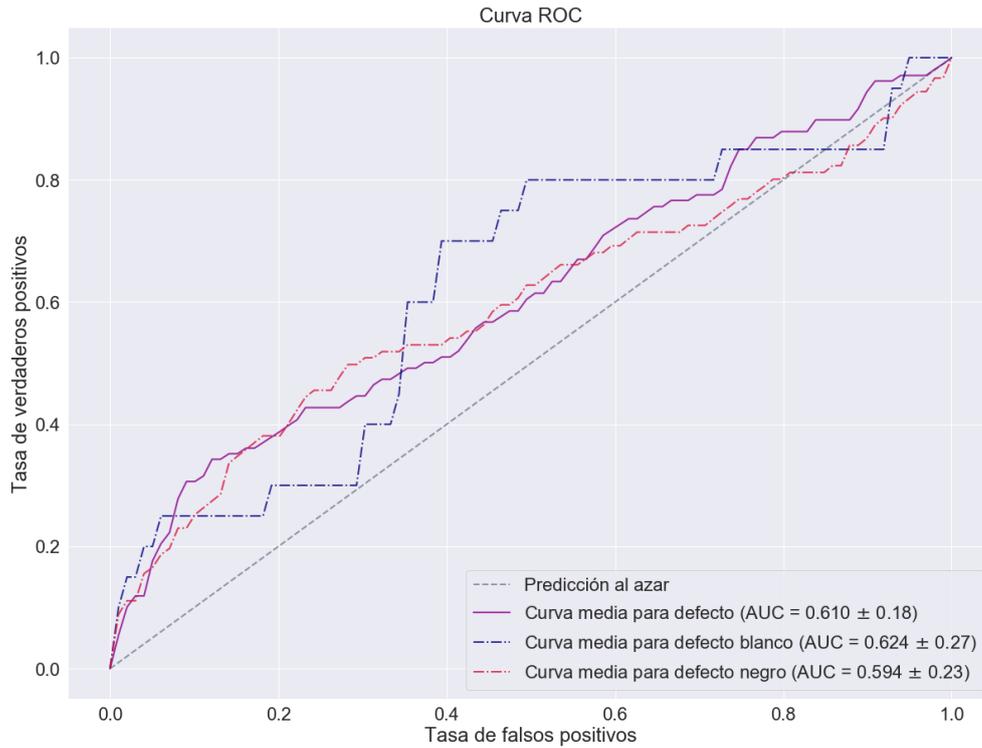


Figura 8.15: Curvas ROC de regresión logística empleando el conjunto de datos A del Corpus II.

El modelo con el umbral de clasificación ajustado alcanza de manera global una precisión mucho mejor que el sistema de referencia (Tabla 8.15). La observación detallada de la matriz de confusión nos permite concluir que la detección de imágenes con defectos ha empeorado significativamente a costa de una mejora detectando imágenes sin defectos. Esto hace que la sensibilidad sea muy baja y la especificidad muy alta: el clasificador, por lo tanto, carecerá de una buena capacidad clasificadora.

Sistema de regresión logística -Conjunto de datos A, Corpus II-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	3874	105	3979
	Con defecto	19	2	21
		3893	107	4000

- Tasa de acierto: 96.85 %
- Intervalo de confianza del 95 %: (94.87, 98.83)
- Sensibilidad: 1.87 %
- Especificidad: 99.51 %

Tabla 8.15: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo de regresión logística del Corpus II con el conjunto de datos A obtenido con regularización L1.

8.3.0.4. Conjunto de datos B

Modelo óptimo: 41 variables. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada. Obtenido mediante regularización L2.

- AreaErrorN.
- Estadísticos: MediaOr, VarianzaOr, MedianaOr, P10Or, P90Or, MediaTratadaB, SkewnessTratadaB, KurtosisTratadaB, MedianaTratadaB, MediaTratadaN, SkewnessTratadaN, KurtosisTratadaN, P10TratadaN.
- DCT: imagen sin binarizar: 1, 2, 4, 6, 7, 16, 27, 28, 29; imagen binarizada: 3, 4, 5, 6, 7, 9, 10, 11, 15, 16, 17, 19, 20, 22, 24, 26, 28, 29.

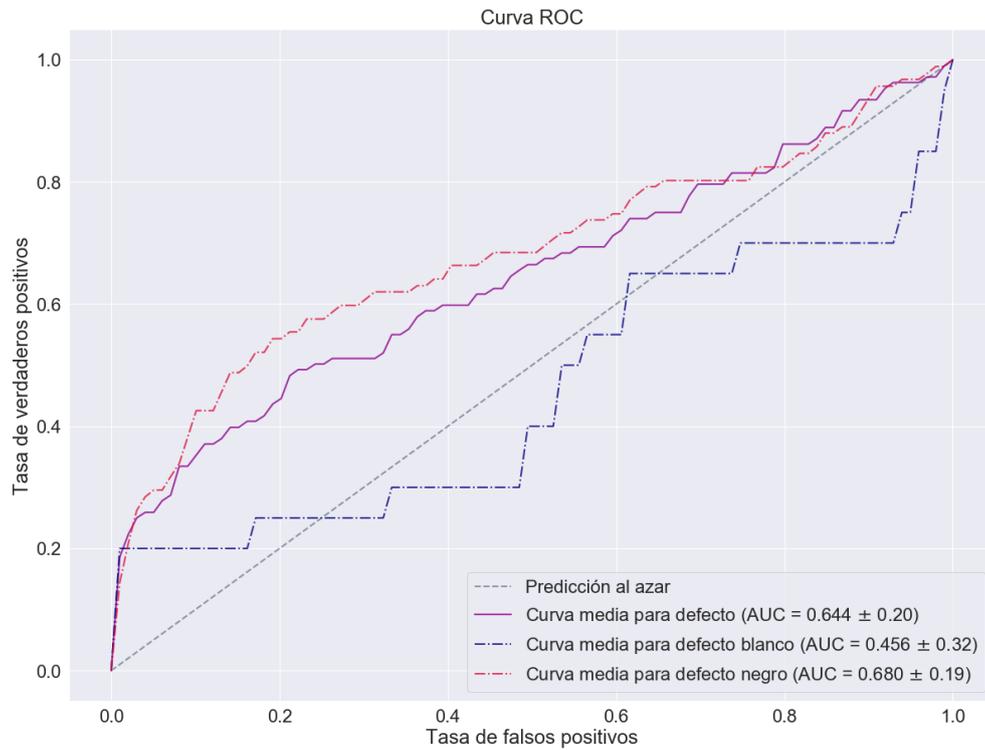


Figura 8.16: Curvas ROC de regresión logística empleando el conjunto de datos B del Corpus II.

Resultados de la Regresión Logística en el Corpus II		
	Tasa de equierror (EER)	Area Under Curve (AUC)
Conjunto de datos B	0.360 ± 0.37	0.644 ± 0.20 { Negro: 0.680 ± 0.19 Blanco: 0.456 ± 0.32

Tabla 8.16: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo de regresión logística creado a partir del conjunto B de datos del Corpus II.

Las curvas ROC aparecen representadas en la Figura 8.16. Diversos resultados relevantes se encuentran reflejados en la Tabla 8.16. El clasificador inducido con el conjunto B de datos es mejor que el obtenido con el A si tomamos como criterio la tasa de equierror. Si tomamos el área bajo la curva ROC del defecto general, son dos sistemas muy similares. La detección de defectos blancos no parece ser muy satisfactoria.

La tasa de acierto correspondiente al modelo de regresión logística inducido es mucho mejor que la del sistema de referencia (Tabla 8.17). La detección de imágenes sin defectos tiene una precisión algo inferior a la correspondiente al clasificador inducido con el conjunto A de datos, mientras que la detección de tablero con defectos ha mejorado. Aún hay mucho margen para mejorar, ya que el número de tableros con defectos bien clasificados no alcanza a ser ni el 50%.

Sistema de regresión logística -Conjunto de datos B, Corpus II-			
Etiqueta	Clase		
	Sin Defecto	Con defecto	
Sin Defecto	3847	85	3932
Con defecto	46	22	68
	3893	107	4000

- Tasa de acierto: 96.72 %.
- Intervalo de confianza del 95 %:(94.71, 98.74)
- Sensibilidad: 20.56 %
- Especificidad: 98.82 %

Tabla 8.17: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo de regresión logística del Corpus II con el conjunto de datos B obtenido con regularización L2.

La Tabla resumen 8.18 muestra el número de variables, área bajo la curva ROC y tasa de equierror de los modelos de regresión logística. También aparece la tasa de acierto estimada por validación cruzada del modelo elegido.

Podemos observar cómo en el caso del Corpus I solo el clasificador creado con el primer conjunto de datos mejora aparentemente y de forma muy leve la precisión del sistema de referencia. Los valores de la área bajo la curva ROC y la tasa de equierror son altamente satisfactorios.

En el caso del Corpus II, la mejora es significativa en lo que se refiere a tasa de acierto, superando con creces el funcionamiento del sistema de referencia. Este dato puede ser engañoso, ya que la detección de imágenes con defectos deja mucho que desear como se puede observar en las matrices de confusión expuestas y los valores de la sensibilidad. No se trata de modelos equilibrados en los que la tasa de falsos negativos y de falsos positivos sea similar, por lo que su capacidad clasificadora es dudosa. Esto se ve reflejado claramente en la tabla por los bajos valores de la AUC y los altos valores de la tasa de equierror.

Los modelos regularizados con la norma 1 que han resultado ser los óptimos (Corpus I: conjuntos de datos A y B; Corpus II: conjunto de datos A) se caracterizan por una alta dimensionalidad relativa si los comparamos con los que serían resultado de la selección recursiva de variables y de la regularización L2, como sería el caso del modelo del conjunto de datos B del Corpus II.

Resultados de los modelos de regresión logística								
	Corpus I				Corpus II			
	Variables	EER	AUC	Tasa de acierto	Variables	EER	AUC	Tasa de acierto
Conjunto A	48	0.070	0.971	95.82 %	49	0.428	0.610	96.85 %
Conjunto B	63	0.090	0.954	95.32 %	41	0.331	0.608	96.72 %

Tabla 8.18: Número de variables, AUC y EER, así como tasa de acierto estimada por validación cruzada del modelo seleccionado, de los sistemas de regresión logística haciendo uso de los conjuntos de datos A y B en ambos Corpus.

8.4. Support Vector Machine

Siguiendo las pautas de la sección 7.3 se han estudiado las curvas ROC y tasas de equierror de los sistemas de Support Vector Machine. Posteriormente se ha valorado la tasa de acierto alcanzada por los modelos seleccionados. En todos los casos desarrollados se ha optimizado el valor del parámetro de regularización λ . A lo largo de las siguientes subsecciones se exponen los resultados del uso de tres núcleos diferentes:

1. Lineal. Al emplear penalización L1 se realiza intrínsecamente la selección de variables quedando ciertos coeficientes nulos. Suponen una excepción de cara a la metodología empleada, ya que tal y como se comentó en la implementación utilizada, los SVM de núcleo lineal no contarán en esta sección con curvas ROC ni tasa de equierror. Esto se debe a que la implementación usada, al igual que la mayoría de implementaciones de SVM lineales, al usar regularización L1 no puede tener como salida probabilidades. Por lo tanto, se valorarán únicamente las matrices de confusión así como la tasa de acierto, especificidad y sensibilidad.
2. Polinómico. Creado a partir de todas las variables, se especificará con cada modelo cual es el grado p del polinomio usado.
3. De base radial. Emplea la totalidad de las variables del conjunto. Se ha optimizado el valor del parámetro del núcleo σ .

8.4.1. Núcleo Lineal

Corpus I

8.4.1.1. Conjunto de datos A

Modelo óptimo: 39 variables. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada.

- AreaErrorN.
- PCA: CompPrinOr1, CompPrinOr2, CompPrinOr3, CompPrinOr4, CompPrinTratB1, CompPrinTratN2.
- DCT: imagen sin binarizar: todas menos las componentes 9, 13, 17, 18 y 30; imagen binarizada: 1, 9, 12, 13, 15, 19, 20.

La Tabla 8.19 nos muestra cómo el clasificador resultante con el conjunto reducido de variables por la penalización L1 tiene una tasa de acierto superior a la obtenida previamente con el sistema de referencia y la regresión logística. Con respecto al sistema de referencia, parece que los falsos negativos y los falsos positivos han disminuido. La especificidad marca de nuevo la dificultad para discriminar ciertos tableros sin defectos de los que los tienen. Este clasificador parece tener una dependencia muy fuerte de las componentes DCT extraídas de la imagen sin binarizar.

Sistema de Support Vector Machine de núcleo lineal -Conjunto de datos A, Corpus I-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	555	63	618
	Con defecto	154	6395	6549
		709	6458	7167

- Tasa de acierto: 96.97 %.
- Intervalo de confianza del 95 %:(95.53, 98.42)
 - Sensibilidad: 99.00 %
 - Especificidad: 78.27 %

Tabla 8.19: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo lineal del Corpus I con el conjunto de datos A.

8.4.1.2. Conjunto de datos B

Modelo óptimo: 37 variables. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada.

- AreaErrorB.
- Estadísticos: MediaOr, VarianzaOr, SkewnessOr, MedianaOr, MediaTratadaB, SkewnessTratadaB, MedianaTratadaB, P10TratadaB, P90TratadaB, MediaTratadaN, SkewnessTratadaN, KurtosisTratadaN, P10TratadaN, P90TratadaN.
- DCT: imagen sin binarizar: 2, 3, 4, 6, 8, 11, 12, 13, 14, 16, 17, 18, 19, 20, 21, 22, 23, 25, 27, 28; imagen binarizada: 1, 15.

Obtenemos un clasificador de una dimensionalidad inferior que los modelos estudiados hasta ahora y cuya tasa de acierto estimada aparentemente es la más elevada (Tabla 8.20), superando al sistema de referencia, a los modelos de regresión logística y al modelo creado a partir del conjunto de datos A. Con respecto a este parece haberse mejorado ligeramente la especificidad.

Sistema de Support Vector Machine de núcleo lineal -Conjunto de datos B, Corpus I-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	564	66	630
	Con defecto	145	6392	6537
		709	6458	7167

- Tasa de acierto: 97.05 %.
- Intervalo de confianza del 95 %:(95.63, 98.48)
 - Sensibilidad: 98.98 %
 - Especificidad: 79.55 %

Tabla 8.20: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo lineal del Corpus I con el conjunto de datos B.

Corpus II

Para los modelos referidos al Corpus II ha sido necesario dar mayor peso a las observaciones de imágenes defectuosas. Se ha aportado el triple de peso a estas. De no hacerse de esta forma, el entrenamiento no se realizaba correctamente y daba lugar a un clasificador muy desequilibrado sin capacidad clasificadora.

8.4.1.3. Conjunto de datos A

Modelo óptimo: 49 variables. Seleccionado bajo criterio de máximo F-Score estimada por validación cruzada.

- AreaErrorB.
- PCA: CompPrinOr1, CompPrinOr2, CompPrinOr3, CompPrinOr4, CompPrinTratB1, CompPrinTratB2, CompPrinTratN1, CompPrinTratN2.
- DCT: imagen sin binarizar: todas menos la componente 2; imagen binarizada: 4, 6, 8, 9, 10, 17, 19, 24, 27, 28, 29, 30.

La Tabla 8.21 puede mostrar un buen resultado en cuanto a precisión se refiere, pero la sensibilidad estimada es paupérrima. El modelo, muy dependiente de las componentes DCT de la imagen sin binarizar, carece de capacidad de clasificadora en las observaciones con defectos prácticamente. Ni aumentando el peso de las observaciones con defectos se ha podido evitar esto.

Sistema de Support Vector Machine de núcleo lineal -Conjunto de datos A, Corpus II-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	3889	106	3995
	Con defecto	4	1	6
		3893	107	4000

- Tasa de acierto: 97.25 %.
- Intervalo de confianza del 95 %:(95.40, 99.10)
 - Sensibilidad: 0.93 %
 - Especificidad: 99.89 %

Tabla 8.21: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo lineal del Corpus II con el conjunto de datos A.

8.4.1.4. Conjunto de datos B

Modelo óptimo: 63 variables. Seleccionado bajo criterio de máximo F-Score estimado por validación cruzada.

- AreaErrorB.
- Estadísticos: MediaOr, VarianzaOr, SkewnessOr, MedianaOr, P10Or, P90Or, MediaTratadaB, VarianzaTratadaB, SkewnessTratadaB, KurtosisTratadaB, MedianaTratadaB, P10TratadaB, P90TratadaB, MediaTratadaN, SkewnessTratadaN, KurtosisTratadaN, MedianaTratadaN, P10TratadaN, P90TratadaN.
- DCT: imagen sin binarizar: todas menos las componentes 15 y 16; imagen binarizada: 4, 6, 8, 9, 10, 13, 17, 19, 24, 25, 27, 28, 29, 30.

En la Tabla 8.22 vemos que el clasificador que obtenemos con el conjunto B se caracteriza por una problemática similar a la obtenida con el conjunto A. Parece clasificar mal menos imágenes con defectos y tener algo menos de sesgo hacia la clase imagen sin defecto, por lo que la sensibilidad aumenta un poco, aunque sigue siendo muy baja. Es otro modelo que depende fuertemente de las componentes de la DCT de la imagen sin binarizar.

Sistema de Support Vector Machine de núcleo lineal -Conjunto de datos B, Corpus II-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	3884	96	3980
	Con defecto	9	11	20
		3893	107	4000

- Tasa de acierto: 97.38 %.
- Intervalo de confianza del 95 %:(95.57, 99.19)
 - Sensibilidad: 10.28 %
 - Especificidad: 99.76 %

Tabla 8.22: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo lineal del Corpus II con el conjunto de datos B.

8.4.2. Núcleo polinómico

Corpus I

8.4.2.1. Conjunto de datos A

Modelo óptimo. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada.

- 70 variables, todas las del conjunto de datos.
- El grado óptimo elegido mediante validación cruzada ha sido $p = 2$.

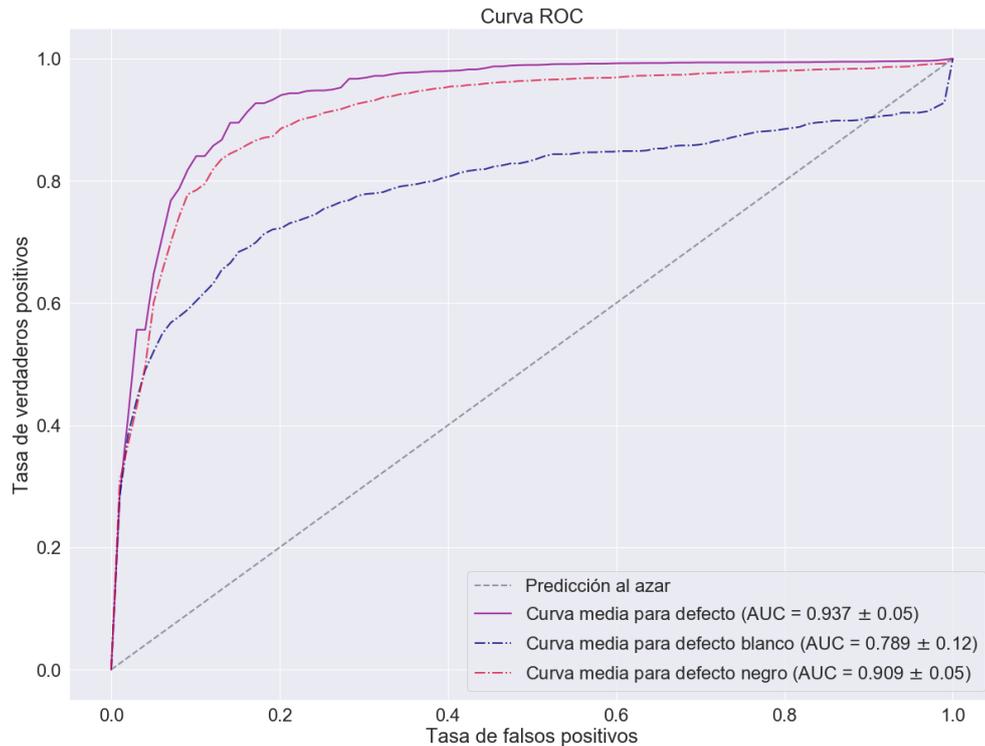


Figura 8.17: Curvas ROC de Support Vector Machine de núcleo polinómico de grado $p = 2$ empleando el conjunto de datos A del Corpus I.

Resultados de Support Vector Machine de núcleo polinómico en el Corpus I			
	Tasa de equierror (EER)	Area Under Curve (AUC)	
Conjunto de datos A	0.111 ± 0.06	0.937 ± 0.05	Negro: 0.909 ± 0.05 Blanco: 0.789 ± 0.12

Tabla 8.23: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo Support Vector Machine de núcleo polinómico de grado $p = 2$ creado a partir del conjunto A de datos del Corpus I.

La curva ROC (Figura 8.17) así como la tasa de equierror y el área bajo la curva (Tabla 8.23) nos dan indicios de que el clasificador obtenido tiene un funcionamiento general similar al de los modelos de regresión logística o el sistema de referencia.

El Support Vector Machine de núcleo polinómico que ha sido capaz de alcanzar la tasa de acierto más elevada estimada por validación cruzada ha resultado ser de grado dos. Aquellos con valores de p superiores lograban tasas de acierto en el conjunto de entrenamiento superiores que no se mantenían tan elevadas al realizar la validación cruzada. La capacidad clasificadora del modelo escogido supera a la del sistema de referencia y la de los modelos de regresión logística. Sin embargo, parece que su precisión es peor que la que alcanzan los Support Vector Machines de núcleo lineal creados anteriormente (Tabla 8.24).

Sistema de Support Vector Machine de núcleo polinómico -Conjunto de datos A, Corpus I-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	529	69	598
	Con defecto	180	6399	6579
		709	6458	7167

- Tasa de acierto: 96.66 %.
- Intervalo de confianza del 95 %:(95.14, 98.18)
- Sensibilidad: 98.93 %
- Especificidad: 74.61 %

Tabla 8.24: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo polinómico de grado $p = 2$ del Corpus I con el conjunto de datos A.

8.4.2.2. Conjunto de datos B

Modelo óptimo. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada.

- 83 variables, todas las del conjunto de datos.
- El grado óptimo elegido mediante validación cruzada ha sido $p = 2$.

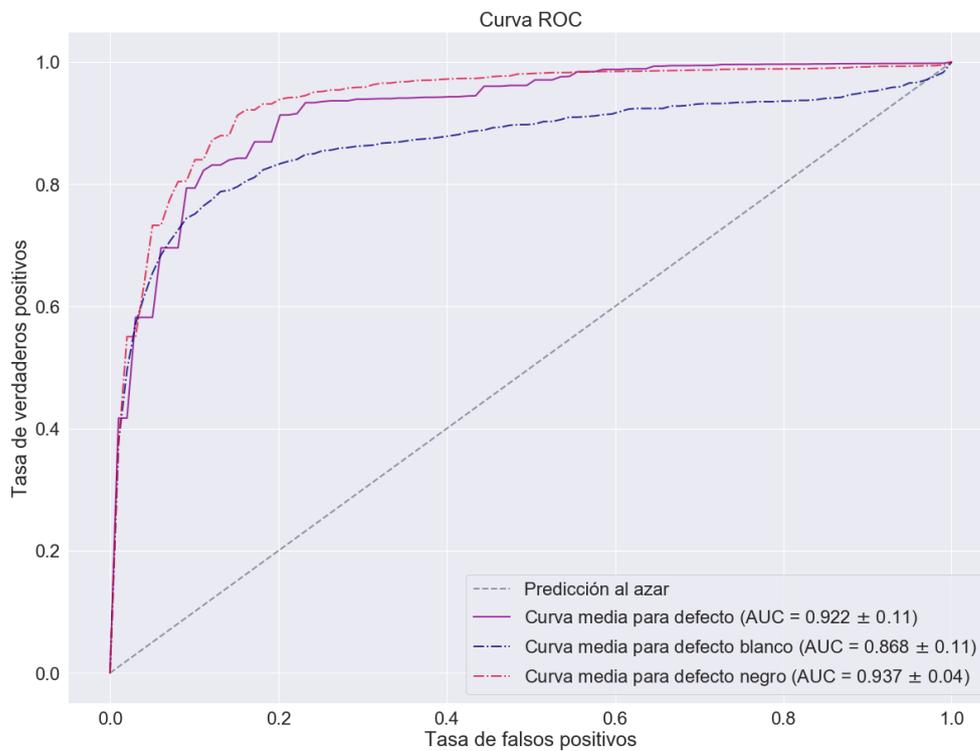


Figura 8.18: Curvas ROC de Support Vector Machine de núcleo polinómico de grado $p = 2$ empleando el conjunto de datos B del Corpus I.

Resultados de Support Vector Machine de núcleo polinómico en el Corpus I		
	Tasa de equierror (EER)	Area Under Curve (AUC)
Conjunto de datos B	0.117 ± 0.09	0.922 ± 0.11 { Negro: 0.937 ± 0.04 Blanco: 0.868 ± 0.11

Tabla 8.25: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo Support Vector Machine de núcleo polinómico de grado $p = 2$ creado a partir del conjunto B de datos del Corpus I.

Las curvas ROC (Figura 8.18) y los valores del área bajo ésta así como la tasa de equierror (Tabla 8.25) nos indican que el modelo obtenido es muy similar en características al obtenido con el conjunto de datos A. Aunque los valores de la clasificación de errores general son algo peores, la AUC correspondiente a los defectos blancos es más alta, por lo que la detección de defectos blancos habrá mejorado.

Con el conjunto B y de nuevo empleando el núcleo polinómico de grado dos en el Support Vector Machine obtenemos un clasificador cuya tasa de acierto parece superar a la del conjunto A (Tabla 8.26). Tanto la especificidad como la sensibilidad se han incrementado. La tasa de acierto, aún así, es inferior a la de los modelos de máquina de vector soporte lineales creados anteriormente.

Sistema de Support Vector Machine de núcleo polinómico -Conjunto de datos B, Corpus I-

Etiqueta	Clase		
	Sin Defecto	Con defecto	
Sin Defecto	535	58	593
Con defecto	174	6400	6574
	709	6458	7167

- Tasa de acierto: 96.76 %.
- Intervalo de confianza del 95 %:(95.27, 98.26)
- Sensibilidad: 99.10 %
- Especificidad: 75.46 %

Tabla 8.26: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo polinómico de grado $p = 2$ del Corpus I con el conjunto de datos B.

Corpus II

Para los modelo referidos al Corpus II ha sido necesario dar mayor peso a las observaciones de imágenes defectuosas. Se ha aportado el triple de peso a estas. De no hacerse de esta forma, el entrenamiento no se realizaba correctamente y daba lugar a un clasificador desequilibrado sin capacidad clasificadora.

8.4.2.3. Conjunto de datos A

Modelo óptimo. Seleccionado bajo criterio de máximo F-Score estimado por validación cruzada.

- 70 variables, todas las del conjunto de datos.
- El grado óptimo elegido mediante validación cruzada ha sido $p = 3$.

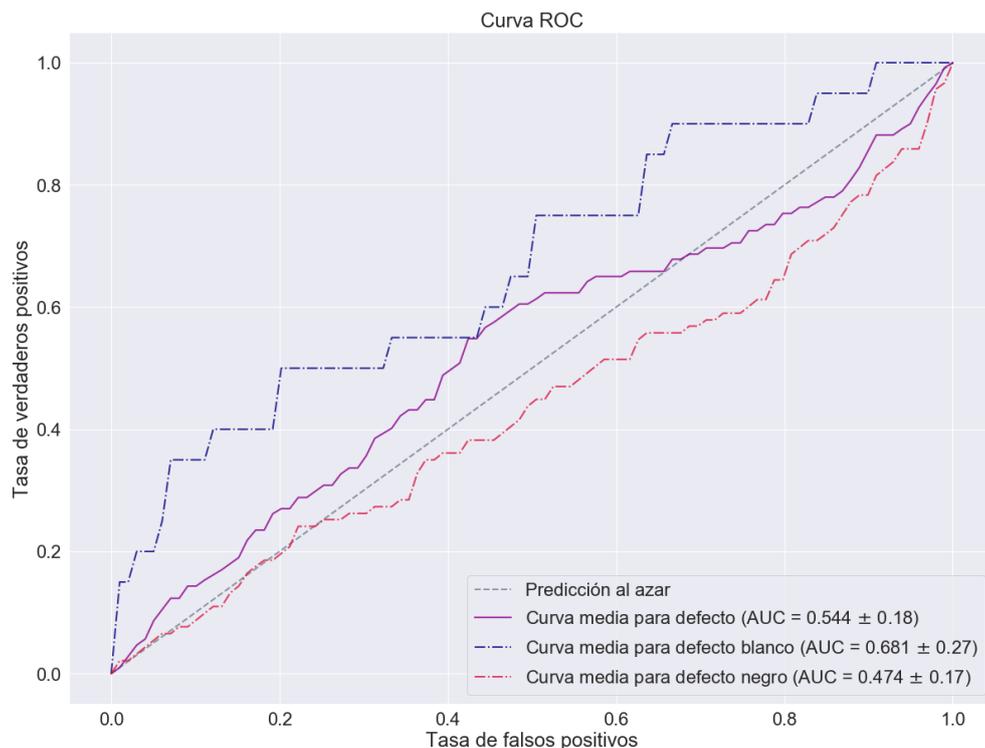


Figura 8.19: Curvas ROC de Support Vector Machine de núcleo polinómico de grado $p = 3$ empleando el conjunto de datos A del Corpus II.

Resultados de Support Vector Machine de núcleo polinómico en el Corpus II		
	Tasa de equierror (EER)	Area Under Curve (AUC)
Conjunto de datos A	0.512 ± 0.16	0.544 ± 0.18 { Negro: 0.474 ± 0.17 Blanco: 0.681 ± 0.27

Tabla 8.27: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo Support Vector Machine de núcleo polinómico de grado $p = 3$ creado a partir del conjunto A de datos del Corpus II.

Las curvas ROC (Figura 8.19) tanto del defecto general como del defecto negro tan cercanas a la clasificación al azar son indicio de un clasificador mediocre. Los valores del área bajo la curva y la tasa de equierror (Tabla 8.27) son mejores que los del sistema de referencia pero peores que los obtenidos con la regresión logística. Cabe destacar que este clasificador discrimina mejor defectos blancos que negros, al contrario que los estudiados hasta ahora en el caso del Corpus II. Existe una diferencia significativa entre la detección de defectos negros y blancos tal y como indican los valores del área bajo la curva correspondientes.

Con el conjunto de datos A del Corpus II obtenemos un clasificador cuyo funcionamiento es incierto a la hora de clasificar observaciones con defectos (Tabla 8.28). Parece funcionar algo mejor que el correspondiente Support Vector Machine de núcleo lineal en este aspecto. No obstante la sensibilidad del modelo sigue siendo excesivamente baja, no llegando ésta a alcanzar ni el 5%.

Sistema de Support Vector Machine de núcleo polinómico -Conjunto de datos A, Corpus II-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	3835	103	3938
	Con defecto	58	4	62
		3893	107	4000

- Tasa de acierto: 95.97 %.
- Intervalo de confianza del 95 %:(94.70, 98.73)
 - Sensibilidad: 3.74 %
 - Especificidad: 98.51 %

Tabla 8.28: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo polinómico de grado $p = 3$ del Corpus II con el conjunto de datos A.

8.4.2.4. Conjunto de datos B

Modelo óptimo. Seleccionado bajo criterio de máximo F-Score estimado por validación cruzada.

- 83 variables, todas las del conjunto de datos.
- El grado óptimo elegido mediante validación cruzada ha sido $p = 3$.

Resultados de Support Vector Machine de núcleo polinómico en el Corpus II		
	Tasa de equierror (EER)	Area Under Curve (AUC)
Conjunto de datos B	0.532 ± 0.21	0.491 ± 0.24 { Negro: 0.517 ± 0.24 Blanco: 0.412 ± 0.27

Tabla 8.29: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo Support Vector Machine de núcleo polinómico de grado $p = 3$ creado a partir del conjunto B de datos del Corpus II.

Las curvas ROC (Figura 8.20), posicionadas en general en la región inferior del espacio de las curvas ROC, y los valores pobres del área bajo la curva y la tasa de equierror (Tabla 8.29) son indicio de la baja capacidad clasificadora del modelo. Las estimaciones de variabilidad de las áreas bajo la curva ROC y la tasa de equierror son muy altas. Esto es indicativo de que en el procedimiento de validación cruzada estas medidas han tomado un amplio abanico de valores.

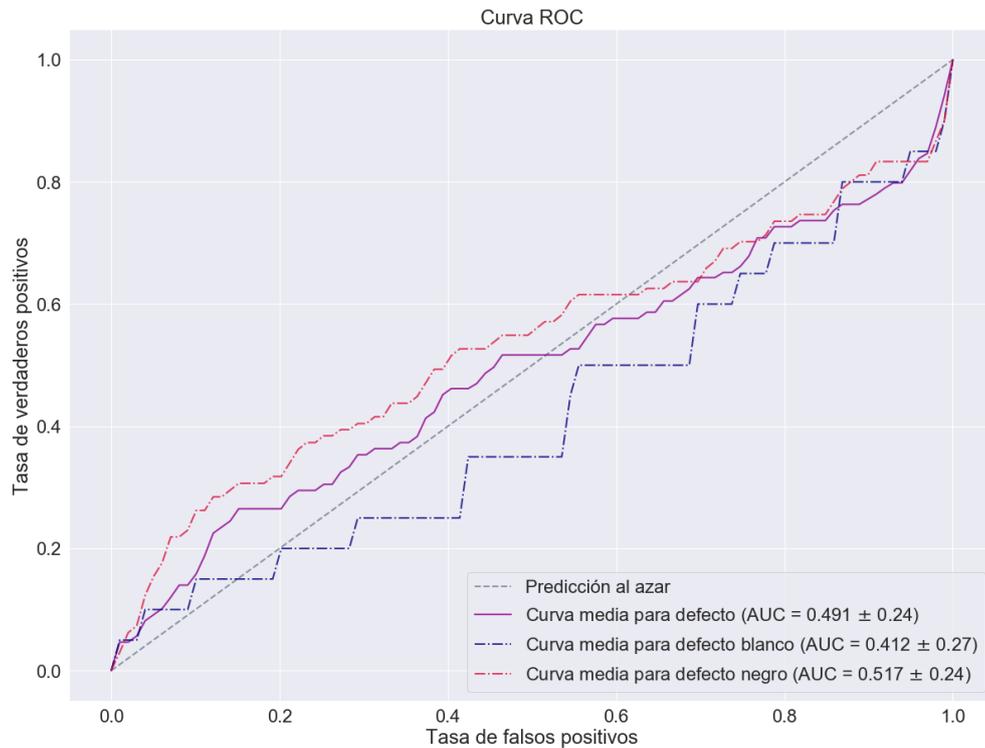


Figura 8.20: Curvas ROC de Support Vector Machine de núcleo polinómico de grado $p = 3$ empleando el conjunto de datos B del Corpus II.

Una vez ajustado el umbral de clasificación, podemos definir un modelo cuyos resultados están en la Tabla 8.30. El procedimiento sigue teniendo dificultades para distinguir los tableros con defectos. La sensibilidad del modelo toma un valor demasiado bajo, cercano al 10%. Funciona mejor que el obtenido con el conjunto A y parece tener un comportamiento similar al correspondiente SVM de núcleo lineal.

Sistema de Support Vector Machine de núcleo polinómico -Conjunto de datos B, Corpus II-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	3857	96	3953
	Con defecto	36	11	47
		3893	107	4000

- Tasa de acierto: 96.70 %.
- Intervalo de confianza del 95 %:(93.75, 98.20)
 - Sensibilidad: 10.28 %
 - Especificidad: 99.07 %

Tabla 8.30: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo polinómico de grado $p = 3$ del Corpus II con el conjunto de datos B.

8.4.3. Núcleo de base radial (RBF)

Corpus I

8.4.3.1. Conjunto de datos A

Modelo óptimo. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada.

- 70 variables, todas las del conjunto de datos.
- El valor óptimo de σ elegido mediante validación cruzada ha sido 4.082.

Las curvas ROC (Figura 8.21) y las medidas relacionadas así como la tasa de equierror (Tabla 8.31) apuntan la obtención de un clasificador de excelentes resultados similares a los de la regresión logística o el sistema de referencia. Destaca la cercanía de las AUC de blanco y negro: es un modelo diestro detectando ambos tipos de defectos.

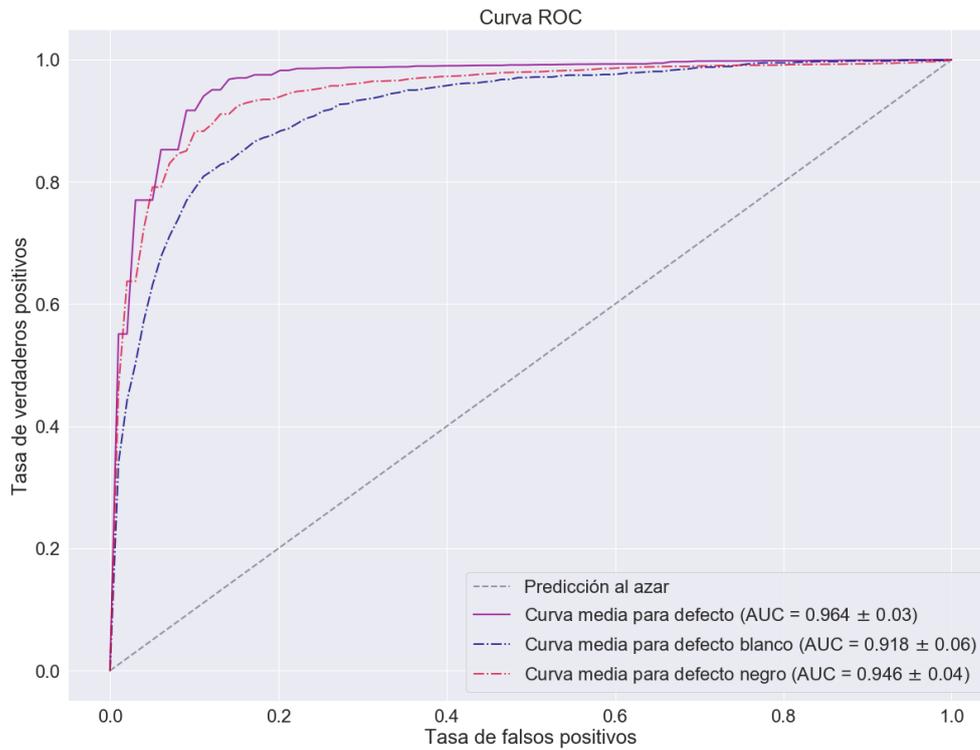


Figura 8.21: Curvas ROC de Support Vector Machine de núcleo de base radial con $\sigma = 4.082$ empleando el conjunto de datos A del Corpus I.

Resultados de Support Vector Machine de núcleo de base radial en el Corpus I		
	Tasa de equierror (EER)	Area Under Curve (AUC)
Conjunto de datos B	0.086 ± 0.05	0.964 ± 0.03 { Negro: 0.946 ± 0.04 Blanco: 0.918 ± 0.06

Tabla 8.31: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo Support Vector Machine de núcleo de base radial con $\sigma = 4.082$ creado a partir del conjunto A de datos del Corpus I.

En la Tabla 8.32 podemos observar que la mayor flexibilidad del núcleo de función de base radial ha dado lugar a un clasificador bastante satisfactorio. Tiene una tasa de acierto superior al sistema de referencia y a los modelos de regresión logística y Support Vector Machines anteriores. Parece tener mayores dificultades distinguiendo el tablero sin defectos aunque la especificidad está más cerca de la sensibilidad que en otros modelos.

Sistema de Support Vector Machine de núcleo de base radial -Conjunto de datos A, Corpus I-				
		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	570	59	629
	Con defecto	139	6399	6538
		709	6458	7167

- Tasa de acierto: 97.24 %.
- Intervalo de confianza del 95 %:(95.85, 98.62)
- Sensibilidad: 99.08 %
- Especificidad: 80.39 %

Tabla 8.32: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo de base radial con $\sigma = 4.082$ del Corpus I con el conjunto de datos A.

8.4.3.2. Conjunto de datos B

Modelo óptimo. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada.

- 83 variables, todas las del conjunto de datos.
- El valor óptimo de σ elegido mediante validación cruzada ha sido 5.

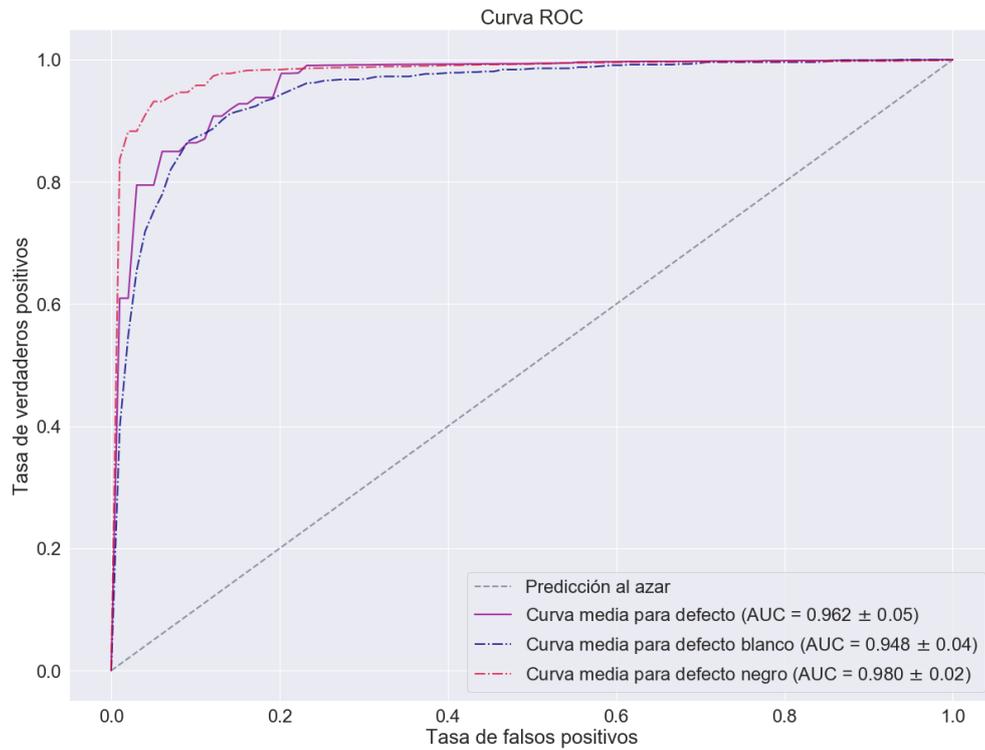


Figura 8.22: Curvas ROC de Support Vector Machine de núcleo de base radial con $\sigma = 5$ empleando el conjunto de datos B del Corpus I.

Resultados de Support Vector Machine de núcleo de base radial en el Corpus I		
	Tasa de equierror (EER)	Area Under Curve (AUC)
Conjunto de datos B	0.066 ± 0.05	0.962 ± 0.05 { Negro: 0.980 ± 0.02 Blanco: 0.948 ± 0.04

Tabla 8.33: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo Support Vector Machine de núcleo de base radial con $\sigma = 5$ creado a partir del conjunto B de datos del Corpus I.

Tanto la tabla con los valores de las AUC y la tasa de equierror (Tabla 8.27) como las curvas ROC (Figura 8.19) señalan que el modelo obtenido es excelente, incluso algo mejor que el SVM de base radial obtenido con el conjunto de datos A.

La conclusión extraída a partir de las curvas ROC y de la tasa de equierror se reitera en la tabla de resultados del modelo ajustado (Tabla 8.34). El modelo obtenido a partir conjunto de datos B satisface las metas logradas por el modelo optimizado creado con el conjunto de datos A, superando el rendimiento del sistema de referencia y los modelos de regresión logística y Support Vector Machine de núcleo lineal y de núcleo polinómico. Aparentemente es un modelo cuya tasa de acierto es ligeramente mejor que la obtenida con el Support Vector Machine óptimo de núcleo de base radial del conjunto de datos A pero sigue teniendo un problema de abundancia de falsos positivos a la hora de clasificar.

Sistema de Support Vector Machine de núcleo de base radial -Conjunto de datos B, Corpus I-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	569	51	620
	Con defecto	138	6407	6545
		709	6458	7167

- Tasa de acierto: 97.34 %.
- Intervalo de confianza del 95 %:(95.98, 98.70)
 - Sensibilidad: 99.21 %
 - Especificidad: 80.48 %

Tabla 8.34: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo de base radial con $\sigma = 5$ del Corpus I con el conjunto de datos B.

Corpus II

Para los modelos referidos al Corpus II ha sido necesario dar mayor peso a las observaciones de imágenes defectuosas. Se ha aportado el triple de peso a estas. De no hacerse de esta forma, el entrenamiento no se realizaba correctamente y daba lugar a un clasificador desequilibrado sin capacidad clasificadora.

8.4.3.3. Conjunto de datos A

Modelo óptimo. Seleccionado bajo criterio de máximo F-Score estimado por validación cruzada.

- 70 variables, todas las del conjunto de datos.
- El valor óptimo de σ elegido mediante validación cruzada ha sido 4.082.

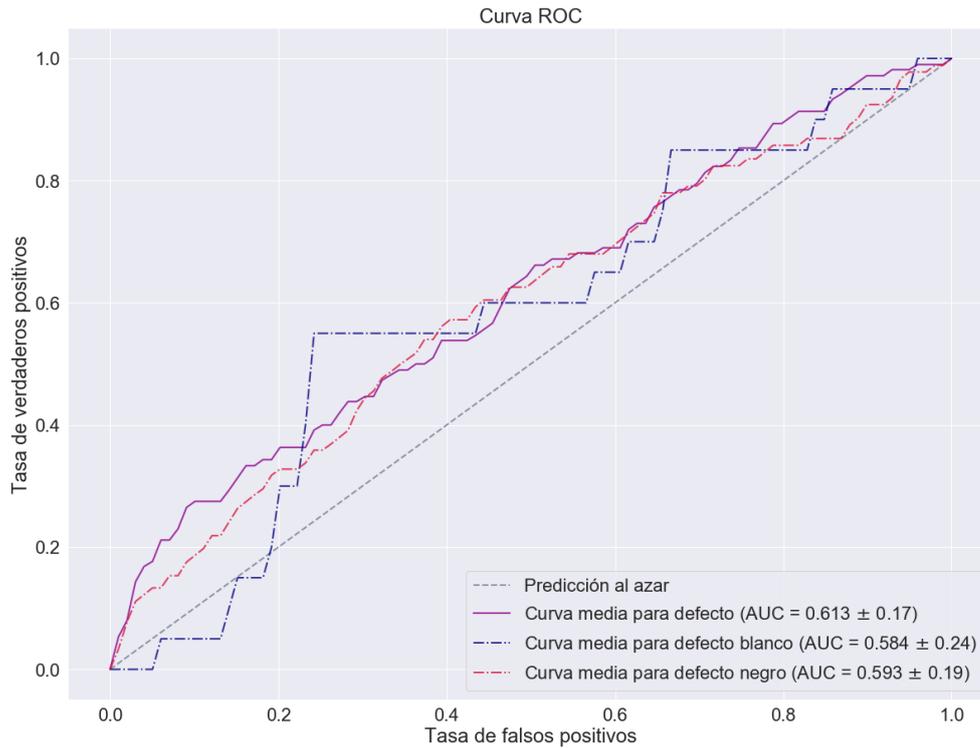


Figura 8.23: Curvas ROC de Support Vector Machine de núcleo de base radial con $\sigma = 4.082$ empleando el conjunto de datos A del Corpus II.

Resultados de Support Vector Machine de núcleo de base radial en el Corpus II		
	Tasa de equierror (EER)	Area Under Curve (AUC)
Conjunto de datos A	0.400 ± 0.12	0.613 ± 0.17 { Negro: 0.593 ± 0.19 Blanco: 0.584 ± 0.24

Tabla 8.35: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo Support Vector Machine de núcleo de base radial con $\sigma = 4.082$ creado a partir del conjunto A de datos del Corpus II.

Valores mediocres para el área bajo la curva y la tasa de equierror (Tabla 8.35) así como la posición de los puntos de las curvas ROC (Figura 8.23) apuntan a la obtención de un modelo con una capacidad clasificadora reducida.

La complejidad superior del núcleo de base radial no logra crear un clasificador equilibrado, ya que sigue teniendo dificultades con las imágenes correspondientes a tableros con algún tipo de defecto (Tabla 8.36). Aunque la tasa de acierto haya disminuido, clasifica mal menos tableros con defectos que los modelos Support Vector Machines anteriores, dando lugar a una sensibilidad algo más alta.

Sistema de Support Vector Machine de núcleo de base radial -Conjunto de datos A, Corpus II-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	3676	89	3765
	Con defecto	218	18	235
		3893	107	4000

- Tasa de acierto: 92.35 %.
- Intervalo de confianza del 95 %:(89.34, 95.36)
- Sensibilidad: 16.82 %
- Especificidad: 94.40 %

Tabla 8.36: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo de base radial con $\sigma = 4.082$ del Corpus II con el conjunto de datos A.

8.4.3.4. Conjunto de datos B

Modelo óptimo. Seleccionado bajo criterio de máximo F-Score estimado por validación cruzada.

- 83 variables, todas las del conjunto de datos.
- El valor óptimo de σ elegido mediante validación cruzada ha sido 5.

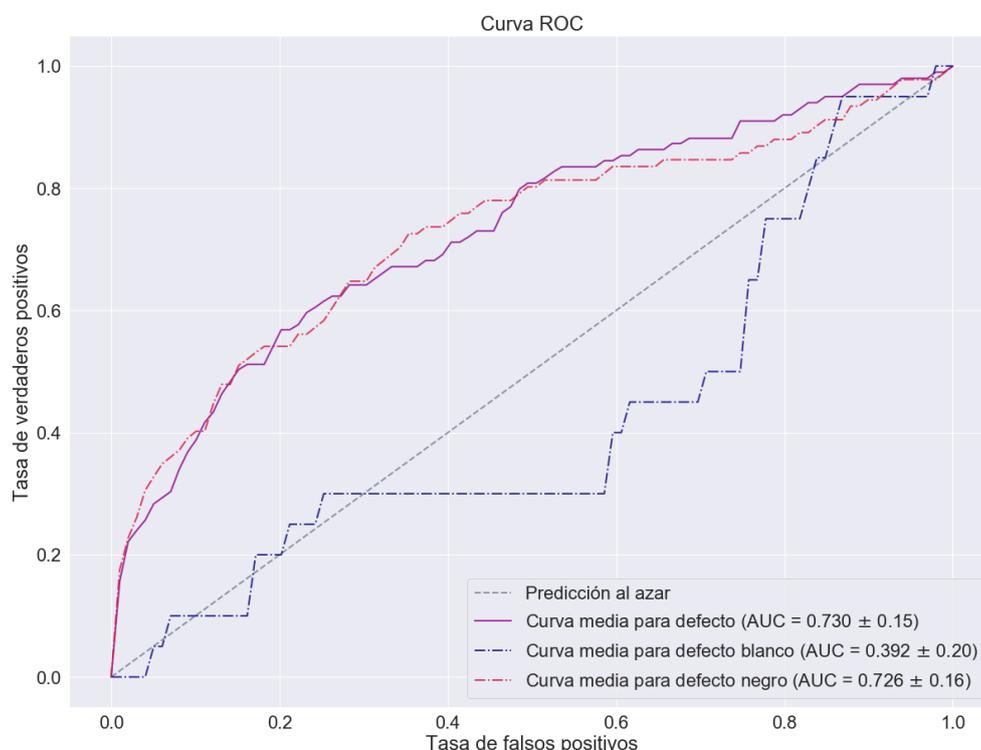


Figura 8.24: Curvas ROC de Support Vector Machine de núcleo de base radial con $\sigma = 5$ empleando el conjunto de datos B del Corpus II.

Resultados de Support Vector Machine de núcleo de base radial en el Corpus II		
	Tasa de equierror (EER)	Area Under Curve (AUC)
Conjunto de datos B	0.380 ± 0.13	0.730 ± 0.15 { Negro: 0.726 ± 0.16 Blanco: 0.392 ± 0.20

Tabla 8.37: Estimación de la tasa de equierror y el área bajo la curva ROC del modelo Support Vector Machine de núcleo de base radial con $\sigma = 5$ creado a partir del conjunto B de datos del Corpus II.

El modelo es capaz de obtener el área bajo la curva de defecto general más alto a la vez que una tasa de equierror no muy elevada en relación con los modelos anteriores del Corpus II (Tabla 8.35). Las curvas ROC de defecto general y negro se distribuyen de una forma correcta mientras que la de defectos blancos, con un valor de la AUC paupérrimo, evidencia una detección de defectos blancos imprecisa (Figura 8.23).

La Tabla 8.38 nos muestra cómo el modelo óptimo alcanzado da lugar a una clasificación similar a la obtenida con los métodos previos. Parece ser el mejor modelo creado hasta ahora para el Corpus II ya que aparentemente clasifica correctamente casi un 20 % de las muestras de imágenes con defectos que recibe, más que los modelos de este Corpus de vector soporte anteriores y de regresión logística. Su sensibilidad aún es demasiado baja por lo que el margen de mejora es amplio.

Sistema de Support Vector Machine de núcleo de base radial -Conjunto de datos B, Corpus II-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	3789	86	3875
	Con defecto	104	21	125
		3893	107	4000

- Tasa de acierto: 95.25 %.
- Intervalo de confianza del 95 %:(92.84, 97.66)
- Sensibilidad: 19.63 %
- Especificidad: 97.33 %

Tabla 8.38: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo SVM de núcleo de base radial con $\sigma = 5$ del Corpus II con el conjunto de datos B.

La Tabla resumen 8.39 muestra los resultados obtenidos con Support Vector Machines de núcleo lineal, polinómico y de base radial.

Con respecto al Corpus I podemos destacar cómo el mejor resultado se alcanza con el núcleo de base radial y el conjunto de datos B si tomamos como criterio de selección la tasa de equierror o la tasa de acierto del modelo ajustado. El AUC estimado es prácticamente el mismo que el del modelo con el conjunto de variables A. El núcleo polinómico de grado dos empleado parece haber dado lugar a un caso de sobreajuste: aunque el error en el conjunto de entrenamiento era inferior que en el caso del núcleo lineal, el error de generalización estimado por validación cruzada que aparece en la tabla es mayor.

Los resultados con el Corpus II no son satisfactorios en su inmensa mayoría: la alta tasa de acierto es engañosa, ya que el estudio de las matrices de confusión mostradas a lo largo de esta sección revelan la escasa capacidad de clasificación existente en lo que se refiere a las imágenes con defectos. El modelo más equilibrado, capaz de clasificar correctamente el 20 % de las muestras de tablero con defectos, ha sido el que ha resultado óptimo también en el caso del Corpus I: el SVM de núcleo de base radial creado con el conjunto de datos B. Cabe destacar como este modelo es aquel con más área bajo la curva ROC de los creados a partir del Corpus II.

Tasa de acierto estimada de los modelos de Support Vector Machine

		Corpus I				Corpus II			
		Variables	EER	AUC	Tasa de acierto	Variables	EER	AUC	Tasa de acierto
Lineal	Conjunto A	39	-	-	96.97 %	49	-	-	97.25 %
	Conjunto B	37	-	-	97.05 %	63	-	-	97.38 %
Polin.	Conjunto A	70	0.111	0.937	96.66 %	70	0.512	0.544	95.97 %
	Conjunto B	83	0.117	0.922	96.76 %	83	0.532	0.491	96.70 %
RBF	Conjunto A	70	0.086	0.964	97.24 %	70	0.400	0.613	92.35 %
	Conjunto B	83	0.066	0.962	97.34 %	83	0.380	0.730	95.25 %

Tabla 8.39: Número de variables, AUC y EER, así como tasa de acierto estimada por validación cruzada del modelo seleccionado, de los sistemas de Support Vector Machine de núcleo lineal, Polinómico (Polin.) y de base radial (RBF) haciendo uso de los conjuntos de datos A y B en ambos Corpus.

8.5. Redes Neuronales

De acuerdo a la metodología establecida en la sección 7.4 se han desarrollado los distintos tipos de redes neuronales. En cada una de las secciones que sigue se especifica la arquitectura de la red en forma de gráfico. Las redes neuronales desarrolladas han sido las siguientes:

1. Perceptrón multicapa. Mediante validación cruzada se han seleccionado la arquitectura de la red, la función de activación de las neuronas y el valor de α como parámetro de regularización tal que el valor de la tasa de error estimada fuese mínimo.

8.5.1. Perceptrón Multicapa (MLP)

Corpus I

En los modelos creados a partir de los conjuntos de datos extraídos del Corpus I de imágenes ha sido necesario dar el doble de peso a las observaciones de imágenes sin defectos al existir menos representación de esta clase en el conjunto de datos.

8.5.1.1. Conjunto de datos A

Modelo óptimo. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada.

- Función de activación: unidad lineal rectificada (ReLU).
- Arquitectura (Figura 8.25):
 - Capa de entrada: 70 neuronas (una por variable del conjunto).
 - Capas ocultas: tres capas con respectivamente 3, 3 y 5 neuronas.
 - Capa de salida: 1 neurona.

Estructura del perceptrón multicapa

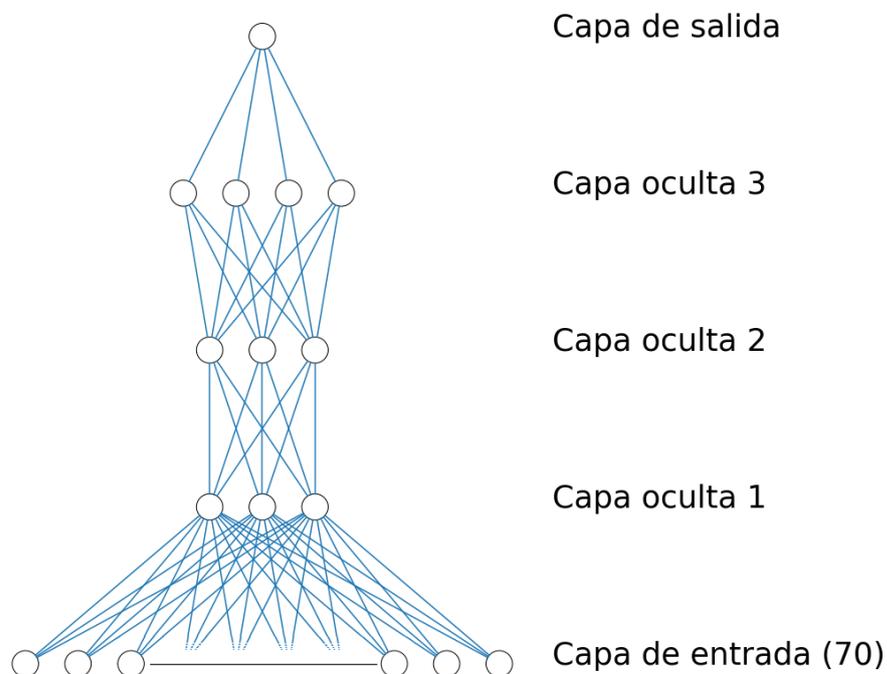


Figura 8.25: Estructura óptima para el perceptrón multicapa inducido con el conjunto de datos A del Corpus I.

El perceptrón multicapa óptimo creado a partir de los datos del conjunto A en el caso del Corpus I consta de tres capas ocultas y emplea la función de activación de la unidad lineal rectificada.

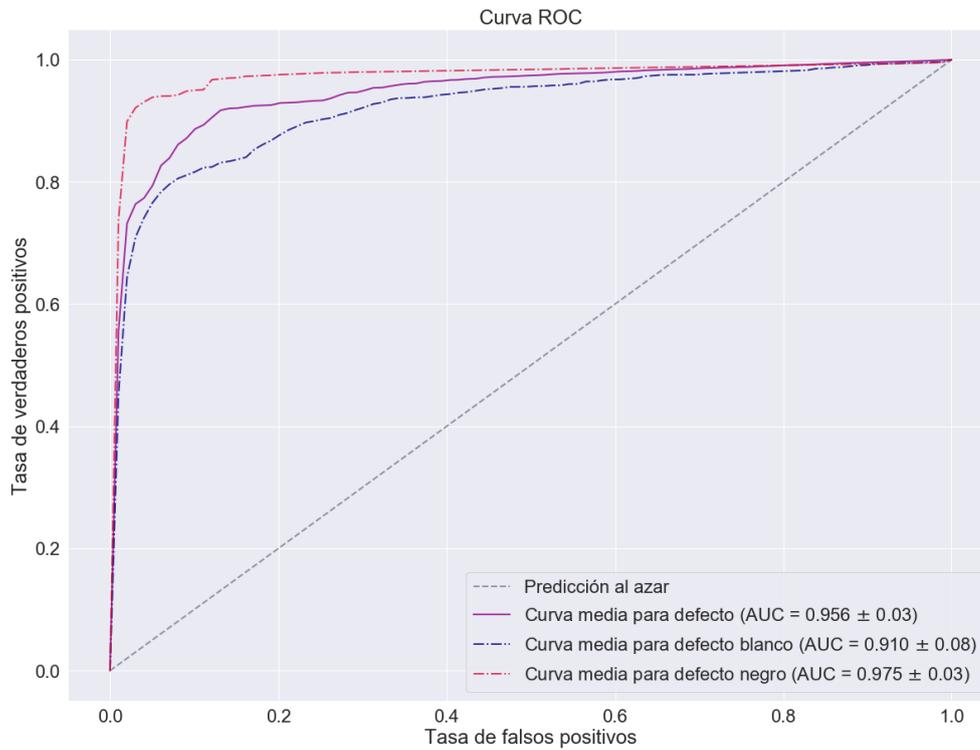


Figura 8.26: Curvas ROC del perceptrón multicapa empleando el conjunto de datos A del Corpus I.

Resultados del perceptrón multicapa en el Corpus I		
	Tasa de equierror (EER)	Area Under Curve (AUC)
Conjunto de datos A	0.101 ± 0.10	0.956 ± 0.03 { Negro: 0.975 ± 0.08 Blanco: 0.910 ± 0.08

Tabla 8.40: Estimación de la tasa de equierror y el área bajo la curva ROC del perceptrón multicapa creado a partir del conjunto A de datos del Corpus I.

El perceptrón multicapa seleccionado logra valores para las áreas bajo las curvas ROC altamente satisfactorios así como un valor de la tasa de equierror del 10% de observaciones mal-clasificadas para cada una de las clases (Tabla 8.40). Las curvas ROC indican que el sistema es capaz de detectar de forma balanceada defectos blancos y negros (Figura 8.26).

El modelo con el umbral de clasificación definido da lugar a una tasa de acierto altamente satisfactoria que supera las obtenidas con los procedimientos anteriores de aprendizaje y el sistema de referencia (Tabla 8.41). Se trata de un modelo mucho más equilibrado que los anteriores, ya que la diferencia en número entre falsos negativos y falsos positivos no es tan significativa.

Sistema perceptrón multicapa -Conjunto de datos A, Corpus I-				
		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	618	93	711
	Con defecto	91	6365	6456
		709	6458	7167

- Tasa de acierto: 97.43 %.
- Intervalo de confianza del 95 %:(96.09, 98.77)
 - Sensibilidad: 98.55 %
 - Especificidad: 87.16 %

Tabla 8.41: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo de perceptrón multicapa del Corpus I con el conjunto de datos A.

8.5.1.2. Conjunto de datos B

Modelo óptimo. Seleccionado bajo criterio de máxima tasa de acierto estimada por validación cruzada.

- Función de activación: unidad lineal rectificada (ReLU).
- Arquitectura (Figura 8.27):
 - Capa de entrada: 83 neuronas (una por variable del conjunto).
 - Capas ocultas: tres capas de tres neuronas cada una.
 - Capa de salida: 1 neurona.

La función lineal rectificada así como una arquitectura muy similar a la óptima en el caso del conjunto de datos A parece ser la estructura óptima para el perceptrón con este conjunto de datos.

Estructura del perceptrón multicapa

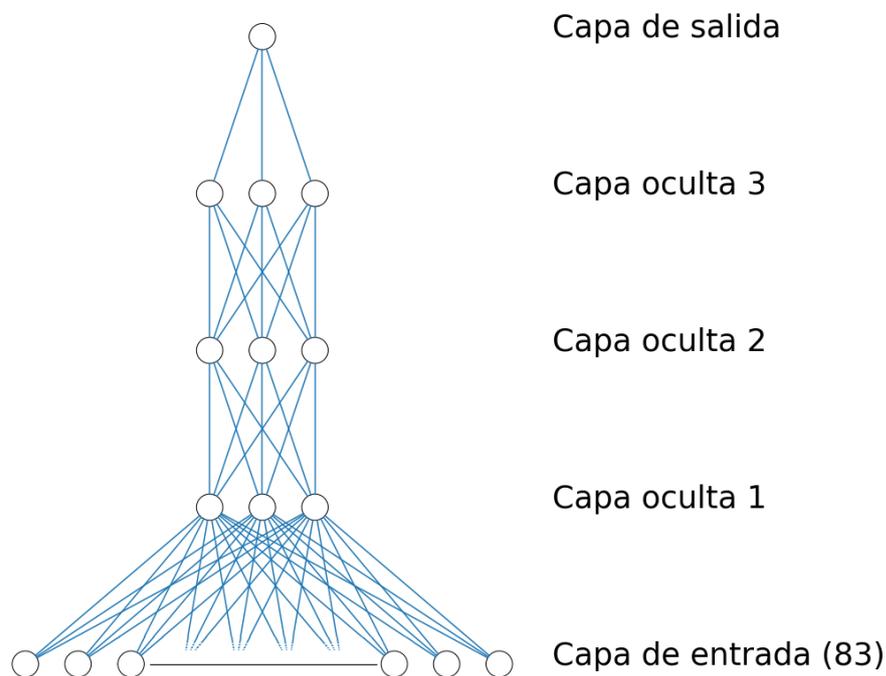


Figura 8.27: Estructura óptima para el perceptrón multicapa inducido con el conjunto de datos B del Corpus I.

El modelo obtenido logra una tasa de equierror muy baja así como un área bajo la curva ROC de valor alto (Tabla 8.42). Las curvas ROC de cada uno de los tipos de defectos son equilibradas y satisfactorias (Figura 8.28).

Resultados del perceptrón multicapa en el Corpus I			
	Tasa de equierror (EER)	Area Under Curve (AUC)	
Conjunto de datos B	0.083 ± 0.06	0.930 ± 0.08	{ Negro: 0.975 ± 0.03 Blanco: 0.928 ± 0.07

Tabla 8.42: Estimación de la tasa de equierror y el área bajo la curva ROC del perceptrón multicapa creado a partir del conjunto B de datos del Corpus I.

El modelo ajustado es capaz de obtener un resultado muy satisfactorio (Tabla 8.43). Este modelo parece funcionar algo peor que el obtenido con el conjunto de datos A, pero la diferencia es ínfima: la observación detallada de las matrices de confusión nos hace percatarnos de que la tasa de acierto y el número de falsos positivos y falsos negativos es prácticamente el mismo.

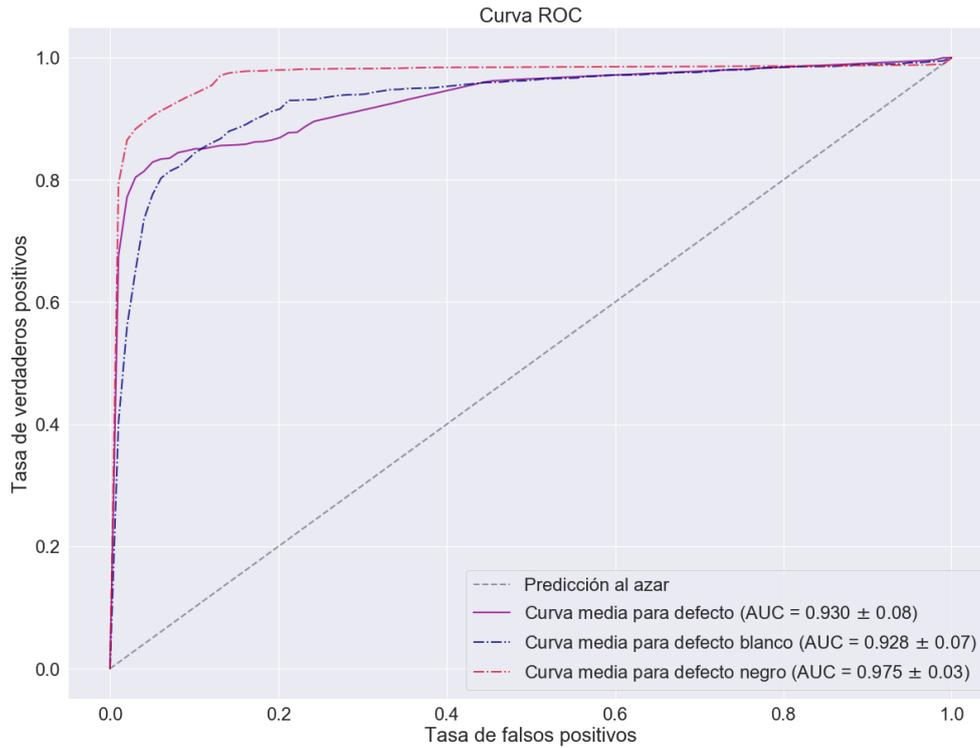


Figura 8.28: Curvas ROC del perceptrón multicapa empleando el conjunto de datos B del Corpus I.

Sistema perceptrón multicapa -Conjunto de datos B, Corpus I-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	617	96	711
	Con defecto	92	6362	6456
		709	6458	7167

- Tasa de acierto: 97.37 %.
- Intervalo de confianza del 95 %:(96.02, 98.72)
- Sensibilidad: 98.51 %
- Especificidad: 87.02 %

Tabla 8.43: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo de perceptrón multicapa del Corpus I con el conjunto de datos B.

Corpus II

Para los modelos del Corpus II ha sido necesario dar el triple de peso a las observaciones de imágenes defectuosas en compensación por su escasez con respecto a la otra clase. Los modelos óptimos se han seleccionado en base a la tasa de acierto y a su equilibrio, es decir, que el número de falsos positivos y de falsos negativos fuese similar.

8.5.1.3. Conjunto de datos A

Modelo óptimo. Seleccionado bajo criterio de máximo F-Score estimado por validación cruzada.

- Función de activación: tangente hiperbólica.
- Arquitectura (Figura 8.29):
 - Capa de entrada: 70 neuronas (una por variable del conjunto).
 - Capas ocultas: tres capas de tres neuronas cada una.
 - Capa de salida: 1 neurona.

El modelo escogido cuenta con tres capas ocultas homogéneas de tres neuronas en las que la función de activación es la tangente hiperbólica.

Estructura del perceptrón multicapa

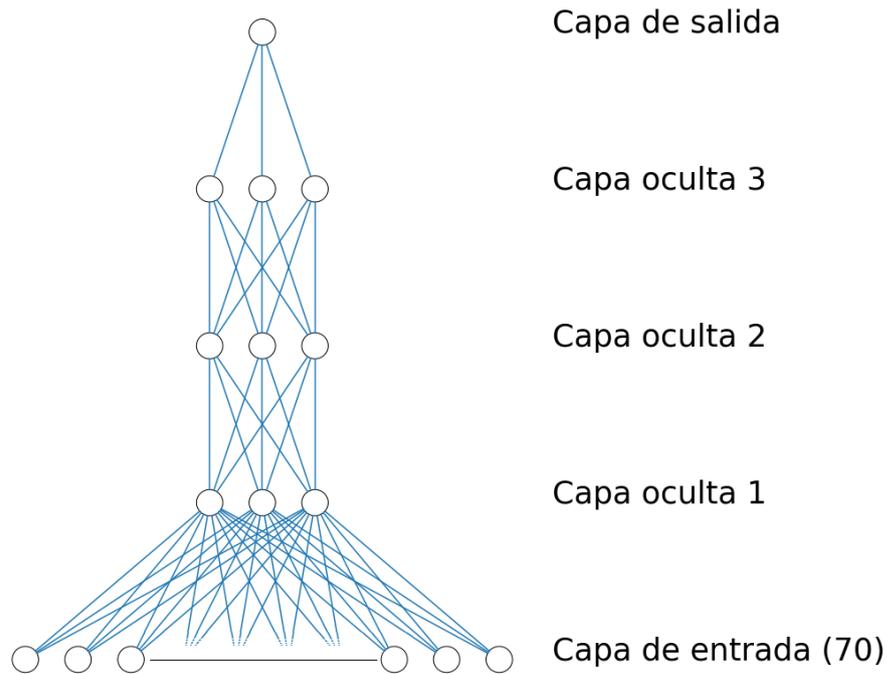


Figura 8.29: Estructura óptima para el perceptrón multicapa inducido con el conjunto de datos A del Corpus II.

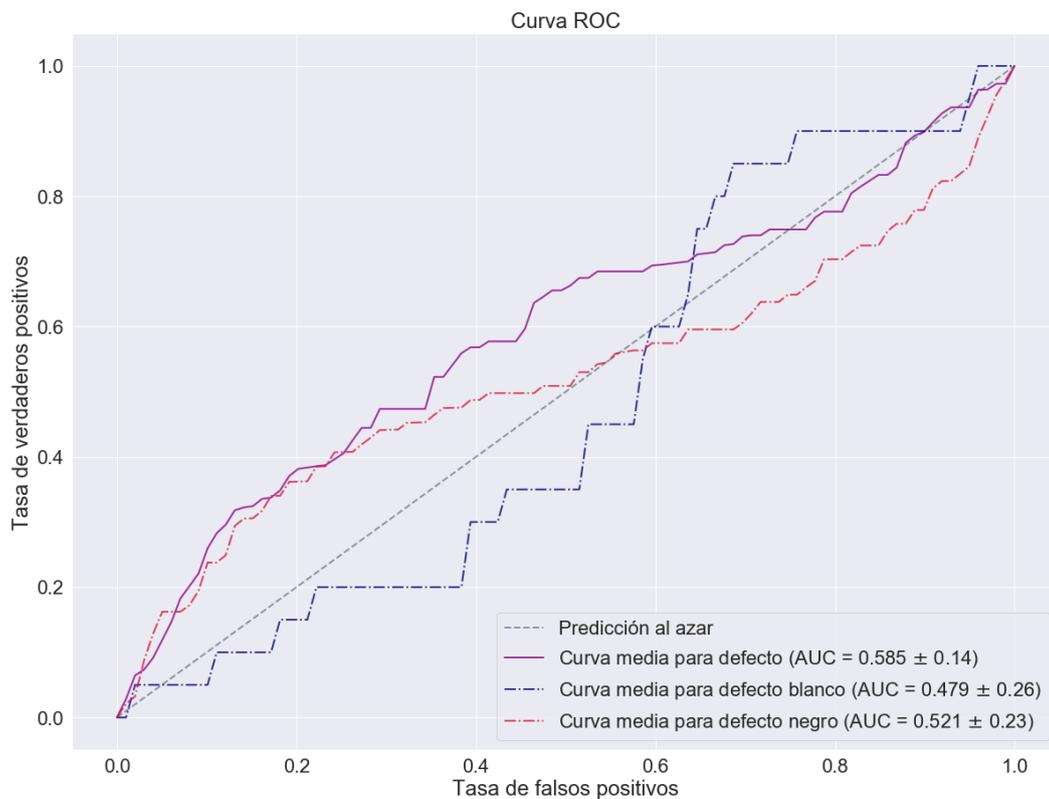


Figura 8.30: Curvas ROC del perceptrón multicapa empleando el conjunto de datos A del Corpus II.

Los valores de las áreas bajo la curva y de la tasa de equierror (Tabla 8.44) así como la distribución de las curvas ROC (Figura 8.30) nos indican que el clasificador resultante podría ser ligeramente mejor que la asignación al azar. La variabilidad en el área bajo la curva ROC de defectos blancos es alta, al igual que la de defectos negros.

Resultados del perceptrón multicapa en el Corpus II			
	Tasa de equierror (EER)	Area Under Curve (AUC)	
Conjunto de datos A	0.464 ± 0.14	0.585 ± 0.14	<ul style="list-style-type: none"> Negro: 0.521 ± 0.23 Blanco: 0.479 ± 0.26

Tabla 8.44: Estimación de la tasa de equierror y el área bajo la curva ROC del perceptrón multicapa creado a partir del conjunto A de datos del Corpus II.

El perceptrón multicapa logra un resultado similar al SVM de núcleo de base radial (Tabla 8.45): la tasa de acierto aparentemente es alta, pero la observación de la matriz de confusión nos hace percatarnos de su deficiencia en la detección de tableros con defectos. La sensibilidad del sistema es muy baja.

Sistema perceptrón multicapa -Conjunto de datos A, Corpus II-				
		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	3631	89	3720
	Con defecto	262	18	280
		3893	107	4000

- Tasa de acierto: 91.23 %.
- Intervalo de confianza del 95 %:(88.03, 94.43)
- Sensibilidad: 16.82 %
- Especificidad: 93.27 %

Tabla 8.45: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo de perceptrón multicapa del Corpus II con el conjunto de datos A.

8.5.1.4. Conjunto de datos B

Modelo óptimo. Seleccionado bajo criterio de máximo F-Score estimado por validación cruzada.

- Función de activación: tangente hiperbólica.
- Arquitectura (Figura 8.31):
 - Capa de entrada: 83 neuronas (una por variable del conjunto).
 - Capas ocultas: dos capas de 3 y 2 neuronas respectivamente.
 - Capa de salida: 1 neurona.

En base a una arquitectura simple de dos capas ocultas con estructura de neuronas 3-2 y con función de activación tangente hiperbólica se ha construido el modelo del conjunto de datos B del Corpus II.

Resultados del perceptrón multicapa en el Corpus II			
	Tasa de equierror (EER)	Area Under Curve (AUC)	
Conjunto de datos B	0.306 ± 0.13	0.730 ± 0.17	<ul style="list-style-type: none"> Negro: 0.672 ± 0.12 Blanco: 0.495 ± 0.32

Tabla 8.46: Estimación de la tasa de equierror y el área bajo la curva ROC del perceptrón multicapa creado a partir del conjunto B de datos del Corpus II.

Obtenemos uno de los modelos más satisfactorios en cuanto lo que se refiere al Corpus II, con un valor relativamente satisfactorio para el área bajo la curva y una tasa de equierror del 30 %. (Tabla 8.46 y Figura 8.32). La detección de defectos blancos se encuentra por debajo del umbral de la decisión al azar.

Estructura del perceptrón multicapa

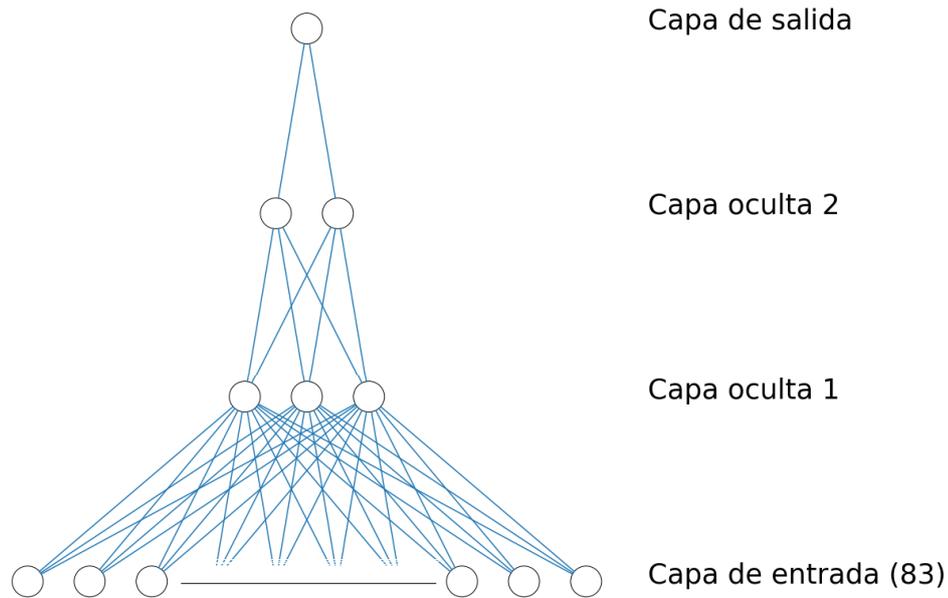


Figura 8.31: Estructura óptima para el perceptrón multicapa inducido con el conjunto de datos B del Corpus II.

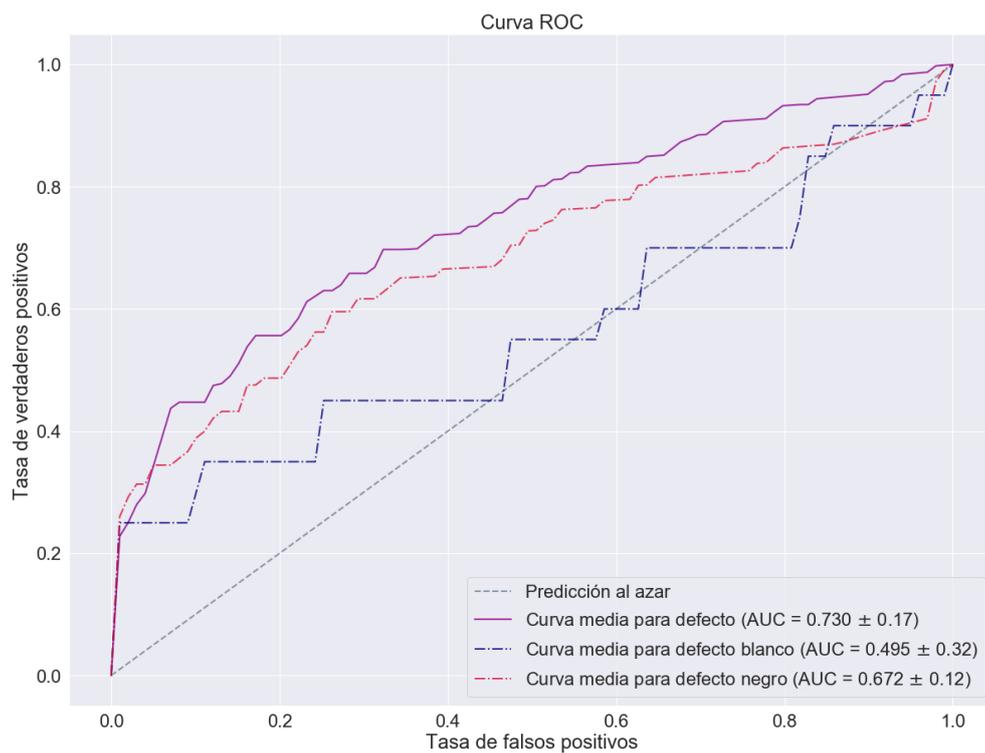


Figura 8.32: Curvas ROC del perceptrón multicapa empleando el conjunto de datos B del Corpus II.

Se puede afirmar que este es el modelo obtenido hasta el momento más satisfactorio en lo referente al Corpus II (Tabla 8.47): puede que la tasa de acierto pueda mejorarse aún, pero se logra que la sensibilidad más alta de todos los modelos estudiados hasta ahora (cerca del 50% de las observaciones con defectos). Aún así este dato se puede mejorar mucho.

Sistema perceptrón multicapa -Conjunto de datos B, Corpus II-

		Clase		
		Sin Defecto	Con defecto	
Etiqueta	Sin Defecto	3766	65	3831
	Con defecto	127	42	169
		3893	107	4000

- Tasa de acierto: 95.20 %.
- Intervalo de confianza del 95 %:(92.78, 97.62)
 - Sensibilidad: 39.25 %
 - Especificidad: 96.74 %

Tabla 8.47: Matriz de confusión y tasa de acierto correspondiente del modelo óptimo de perceptrón multicapa del Corpus II con el conjunto de datos B.

La Tabla resumen 8.48 muestra que los modelos de perceptrón multicapa han dado lugar a resultados altamente satisfactorios.

El perceptrón multicapa obtenido a partir del conjunto de variables A del Corpus I obtiene la tasa de acierto hasta el momento más elevada, superando la del sistema de referencia y los modelos de regresión logística y Support Vector Machine. Los valores estimados para el área bajo la curva ROC de este modelo y la EER son también satisfactorios. El modelo de perceptrón multicapa creado a partir del conjunto de variables B del Corpus I parece cumplir con éxito las expectativas: la tasa de acierto es alta y prácticamente la misma que la del conjunto A (la más elevada hasta el momento) y supera su tasa de equierror.

El conjunto de datos A, en el caso del Corpus II, ha dado lugar a un clasificador que detecta imágenes con defectos de forma dudosa. Esto podría achacarse a la necesidad de algunos tipos de redes neuronales de que la representación de las clases sea suficientemente alta. El Corpus II no parece cumplir este requisito con el conjunto A. El funcionamiento del modelo creado a partir del conjunto B del Corpus II debe ser destacado: obtenemos el primer clasificador inducido con datos del Corpus II con una buena tasa de acierto y capaz de tener una capacidad clasificadora de cierta significancia tanto en imágenes con defectos como sin ellos, logrando una sensibilidad cercana al 40 %. No obstante, este dato dista de ser óptimo y podría aún mejorarse en un gran margen.

Resultados de los modelos de perceptrón multicapa								
	Corpus I				Corpus II			
	Variables	EER	AUC	Tasa de acierto	Variables	EER	AUC	Tasa de acierto
Conjunto A	70	0.101	0.956	97.43 %	70	0.464	0.585	91.23 %
Conjunto B	83	0.083	0.930	97.37 %	83	0.306	0.730	95.20 %

Tabla 8.48: Número de variables, AUC y EER, así como tasa de acierto estimada por validación cruzada del modelo seleccionado, de los sistemas de perceptrón multicapa haciendo uso de los conjuntos de datos A y B en ambos Corpus.

Capítulo 9

Discusión general de resultados

Este capítulo consistirá en la discusión global de los resultados alcanzados con los diferentes modelos desarrollados a lo largo de la memoria de ingeniería informática. Estos modelos se compararán con el sistema de referencia que emplea únicamente la suma de las variables del área de error relativa ya que sus resultados son mejores que los obtenidos con el que usa por separado las dos. En la correspondiente sección de la memoria de Trabajo de Fin de Grado de estadística [3] se comentan los resultados relativos a los sistemas desarrollados en la misma (análisis discriminante, árboles de decisión y extensiones de estos).

Como se ha detallado anteriormente, se realizará una comparativa global con los resultados estimados (área bajo la curva ROC, tasa de equierror, tasa de acierto, sensibilidad, especificidad y F-Score) por validación cruzada de 10 particiones para los dos conjuntos de datos extraídos (Conjunto A -Componentes Principales- y Conjunto B -Estadísticos-) de los Corpus I y II de imágenes.

9.1. Comparativa de los modelos según AUC y EER

Compendio general de resultados								
			Corpus I			Corpus II		
			Variables	EER	AUC	Variables	EER	AUC
00		Sist. Ref.	1	0.046	0.962	1	0.551	0.459
01	RLog	Conjunto A	48	0.070	0.971	49	0.428	0.610
		Conjunto B	63	0.090	0.954	41	0.331	0.608
02 SVM	Pol	Conjunto A	70	0.111	0.937	70	0.512	0.544
		Conjunto B	83	0.117	0.922	83	0.532	0.491
	RBF	Conjunto A	70	0.086	0.964	70	0.400	0.613
		Conjunto B	83	0.066	0.962	83	0.380	0.730
03	MLP	Conjunto A	70	0.101	0.956	70	0.464	0.585
		Conjunto B	83	0.083	0.930	83	0.306	0.730

Tabla 9.1: Número de variables, AUC y EER de los modelos estudiados en la memoria de ingeniería informática.

En la Tabla 9.1 aparecen los valores de las tasas de equierror y áreas bajo la curva ROC de defecto general de los modelos estudiados en la memoria de ingeniería informática. Los modelos de SVM de núcleo lineal al haberse optimizado con regularización L1 no se ha podido definir su salida como probabilística y por tanto no se ha podido estimar su EER y AUC. Parece que los resultados más destacables provienen de Support Vector Machine de núcleo de base radial y de los perceptrones multicapa aunque en ambos casos los resultados en el Corpus II no son excepcionales.

En el Corpus I, el mejor modelo según el valor de la tasa de equierror es, a pesar de su simpleza, el sistema de referencia. Los tres mejores modelos de aprendizaje supervisado según esta medida han sido los SVM de núcleo de base radial con el conjunto de datos B, la regresión logística con el A y el perceptrón multicapa con el conjunto B de variables. La ventaja que ofrece la regresión logística es emplear un subconjunto reducido de variables sobre el total. Empleando el área bajo la curva ROC como medida comparativa, el modelo de SVM de base radial con el conjunto de datos A sustituye al perceptrón multicapa con el conjunto de los estadísticos como tercer mejor modelo de reconocimiento de patrones. El sistema de referencia logra empatar esta marca.

En el caso del Corpus II, los modelos de regresión logística, SVM de núcleo RBF y los MLP logran resultados medios con tasas de equierror inferiores al 45 %. El resto de modelos logran resultados bastante pobres, especialmente el sistema de referencia que da lugar a un modelo de clasificación en el que la asignación al azar sería más eficaz.

Las Figuras 9.1 y 9.2 muestran mediante gráficos de líneas las estimaciones realizadas de área bajo la curva ROC y la probabilidad complementaria a la tasa de equierror: $1 - EER$, a la que he denominado tasa de equiacierto, asociadas a los modelos creados con los conjuntos de datos A y B extraídos de los Corpus I y II respectivamente. Es importante destacar la diferencia de escala existente en ambas Figuras.

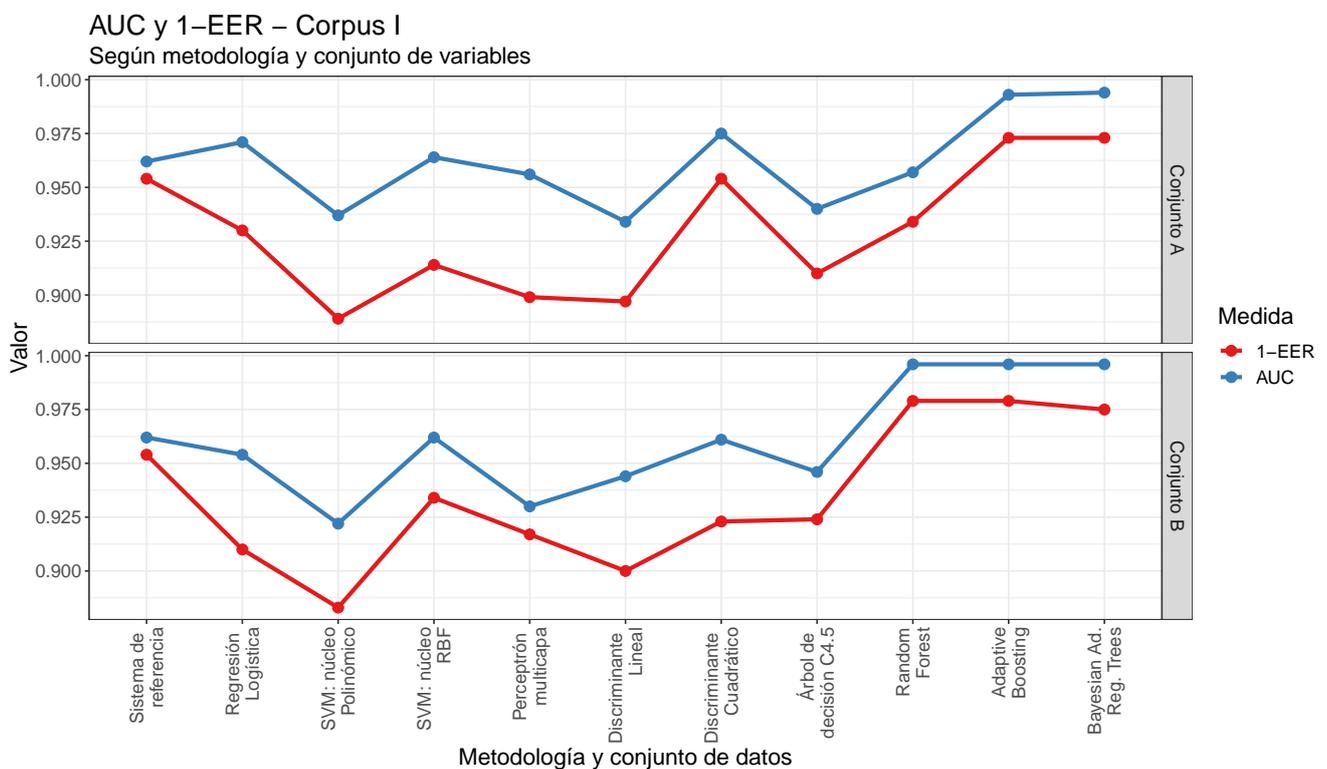


Figura 9.1: AUC y tasa de equiacierto para cada uno de los conjuntos de datos del Corpus I y metodología empleada.

Podemos extraer una serie de conclusiones similares a las obtenidas a partir de la Tabla 9.1. Mientras que los resultados del Corpus I son bastante similares y uniformes, los del Corpus II son mucho más variables debido a la resolución más pobre de las imágenes. Podemos comentar como el área bajo la curva ROC y la tasa de equiacierto, y por tanto la tasa de equierror, son bastante parejas para realizar una comparativa de calidad de las metodologías empleadas. La Figura 9.3 une en un único gráfico de líneas las Figuras 9.1 y 9.2, representándose en un solo gráfico el AUC y tasa de equiacierto para ambos Corpus con cada uno de los algoritmos empleados. Como ya hemos comentado, el que los modelos del Corpus I queden por encima de los del Corpus II en su totalidad se debe a la menor resolución del segundo conjunto de imágenes.

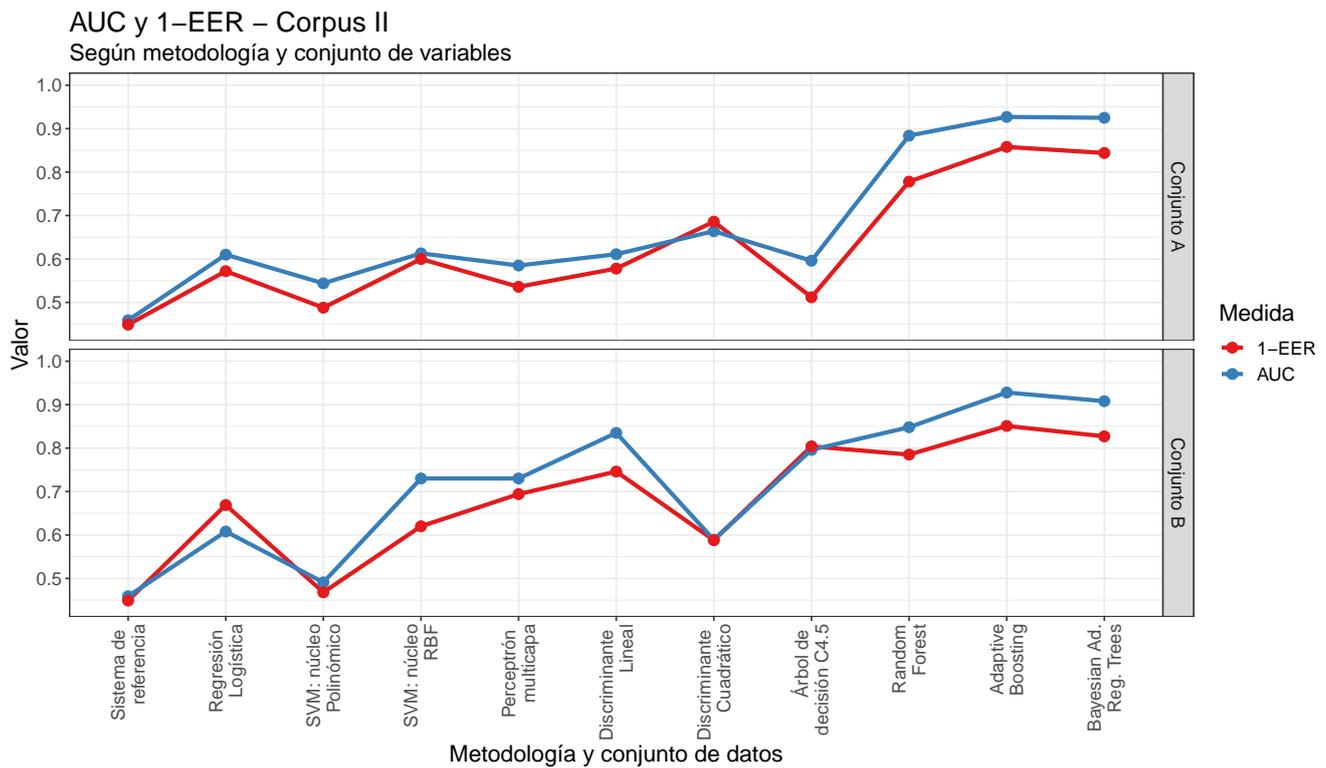


Figura 9.2: Área bajo la curva ROC y tasa de equiabierto para cada uno de los conjuntos de datos del Corpus II y metodología empleada.

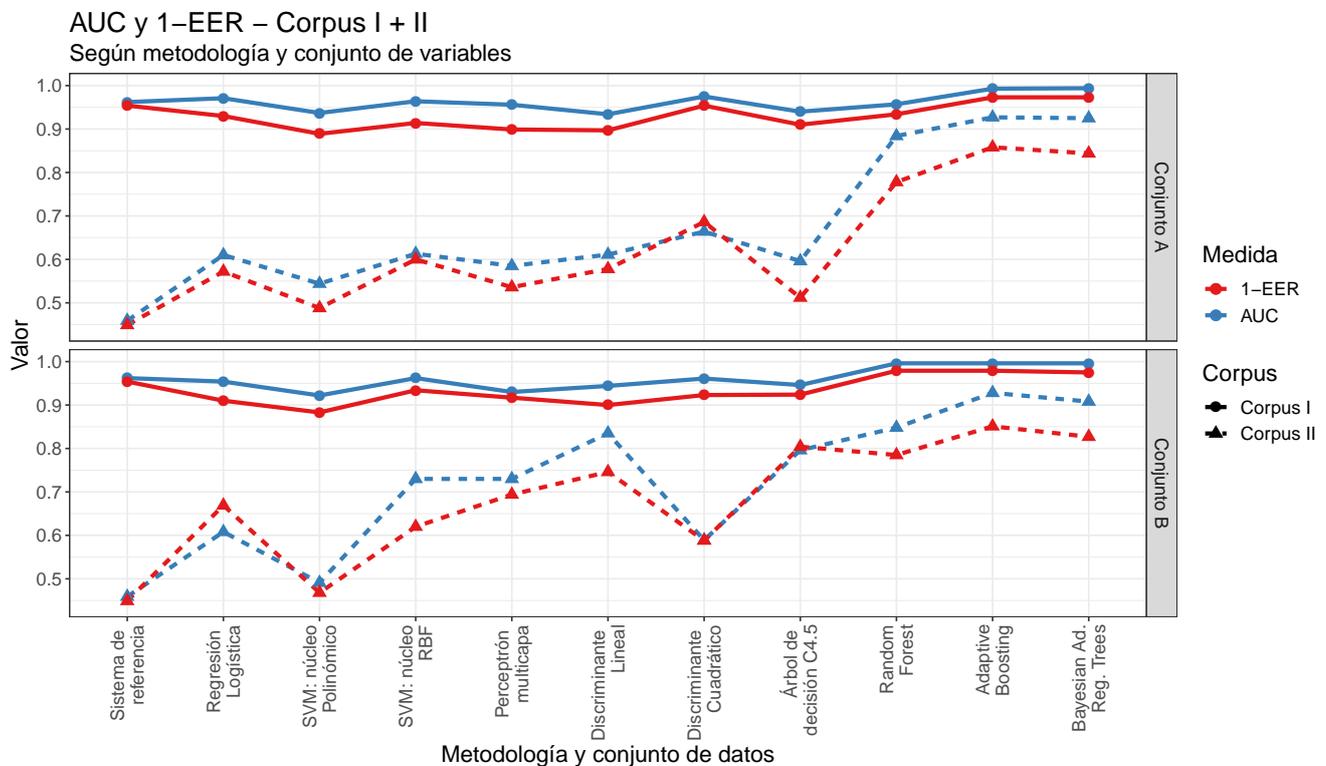


Figura 9.3: Área bajo la curva ROC y tasa de equiabierto para cada uno de los conjuntos de datos de los Corpus I y II (representados con estilos de línea diferentes) y metodología empleada.

Las Figuras 9.4 y 9.5 son una visualización de la relación existente entre el AUC y el número de variables en función del conjunto de datos y la metodología empleadas en el Corpus I y Corpus II. Es relevante destacar que aunque las figuras de los dos Corpus son altamente similares, existe una diferencia de escala significativa en el eje vertical (área bajo la curva ROC). Se podría hacer otro par de figuras con la tasa de equierror pero las representaciones que obtendríamos serían análogas a las del AUC.

En el Corpus I, en cuanto a los modelos desarrollados en esta memoria, podemos destacar los modelos de SVM de núcleo RBF de alta dimensionalidad, los de regresión logística con menos variables y el simple sistema de referencia. Este último logra una marca bastante buena para su relativa simpleza, como ya se ha comentado.

El rango de valores de los modelos del Corpus II en lo que se refiere a área bajo la curva ROC es mucho más extenso que en el Corpus I. El sistema de referencia resulta ser excesivamente simple y se aproxima a la asignación azarosa muy posiblemente debido a la pobre calidad de las imágenes. Destacan los modelos de SVM de base radial y los MLP sobre el resto de los modelos desarrollados en esta memoria aunque resultan ser notablemente inferiores a otras metodologías desarrolladas en la memoria de estadística [3].

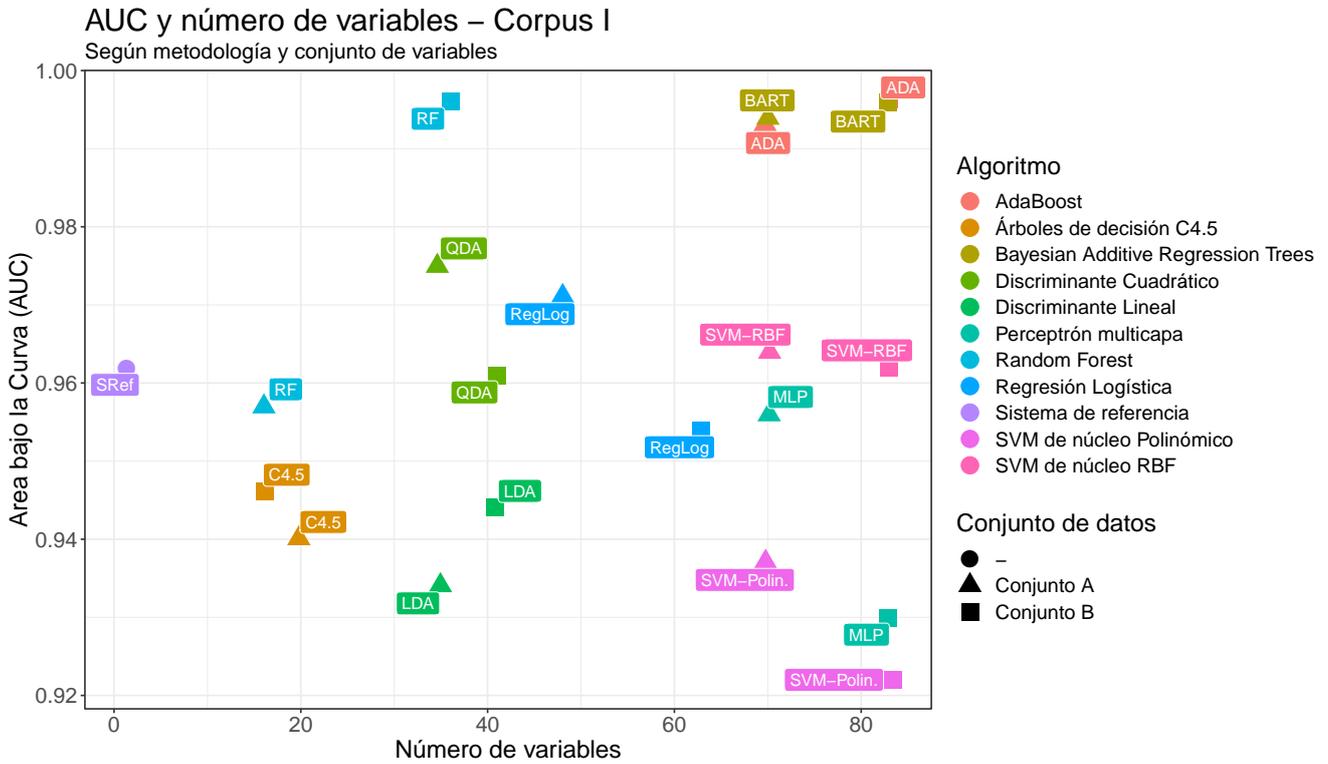


Figura 9.4: Área bajo la curva ROC y número de variables según el conjunto de datos del Corpus I usado y el clasificador empleado.

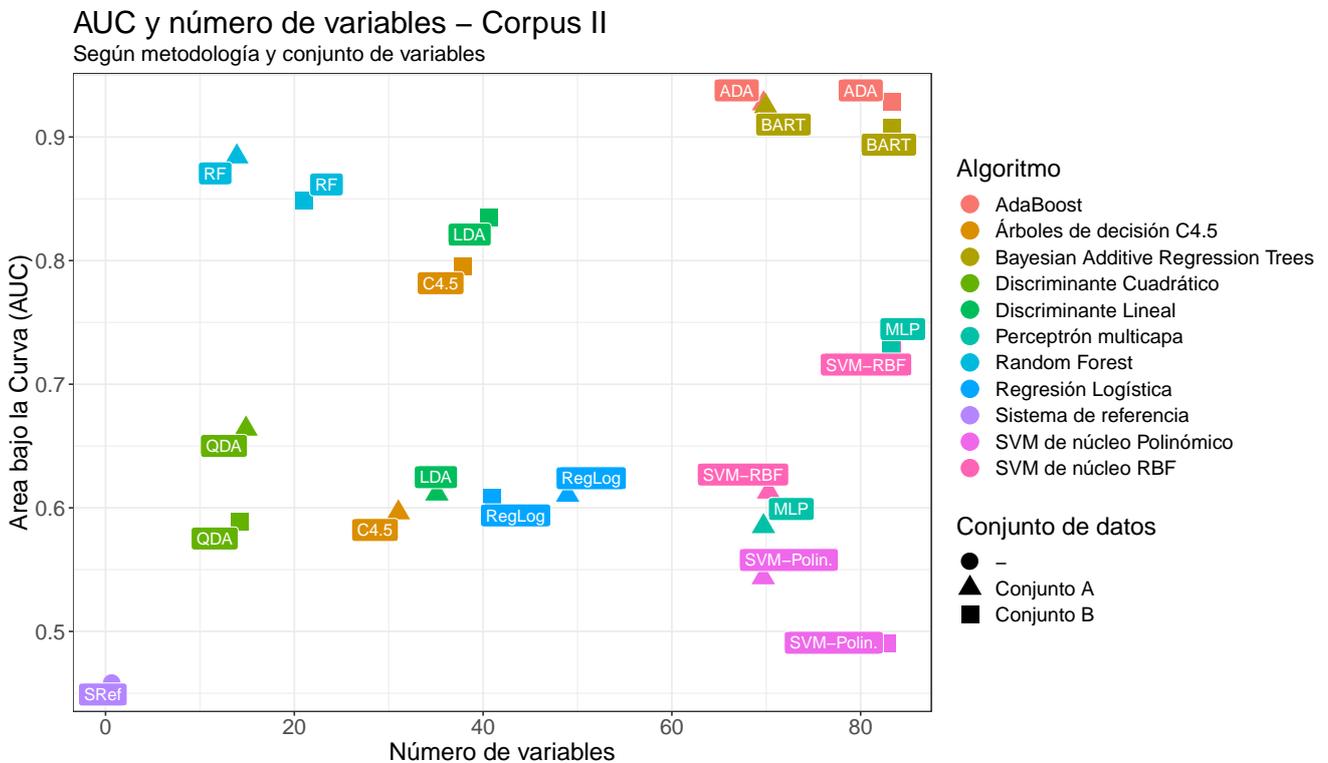


Figura 9.5: Área bajo la curva ROC y número de variables según el conjunto de datos del Corpus II usado y el clasificador empleado.

9.2. Comparativa de los modelos según precisión, especificidad y sensibilidad

La Tabla 9.2 refleja las medidas alcanzadas por los modelos desarrolladas en esta memoria relativas a precisión, sensibilidad (True Positive Rate -TPR-) y especificidad (True Negative Rate -TNR-) de los sistemas cuyo umbral probabilístico (de Score) de clasificación ha sido asignado según el criterio correspondiente de los resultados. Tal y como se ha detallado en la introducción de esta sección, se han estimado las medidas en los modelos de análisis supervisado mediante validación cruzada de diez particiones.

Compendio general de resultados										
			Corpus I				Corpus II			
			Variables	Precisión	TPR	TNR	Variables	Precisión	TPR	TNR
	00	Sist. Ref.	1	95.75 %	95.80 %	95.34 %	1	45.03 %	49.50 %	44.90 %
01	RLog	Conjunto A	48	95.82 %	97.89 %	77.00 %	49	96.85 %	1.87 %	99.51 %
		Conjunto B	63	95.32 %	98.90 %	62.76 %	41	96.72 %	20.56 %	98.82 %
02 SVM	Lin	Conjunto A	39	96.97 %	99.00 %	78.27 %	49	97.25 %	0.93 %	99.89 %
		Conjunto B	37	97.05 %	98.98 %	79.55 %	63	97.38 %	10.28 %	99.76 %
	Pol	Conjunto A	70	96.66 %	98.93 %	74.61 %	70	95.97 %	3.74 %	98.51 %
		Conjunto B	83	96.76 %	99.10 %	75.46 %	83	96.70 %	10.28 %	99.07 %
RBF	Conjunto A	70	97.24 %	99.08 %	80.39 %	70	92.35 %	16.82 %	94.40 %	
	Conjunto B	83	97.34 %	99.21 %	80.48 %	83	95.25 %	19.63 %	97.33 %	
03	MLP	Conjunto A	70	97.43 %	98.55 %	87.16 %	70	91.23 %	16.82 %	93.27 %
		Conjunto B	83	97.37 %	98.51 %	87.02 %	83	95.20 %	39.25 %	96.74 %

Tabla 9.2: Número de variables así como tasa de acierto, sensibilidad y especificidad estimada de los modelos estudiados en la memoria de ingeniería informática.

En el caso del Corpus I, se obtienen marcas excelentes en los que la precisión siempre queda superior al 95 %. La sensibilidad, por encima del 90 % en los modelos estudiados, permanece siempre por encima de la estimación de la tasa de verdaderos negativos o especificidad. Esta preferencia de los clasificadores para asignar la etiqueta positiva ('defectuoso') a la hora de predecir muestras se puede achacar a la mayor proporción de muestras con defectos dentro del Corpus I. Esto afecta al entrenamiento y ajuste de los modelos.

El sistema de referencia, como resultado base, es altamente satisfactorio al superar el 95 % de precisión o tasa de acierto. Cabe destacar como los modelos de MLP y de SVM de núcleo RBF logran tasas de error cercanas al 3 %. La regresión logística y el resto de modelos de SVM logran precisiones similares al sistema de referencia.

En el Corpus II, la precisión no resulta ser una magnitud adecuada para estimar la calidad clasificadora de los modelos. La clara asimetría existente entre las clases del Corpus (tan solo tres imágenes con defectos por cada cien) resulta en una tasa de acierto muy significativa unicamente etiquetando todas las observaciones como imágenes carentes de defectos. Los clasificadores, antes este desequilibrio en la muestra de entrenamiento, tienen un claro sesgo ante la clase mayoritaria. La comparativa se deberá realizar, por lo tanto, empleando la sensibilidad o TPR.

El número de modelos que logran sobrepasar, en el proceso de validación cruzada, el 50 % de muestras con defectos bien clasificados es notoriamente bajo: todos los modelos que lo logran se basan en metodología de árboles de decisión y se detallan en la memoria de estadística [3]. En cuanto a los modelos desarrollados en esta memoria, parece destacar el MLP con el conjunto de variables B. Su resultado dista de ser adecuado como para considerar que el modelo es útil. Los modelos que logran una marca inferior carecen de forma más destacada de utilidad práctica.

Las Figuras 9.6 y 9.7 son representaciones de las medidas relativas a la capacidad discriminatoria (precisión, sensibilidad y especificidad) de los modelos de análisis supervisado desarrollados con los conjuntos de datos A y B extraídos del Corpus I y Corpus II. Cabe destacar como a pesar de la similitud de ambas Figuras, la diferencia de escala entre ambas es significativa.

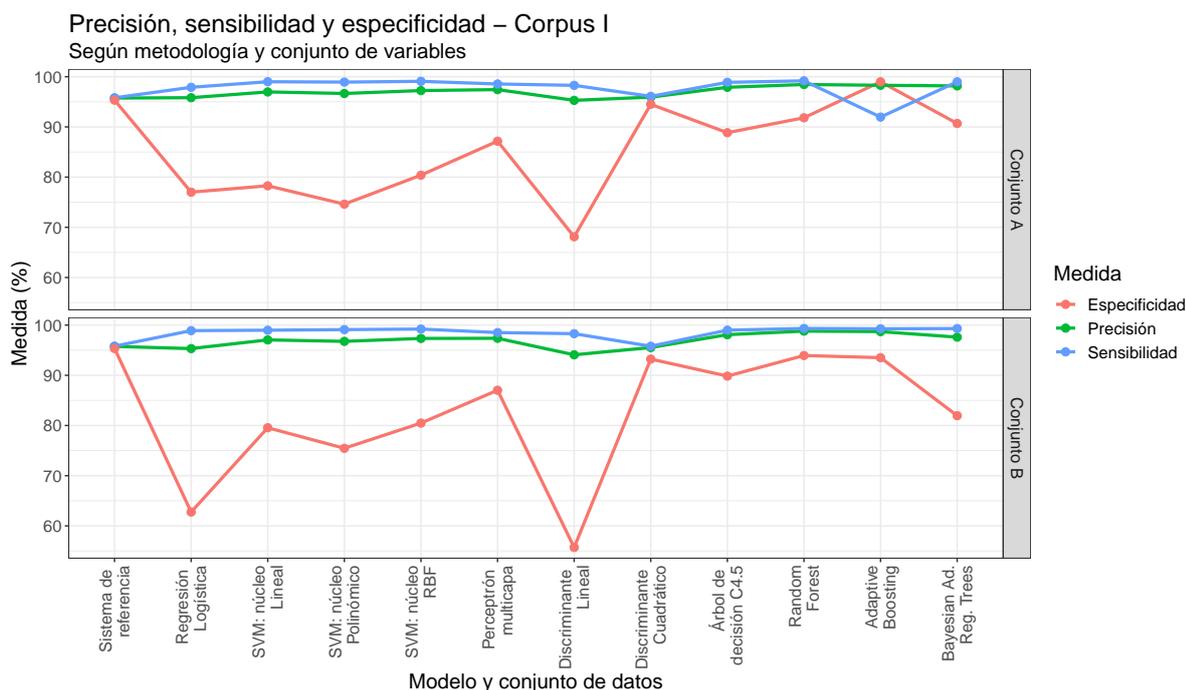


Figura 9.6: Precisión, TPR y TNR para cada uno de los conjuntos de datos del Corpus I y metodología empleada.

El Corpus I ha dado lugar a modelos con excelentes marcas en los que la especificidad parece ser la única medida algo más carente, especialmente en los modelos de regresión logística. El sistema de referencia destaca especialmente al superar el 90% en las tres tasas. Esto solo lo logran otros modelos desarrollados en la memoria de estadística.

La representación correspondiente al Corpus II sirve de evidencia para reflejar la baja tasa de verdaderos positivos de los modelos. Muchos modelos parecen no haber logrado alcanzar hipótesis que distingan claramente las imágenes con tableros defectuosos. Cuatro modelos desarrollados en la memoria de estadística son los únicos capaces de superar el 50% de observaciones con defectuosas correctamente clasificadas.

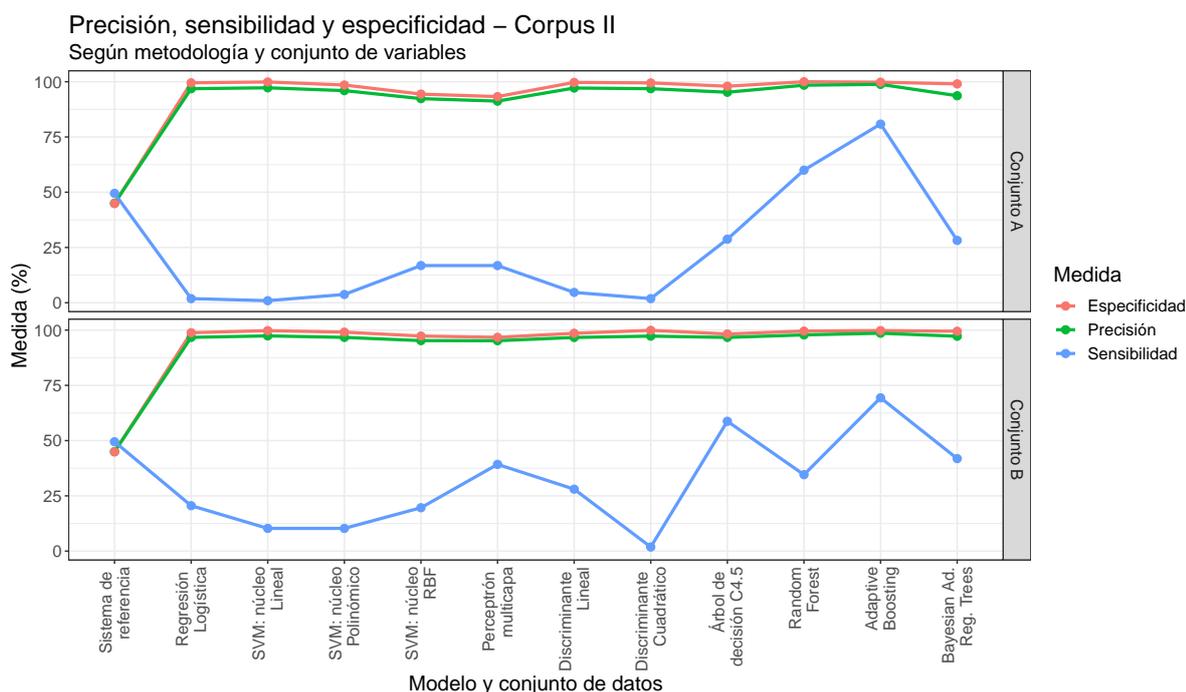


Figura 9.7: Precisión, TPR y TNR para cada uno de los conjuntos de datos del Corpus II y metodología empleada.

9.3. Discusión sobre modelos

En esta sección se ha hecho un Spider Plot o representación de malla del ranking que ocupa cada modelo con respecto al resto de los creados para ese Corpus. Las representaciones se han realizado de tal forma que cuanto mayor sea el área recogida por el modelo, mayor calidad tendrá este con respecto al resto. En los casos en los que se diese un empate, se ha asignado el ranking correspondiente a la posición máxima. Las cinco medidas elegidas para la representación han sido las siguientes:

- Número de variables. Se ha establecido un ranking decreciente: cuantos más atributos tenga el modelo, menor será el ranking del modelo. Cabe a destacar que esta medida será de menor relevancia por dos motivos:
 1. Muchos modelos emplean variables cuya medición requiere la extracción de la totalidad de las variables (como es el caso una componente avanzada de la DCT).
 2. Todos los modelos estudiados ofrecen una clasificación de nuevas muestras prácticamente instantánea.
- Precisión. Se ha establecido un ranking creciente: los modelos con mayor precisión tendrán mayor ranking.
- Área bajo la curva ROC. Se ha establecido un ranking creciente: a más AUC, mayor ranking.
- F-Score. Tal y como se explico en la sección de metodología, es la media armónica de la sensibilidad y especificidad. Se ha establecido un ranking creciente: los modelos con mayor F-Score tendrán mayor ranking.
- Tasa de equierror. Se ha establecido un ranking decreciente: cuanto más EER tenga el modelo, menor será el ranking del modelo.

9.3.1. Corpus I

En la Tabla 9.3 podemos observar el ranking, de mejor a peor, en cada uno de los criterios de los modelos desarrollados para el Corpus I ordenados por la calificación correspondiente al F-Score. Se ha escogido el F-Score para la ordenación al ser un criterio sin valores faltantes y sin empates.

Ranking general de los modelos estudiados (Corpus I)						
	Conjunto	F-Score	Precisión	AUC	EER	Nº Variables
Sistema de referencia	-	21	5	15	18	23
Perceptrón multicapa	Conjunto A	13	15	11	6	10
Perceptrón multicapa	Conjunto B	12	14	4	11	5
SVM de núcleo RBF	Conjunto B	10	13	15	16	5
SVM de núcleo RBF	Conjunto A	9	12	16	10	10
SVM de núcleo lineal	Conjunto B	8	11	-	-	16
SVM de núcleo lineal	Conjunto A	7	10	-	-	15
Regresión logística	Conjunto A	6	6	17	14	12
SVM de núcleo polinómico	Conjunto B	5	9	3	3	5
SVM de núcleo polinómico	Conjunto A	4	8	6	4	10
Regresión logística	Conjunto B	2	3	10	9	11

Tabla 9.3: Ranking de los criterios seleccionados (Número de variables, Precisión, AUC, F-Score y EER) para los modelos estudiados en el Corpus I desarrollados en la memoria de ingeniería informática.

En la Figura 9.8 aparece las representaciones de malla de los ranking del sistema de referencia y los modelos desarrollados en la memoria de ingeniería informática.

Podemos hacer los siguientes comentarios en base a la representación de malla de los modelos del Corpus I realizada:

- **Sistema de referencia:** en el Corpus I el sistema de referencia logra resultados bastante buenos: emplea el menor número posible de variables (una) y con ello consigue puntuaciones altas en todas las medidas a excepción de la precisión general del modelo.
- **Regresión logística:** el modelo creado a partir con el conjunto de variables B parece ser superior en todos los sentidos al del A. Los resultados son medios y no excesivamente destacables.

- **Support Vector Machines:** los SVM de núcleo lineal carecen de puntuación en tasa de equierror y área bajo la curva ROC al no haberse podido estimar estas medidas. Parecen lograr un compromiso adecuado entre el número de variables y la precisión o el F-Score. Los SVM de núcleo polinómico han dado lugar a un resultado que en comparativa con el resto es pobre. Aquellos cuyo núcleo es una función de base radial obtienen con los conjuntos de datos A y B resultados medios que destacan por su EER y su AUC respectivamente.
- **Perceptrón multicapa:** el modelo correspondiente al conjunto A parece destacar por encima del B exceptuando en la EER. Ambos parecen destacar de forma media en lo que se refiere a la precisión.

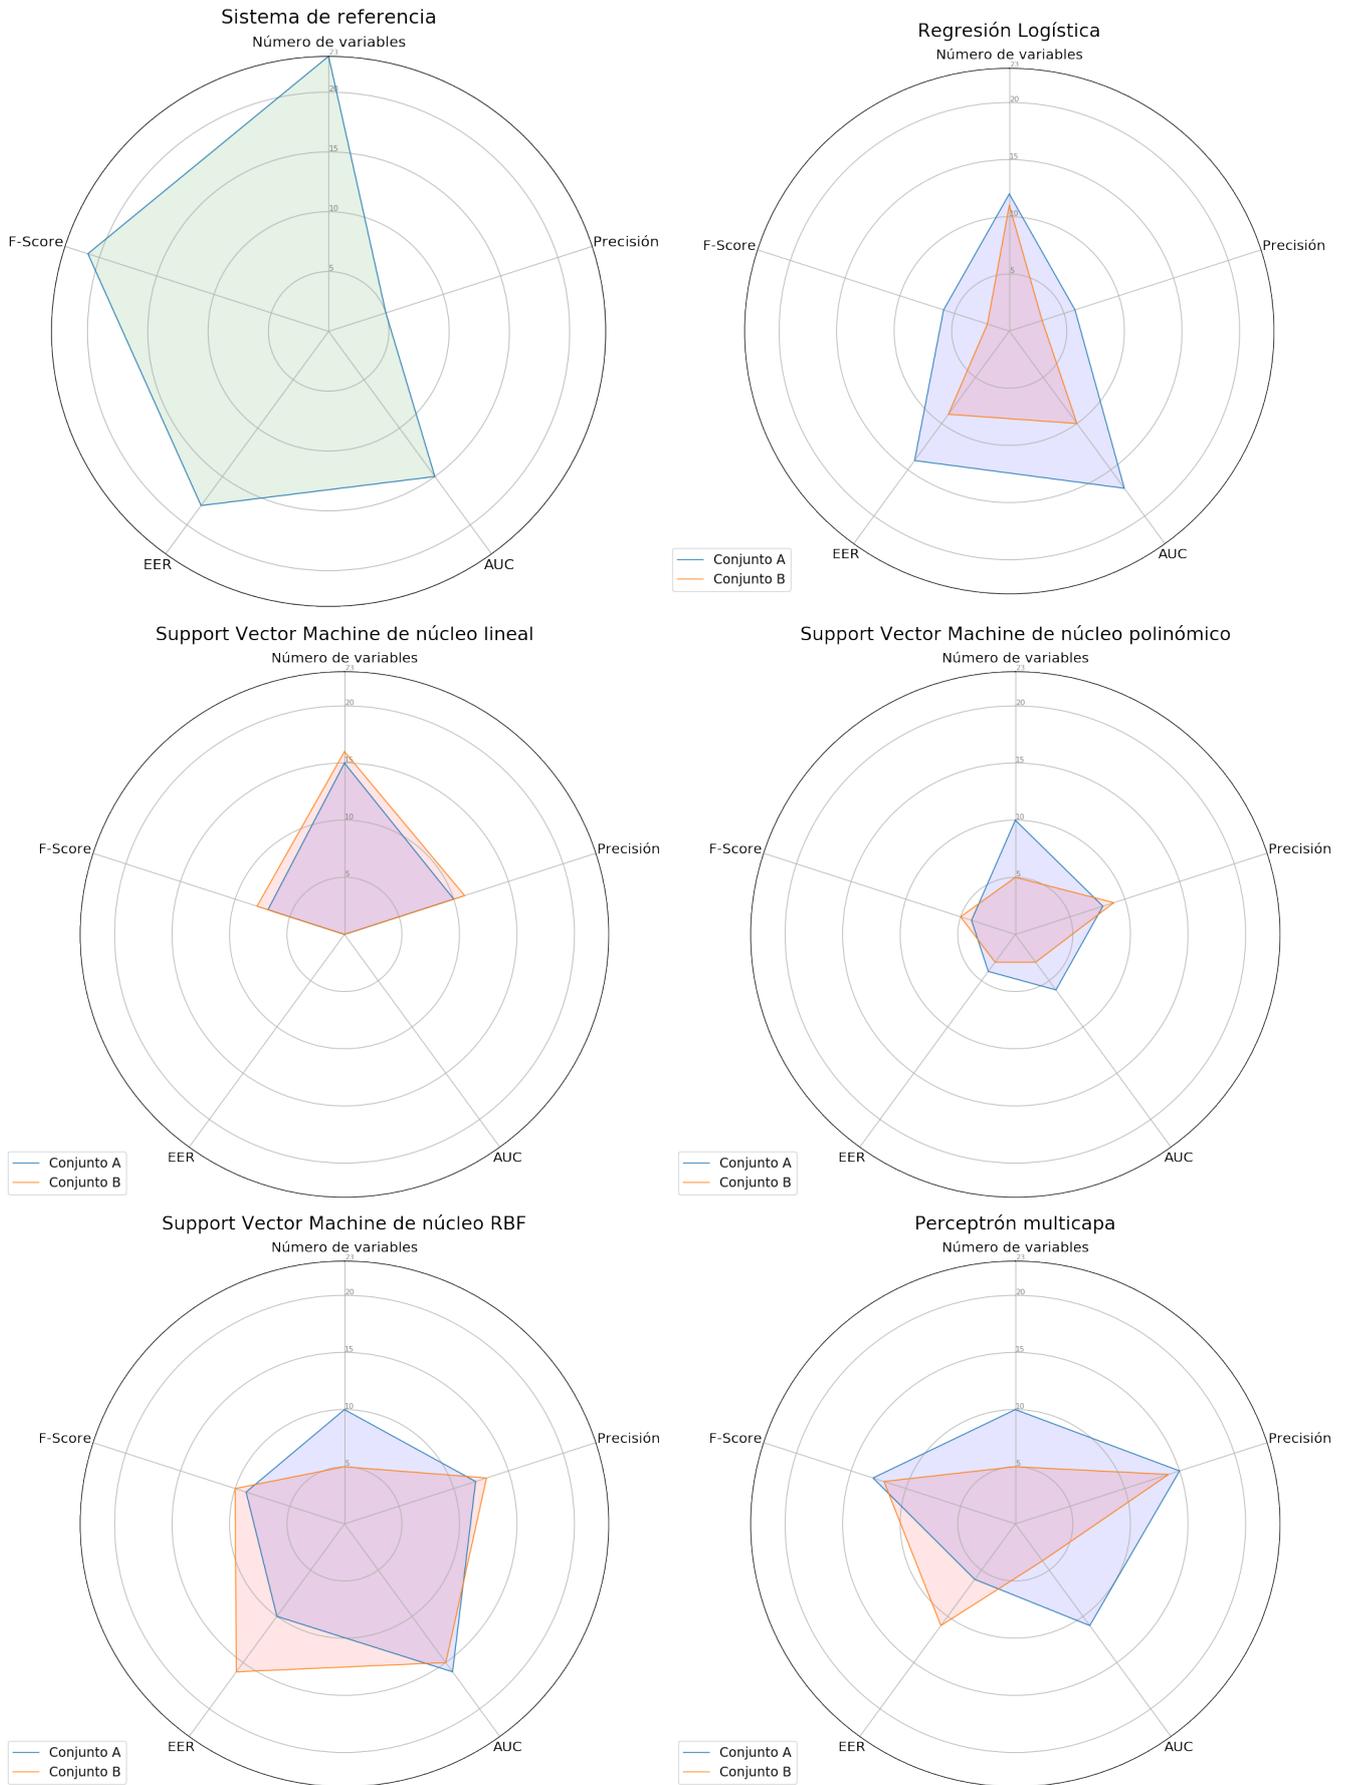


Figura 9.8: Representación gráfica del ranking en distintos criterios (Número de variables, Precisión, F-Score, EER y AUC) del sistema de referencia y los modelos desarrollados en la memoria de ingeniería informática a partir de los conjuntos de datos A y B del Corpus I.

9.3.2. Corpus II

En la Tabla 9.4 podemos observar el ranking, de mejor a peor, en cada uno de los criterios de los modelos desarrollados para el Corpus II ordenados por la calificación correspondiente al F-Score. De nuevo, la elección del F-Score como criterio de ordenación se debe a que no tiene valores faltantes ni empates.

Ranking general de los modelos estudiados (Corpus II)						
	Conjunto	F-Score	Precisión	AUC	EER	Nº Variables
Perceptrón multicapa	Conjunto B	18	5	15	15	5
Sistema de referencia	-	16	1	3	3	23
Regresión logística	Conjunto B	12	12	9	13	15
SVM de núcleo RBF	Conjunto B	11	7	15	12	5
SVM de núcleo RBF	Conjunto A	10	3	12	11	10
Perceptrón multicapa	Conjunto A	9	2	6	7	10
SVM de núcleo lineal	Conjunto B	8	19	-	-	11
SVM de núcleo polinómico	Conjunto B	7	11	4	4	5
SVM de núcleo polinómico	Conjunto A	5	8	5	5	10
Regresión logística	Conjunto A	3	14	10	8	13
SVM de núcleo lineal	Conjunto A	1	17	-	-	13

Tabla 9.4: Ranking de los criterios seleccionados (Número de variables, Precisión, AUC, F-Score y EER) para los modelos estudiados en el Corpus II desarrollados en la memoria de ingeniería informática.

En la Figura 9.9 aparecen las representaciones de malla de los ranking del sistema de referencia y los modelos desarrollados en la memoria de ingeniería informática. Al tener una resolución inferior las imágenes del Corpus II, las características se extraen de tal forma que tienen ruido y variaciones con respecto al Corpus I. Esto genera una disposición diferente de rankings que desarrollamos a continuación.

Podemos hacer los siguientes comentarios en base a la representación de malla de los modelos del Corpus II realizada:

- **Sistema de referencia:** en el Corpus II logra con una única variable medidas de precisión, EER y AUC bajas. Sin embargo, su F-Score -relevante ante la baja especificidad de los modelos de este Corpus- es relativamente elevado.
- **Regresión logística:** se obtienen modelos con puntuaciones medias, destacando el F-Score, EER y menor dimensionalidad del clasificador asociado al conjunto A y la precisión y AUC del modelo del conjunto B.
- **Support Vector Machines:** los Support Vector Machine de núcleo lineal carecen de puntuación en tasa de equierror y área bajo la curva ROC al no haberse podido estimar estas medidas. El modelo SVM de núcleo lineal del conjunto de variables de las componentes principales parece carecer de utilidad al tener un F-Score muy bajo (y por tanto una especificidad paupérrima). El conjunto B logra resultados pobres cuya única medida a destacar es la precisión. Los SVM de núcleo polinómico carecen de rasgos destacables al lograr puntuaciones bajas. En el caso de aquellos con núcleo de función de base radial, los resultados son medios. Parece que la única ventaja que ofrece el conjunto A con respecto al B es una reducción de dimensionalidad.
- **Perceptrón multicapa:** mientras que el conjunto A logra resultados pobres con menos variables, el conjunto de los estadísticos logra resultados medios-altos con un número de variables elevado teniendo en cuenta la pobreza general relativa en los resultados del Corpus II. Destaca el alto ranking del F-Score.

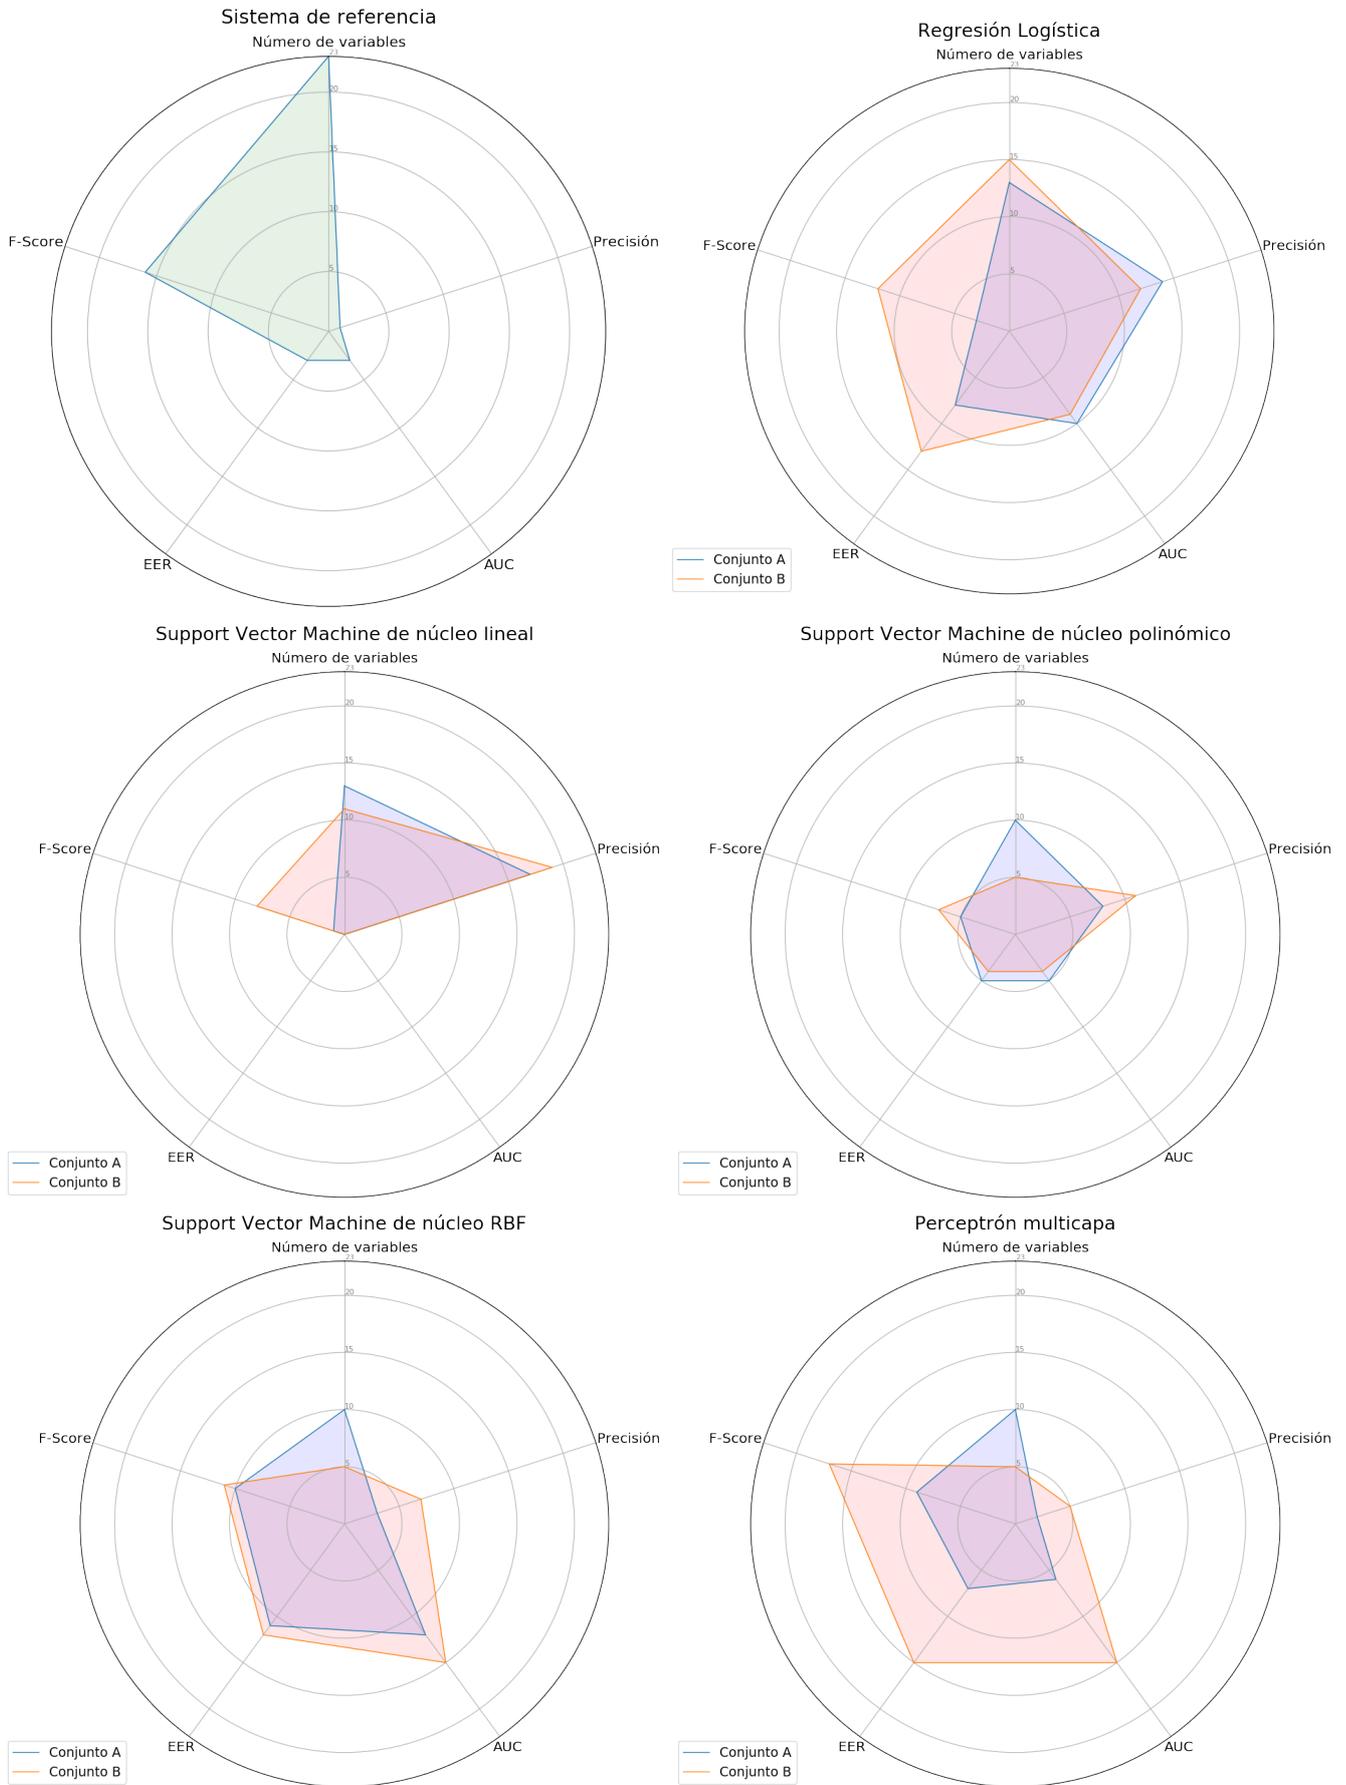


Figura 9.9: Representación gráfica del ranking en distintos criterios (Número de variables, Precisión, F-Score, EER y AUC) del sistema de referencia y los modelos desarrollados en la memoria de ingeniería informática a partir de los conjuntos de datos A y B del Corpus II.

9.4. Discusión de relevancia de las variables

En este apartado se hará una breve disquisición de la relevancia relativa de las variables que conforman cada uno de los subconjuntos de variables empleados para inducir los modelos. Esta discusión se hará en base a las variables seleccionadas para crear los modelos así como con las representaciones hechas de importancia de variables en los modelos que ha sido posible.

9.4.1. Variables relativas al filtrado

En la Tabla 9.5 podemos ver las variables que conforman este subgrupo de atributos.

Variables relativas al filtrado	
AreaErrorB	AreaErrorN

Tabla 9.5: Variables directamente relacionadas con el filtrado.

En el caso del Corpus I estas variables se usan en la inmensa mayoría de modelos, especialmente la relacionada con el filtrado de negros. En los modelos en que no se usa una de las dos, como ocurre en algunos modelos inducidos con el conjunto de datos B, se opta por características relativas a la distribución de grises como sustitutivas. En los modelos de mejores resultados parece que el área de error relativa del filtrado de negros tiene una influencia significativa.

El caso del Corpus II parece ser el antagónico: se usan mucho menos en los modelos en los que se seleccionan variables o tienen una relevancia por debajo de la media en los modelos con la totalidad de variables. Los modelos con mejores resultados no emplean estas variables o tienen una influencia muy baja. La menor resolución de las imágenes de este conjunto de datos hace que los filtrados den lugar a más ruido que deteriora la información útil proporcionada por estas variables.

9.4.2. Caracterizaciones de la distribución de grises

Componentes principales

En la Tabla 9.6 podemos ver las variables que conforman este subgrupo de atributos.

Distribución de grises: componentes principales				
- Img. original:	CompPrinOr1	CompPrinOr2	CompPrinOr3	CompPrinOr4
- Img. filtrada en blanco:	CompPrinTratB1	CompPrinTratB2		
- Img. filtrada en negro:	CompPrinTratN1	CompPrinTratN2		

Tabla 9.6: Atributos de componentes principales que caracterizan la distribución de grises.

En el Corpus I, son un conjunto de variables útiles para multitud de modelos. Se usan primordialmente las componentes extraídas de la imagen original, especialmente la 4 y 3. CompPrinTratN2 se usa en más modelos que CompPrinTratN1, aunque ninguna de las dos parece ser seleccionada en exceso o tener una importancia significativa. Esto se debe posiblemente a que la estimación de área de error en negro aporta una información similar. Las componentes extraídas de la imagen filtrada en blanco se usan en un subconjunto no muy numeroso de modelos.

En el caso del Corpus II, parece que se da mucho peso a las componentes extraídas de la imagen original. En la mayoría de modelos CompPrinTratN1 es relevante como posible sustitutivo al área de error por filtrado de negros (que no se selecciona mucho o se le da un peso poco importante) y CompPrinTratB2 parece aportar más información útil que CompPrinTratB1. Muchos modelos necesitan, aparte de estas variables, abundancia de atributos de información auxiliar (como las componentes de la DCT).

Estadísticos característicos

En la Tabla 9.7 podemos ver las variables que conforman este subgrupo de atributos. El uso de los estadísticos, en general, requiere de un número de variables más elevado que el uso de las componentes principales.

Distribución de grises: estadísticos característicos				
-Img. original:	MediaOr	VarianzaOr	SkewnessOr	KurtosisOr
	MedianaOr	P10Or	P90Or	
-Img. filtrada en blanco:	MediaTratadaB	VarianzaTratadaB	SkewnessTratadaB	KurtosisTratadaB
	MedianaTratadaB	P10TratadaB	P90TratadaB	
-Img. filtrada en negro:	MediaTratadaN	VarianzaTratadaN	SkewnessTratadaN	KurtosisTratadaN
	MedianaTratadaN	P10TratadaN	P90TratadaN	

Tabla 9.7: Atributos estadísticos que caracterizan la distribución de grises.

Destaca en absolutamente todos los modelos creados la KurtosisTratadaN, de forma indiferente a que estemos hablando de los modelos del Corpus I o II. Es una variable que parece tener un papel fundamental en los modelos de ambos Corpus que logran los mejores resultados.

En el Corpus I se puede destacar que se usan mucho las otras dos variables de la kurtosis (KurtosisOr y KurtosisTratadaB) y las variables del grupo apuntamiento o skewness. Otras variables muy utilizadas que son de relevancia o han sido seleccionadas en los modelos de mejores resultados son la MediaOr, SkewnessTratadaN y VarianzaTratadaN. La MedianaTratadaB es el atributo más usado extraído a partir de la imagen tratada en blanco. Sin embargo, la mayoría de atributos extraídos de esta imagen o no se seleccionan en los procedimientos de selección de variables, o no se les otorga importancia dentro del algoritmo. Un posible motivo puede ser la relativa escasez de muestras de defecto blanco.

Con el Corpus II desatacamos de nuevo el frecuente uso de las variables de apuntamiento y kurtosis proveniente de cualquiera de las imágenes de las que se han extraído las características. Estas se usan en muchos modelos, incluyendo aquellos que se han alzado con los mejores resultados. Otros atributos seleccionados en múltiples ocasiones son la MediaOr y MedianaOr. Variables extraídas de la imagen filtrada para la detección de defectos blancos como la VarianzaTratadaB se emplean en modelos de resultados altamente satisfactorios. Muchos modelos necesitan, aparte de estas variables, abundancia de atributos de información auxiliar (como componentes de la DCT).

9.4.3. Componentes extraídas de la DCT

En la Tabla 9.8 podemos ver las variables que conforman este subgrupo de atributos.

Componentes extraídas de la DCT	
Img. filtrada sin binarizar:	Componentes de la 1 a la 30 extraídas.
Img. filtrada binarizada:	Componentes de la 1 a la 30 extraídas.

Tabla 9.8: Componentes de la DCT extraídas de la imagen tratada binarizada y sin binarizar.

En los modelos inducidos con los datos del Corpus I, las componentes de la DCT parecen aportar información relevante que supone una adición a las aportaciones principales de los estadísticos, las componentes principales y las áreas de error relativas. Se seleccionan por igual componentes de la imagen procesada binarizada como de la imagen sin binarizar.

En el Corpus II, los modelos tienen una dependencia muy fuerte de las componentes DCT de la imagen tratada sin binarizar. Esto se manifiesta de forma más aguda en los modelos inducidos con el conjunto de variables B. Las componentes DCT extraídas de la imagen binarizada se emplean mucho menos y de forma más aislada no dándose a estas un peso de relevancia en casi ninguno de los modelos de análisis supervisado.

9.5. Conclusiones

Parece que las métricas más útiles para la comparación de modelos son la tasa de equierror, el área bajo la curva ROC y la sensibilidad y especificidad (o F-Score). La precisión, debido al desbalance existente entre clases de los conjuntos de datos, no nos permite aclarar de forma precisa la calidad del clasificador, especialmente en el Corpus II.

En cuanto a modelos, los mejores resultados se han obtenido a partir de los modelos de árboles de clasificación o en los que se han agregado diversos árboles mediante Bagging o Boosting. Estos modelos aparecen desarrollados en la memoria correspondiente al grado en Estadística [3].

Todos los modelos estudiados tienen un tiempo de cómputo para predecir una nueva observación prácticamente instantáneo, por lo que mantienen el que el control de las imágenes tomadas de tableros se pueda hacer en tiempo real.

La diferencia existente entre usar un modelo con un número menor de variables puede ser poco significativa: se ahorraría tan solo el tiempo proporcional a reducir el procesamiento de la entrada del clasificador y, como ya hemos comentado, no parece ser de una magnitud considerable. Acortar el tiempo para extraer las características necesarias de las imágenes podría ahorrar unidades de tiempo en lo que sería la predicción de una nueva observación. Sin embargo, el procesamiento de la imagen se tendría que hacer al completo: los modelos de baja dimensionalidad que han dado buenos resultados necesitan de componentes altas de la DCT, y por ello necesitan extraer los elementos anteriores, o caracterizaciones de la distribución de grises de la imagen tratada en negro o blanco. Esto hace que el número de variables del modelo no sea tan relevante.

En cuanto a lo que se refiere a variables, podemos destacar que nuestro filtrado de negros da lugar a una buena estimación del área de error de defectos negros que sirve como una entrada de utilidad a los clasificadores. La estimación del área de blancos no es tan precisa y necesita de variables características de la distribución de grises de la imagen procesada en blancos, ya sea con componentes principales o estadísticos. La kurtosis de la imagen procesada en negros destaca por encima de todas las variables en muchos modelos, por lo que posiblemente sea la variable con mayor poder discriminatorio de las estudiadas. Las variables DCT parecen aportar información complementaria útil para los clasificadores. Si estos dependiesen de las variables DCT únicamente, el número de estas necesarias para dar lugar a un buen clasificador sería elevado.

Capítulo 10

Conclusiones y trabajo futuro

En este capítulo se van a exponer las conclusiones que se han podido obtener con la finalización del proyecto.

Se desarrollará la relación del proyecto con los contenidos impartidos en asignaturas del grado y la consecución de los objetivos planteados con el comienzo del trabajo de fin de grado. Por último se propondrán posibles líneas de trabajo futuras para desarrollar el trabajo realizado en el desarrollo del proyecto.

10.1. Relación con los contenidos del grado

El proyecto ha permitido emplear conocimientos desarrollados en asignaturas del grado. A continuación se desarrollará un listado de las asignaturas cuyos contenidos están más relacionados con la evolución del proyecto.

Las asignaturas propias de análisis y minería de datos ('Técnicas de Aprendizaje Automático' y 'Minería de Datos') han aportado los conocimientos básicos necesarios para el desarrollo del proyecto. La formación adquirida en 'Fundamentos de Inteligencia Artificial' será siempre necesaria en cualquier aplicación relacionada con la materia.

La asignatura 'Diseño y Evaluación de Sistemas Interactivos' aportó conocimientos fundamentales para hacer que un gráfico o visualización sea legible y transmita de forma clara el objetivo de la misma. Las nociones adquiridas del lenguaje de programación Python en 'Paradigmas de Programación' han resultado ser fundamentales en la creación del código para la inducción de los clasificadores. 'Planificación y diseño de Sistemas Computacionales' ha servido para establecer una planificación temporal adecuada. La implicación de una empresa en el proyecto hace útiles los conocimientos adquiridos en 'Profesión y Sociedad' y en las propias 'Prácticas en Empresa'.

10.2. Objetivos alcanzados

Los objetivos planteados al comienzo del proyecto se han completado con éxito con el desarrollo del mismo. El grado de desarrollo de cada uno de los objetivos ha sido el siguiente:

- Se han obtenido con éxito dos Corpus de imágenes necesarios para realizar el estudio adecuado del problema. El Corpus I cuenta con muchas imágenes con defectos y algunas sin ellos grabadas en una resolución alta. El Corpus II consta de un conjunto de imágenes de baja resolución compuesta por muchas imágenes sin defectos y pocas defectuosas.
- El desarrollo se ha realizado siguiendo las pautas establecidas en la planificación temporal. El retraso de la entrega del Corpus II supuso aplazar alguna de las tareas. El resto del proyecto se continuó de forma adecuada a las especificaciones hechas exceptuando ligeras diferencias entre el tiempo estimado y el dedicado.
- La clasificación de las imágenes de los Corpus se ha realizado adecuadamente mediante visualización en las diversas clases de defectos (negro, blanco y topográfico -relieves defectuosos en negro y blanco-). Para asegurar que la clasificación se había hecho correctamente, se contrastó con un grupo de expertos de la empresa. Este punto posiblemente haya sido la parte del proyecto más dura, ya que requirió de la observación individual de cada imagen de los Corpus. Esto llevo aproximadamente 80 horas entre el Corpus I y el II.

- Los datos se depuraron de tal forma que las imágenes que había captado incorrectamente “Smart Eyes” no se emplearon en la inducción de los sistemas de clasificación. Posteriormente, las imágenes se analizaron para conocer cuales eran las propiedades más relevantes de estas que pudiesen tener relevancia en el posterior filtrado de la imagen y en la extracción de características.
- Se realizó un análisis del funcionamiento de “Smart Eyes”. Se pudo realizar una estimación muy sesgada de su tasa de error y con el estudio visual se analizó la posible fuente de este error. El sistema tiene un comportamiento errático en escenarios donde el tablero o está muy iluminado o carece de suficiente luz.
- Se ha desarrollado un sistema propio de filtrado en base a la irregularidad en la iluminación existente en las imágenes. El sistema de filtrado consta de un procedimiento para la detección de relieves propios de defectos negros y otro para la detección de relieves de defectos blancos. El sistema de filtrado se ha optimizado por separado para ambos Corpus para tener en cuenta las diferencias existentes entre ambos.
- A partir de las diferentes imágenes usadas en el proceso de filtrado se han extraído diversas características: relativas al procesamiento (áreas de error relativas), componentes de la transformada discreta del coseno y caracterizaciones de la distribución de grises de las imágenes. Sobre este último grupo de variables se ha podido hacer un estudio de las ventajas y desventajas que ofrecía caracterizar el histograma de grises mediante componentes principales o con estadísticos.
- Se han ajustado correctamente modelos de análisis supervisado de regresión logística, Support Vector Machines y perceptrón multicapa. Sobre los primeros se ha estudiado el efecto de la regularización L1 como forma de selección de variables. Con los SVM se ha variado el núcleo, los parámetros relativos a estos y el coste para obtener clasificadores con resultados asociados óptimos. En el caso del perceptrón multicapa, el estudio se ha hecho en base a la variación de la arquitectura, activación de las neuronas y los parámetros relativos a la regularización.
- Posteriormente se ha realizado una discusión sobre los resultados obtenidos a partir de los clasificadores desarrollados en ambas memorias. Se ha valorado qué modelos de los desarrollados podría ser el óptimo para el problema planteado en función de los resultados obtenidos. Adicionalmente, se ha estudiado la relevancia de las variables dentro del proceso discriminatorio de los clasificadores. Esta sección ha resultado ser la más gratificante ya que a través del estudio y comparación de resultados se han podido conocer las ventajas y desventajas de cada una de las metodologías empleadas.
- Con el desarrollo del proyecto se han podido crear modelos de análisis supervisado de agregación de árboles de decisión capaces de discriminar con alta precisión entre imágenes con defectos de las que carecen de ellos. Los modelos de Random Forest y AdaBoost logran resultados altamente satisfactorios en las diferentes medidas relativas a su calidad como clasificadores.
Aquellos creados a partir del conjunto de variables caracterizado por el uso de estadísticos combinan estos con la información extraída de la DCT. Destacan por encima del resto de variables la Kurtosis de la imagen tratada en negro, dato que concuerda con la relación existente entre esta medida y el número de puntos extraños en una distribución. Por otro lado, aquellos inducidos con el conjunto de datos de las componentes principales parecen marcar como relevantes estas componentes. Aquellas extraídas a partir de la transformada discreta del coseno (DCT) aportan información de utilidad pero complementaria en comparación con componentes principales en estos modelos.

10.3. Trabajo Futuro

Como trabajo futuro, se pueden proponer diversidad de líneas para la continuación del proyecto:

- La obtención de imágenes de falsos negativos supondría un aporte de alto valor al posible futuro desarrollo del estudio realizado. De esta forma, podríamos precisar nuestra estimación sobre la tasa de acierto de ‘Smart Eyes’ así como conocer si los nuevos modelos que hemos desarrollado son capaces de detectar correctamente aquellas imágenes con defectos que ‘Smart Eyes’ no clasifico adecuadamente.

- Si la empresa nos facilitase otro conjunto de datos, podríamos utilizarlo como conjunto test y de esta forma hacer una estimación más precisa de las medidas de capacidad discriminatoria de los modelos desarrollados. Otra forma de conocer si los mejores modelos funcionan adecuadamente sería ponerles en funcionamiento en la línea de la empresa para observar si realmente mejoran el rendimiento asociado a ‘Smart Eyes’.
- Se podría continuar trabajando con los conjuntos de imágenes ya obtenidos de la empresa y probar clasificadores más complejos como serían las redes convolucionales [34] en las que la imagen filtrada se podría introducir sin la extracción de características en el clasificador.
- Con los resultados obtenidos, existe evidencia que apoya que si se mejorasen los equipos de visión artificial se podría obtener un sistema altamente fiable. Las tasas de error de este proyecto han sido muy bajas empleando imágenes en escala de grises grabadas por cámaras lineales. Estas cámaras las compro la empresa hace más de cinco años y, por aquel entonces, ya estaban algo obsoletas. Parece evidente que si la empresa adquiriese cámaras industriales de última generación se podría alcanzar el 100 % de imágenes bien clasificadas.

Bibliografía

- [1] Sonae Arauco. *Sonae Industria - About Us*. 2018. Último acceso: 04-02-2018. URL: <http://www.sonaeindustria.com/page.php?ctx=1,0,17>.
- [2] Synergic Partners. *Ganadores de Data Sciences Awards 2016*. 2016. Último acceso: 04-02-2018. URL: <http://www.synergicpartners.com/synergic-partners-y-telefonica-anuncian-los-premiados-de-los-dsawards/>.
- [3] Alejandro Rodríguez Collado y Miguel Alejandro Fernández Temprano. *Detección de defectos en tiempo real en una línea de fabricación de tableros mediante métodos multivariantes de clasificación*. Departamento de Estadística e Investigación Operativa, Facultad de Ciencias. Universidad de Valladolid, 2019.
- [4] Mathworks. *Complement Image*. 2017. Último acceso: 04-02-2018. URL: <https://es.mathworks.com/help/images/ref/imcomplement.html>.
- [5] Mathworks. *Crop Image*. 2017. Último acceso: 31-01-2018. URL: <https://es.mathworks.com/help/images/ref/imcrop.html>.
- [6] Mathworks. *Correct Nonuniform Background Illumination and Analyze Foreground Objects*. 2017. Último acceso: 31-01-2018. URL: <https://es.mathworks.com/help/images/image-enhancement-and-analysis.html>.
- [7] A. Agresti. *Categorical Data Analysis*. Wiley Series in Probability and Statistics. Wiley, 2003. ISBN: 9780471458760. URL: <https://books.google.es/books?id=hpEzw4T0sPUC>.
- [8] Luis Ángel García y Miguel Alejandro Fernández. *Apuntes de la asignatura "Análisis de Datos"*. Departamento de Estadística e Investigación Operativa, Facultad de Ciencias. Universidad de Valladolid, 2016.
- [9] T.A. Banet, T. Aluja y A. Morineau. *Aprender de los datos: el análisis de componentes principales : una aproximación desde el Data Mining*. Ciencia y tecnología. EUB, 1999. ISBN: 9788483120224. URL: <https://books.google.es/books?id=6p7mPQAACAAJ>.
- [10] Gilbert Strang. "The Discrete Cosine Transform". En: *SIAM Rev.* 41.1 (mar. de 1999), págs. 135-147. ISSN: 0036-1445. DOI: 10.1137/S0036144598336745. URL: <http://dx.doi.org/10.1137/S0036144598336745>.
- [11] Xiph.Org Foundation. *Strengths and Weaknesses of the DCT*. 2018. Último acceso: 05-09-2018. URL: <https://people.xiph.org/~xiphmont/demo/daala/demo1.shtml>.
- [12] Nuno Vasconcelos University of California San Diego. *Discrete Cosine Transform*. 2016. Último acceso: 23-11-2018. URL: <http://www.svcl.ucsd.edu/courses/ece161c/handouts/DCT.pdf>.
- [13] Teodoro Calonge Cano y Carlos J. Alonso González. *Apuntes de la asignatura "Técnicas de Aprendizaje Automático"*. Departamento de Informática, Escuela de Ingeniería Informática. Universidad de Valladolid, 2018.
- [14] Teodoro Calonge Cano y Carlos J. Alonso González. *Apuntes de la asignatura "Minería de Datos"*. Departamento de Informática, Escuela de Ingeniería Informática. Universidad de Valladolid, 2018.
- [15] Viv Bewick, Liz Cheek y Jonathan Ball. "Statistics review 13: receiver operating characteristic curves". En: *Critical care (London, England)* 8.6 (2004), 508—512. ISSN: 1364-8535. DOI: 10.1186/cc3000. URL: <http://europepmc.org/articles/PMC1065080>.
- [16] Suzanne Ekelund AcuteCareTesting. *ROC curves - what are they and how are they used?* 2011. Último acceso: 23-11-2018. URL: <https://acutecaretesting.org/en/articles/roc-curves-what-are-they-and-how-are-they-used>.

- [17] Luis Ángel García y Miguel Alejandro Fernández. *Apuntes de la asignatura "Análisis de Datos Multivariantes"*. Departamento de Estadística e Investigación Operativa, Facultad de Ciencias. Universidad de Valladolid, 2017.
- [18] Nathan Brixius. *The Logit and Sigmoid Functions- Nathan Brixius: Data science, optimization, analytics, sports*. 2016. Último acceso: 06-08-2018. URL: <https://nathanbrixius.wordpress.com/2016/06/04/functions-i-have-known-logit-and-sigmoid/>.
- [19] KDnuggets. *Learn Generalized Linear Models (GLM) using R*. 2017. Último acceso: 06-08-2018. URL: <https://www.kdnuggets.com/2017/10/learn-generalized-linear-models-glm-r.html/2>.
- [20] Thomas Mazzocco y Amir Hussain. "Novel logistic regression models to aid the diagnosis of dementia". En: *Expert Systems with Applications* 39.3 (2012), págs. 3356 -3361. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2011.09.023>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417411013327>.
- [21] Sami Ben Jabeur. "Bankruptcy prediction using Partial Least Squares Logistic Regression". En: *Journal of Retailing and Consumer Services* 36 (2017), págs. 197 -202. ISSN: 0969-6989. DOI: <https://doi.org/10.1016/j.jretconser.2017.02.005>. URL: <http://www.sciencedirect.com/science/article/pii/S0969698916305434>.
- [22] Cross Validated. *Why L1 norm for sparse models*. 2018. Último acceso: 13-08-2018. URL: <https://stats.stackexchange.com/questions/45643/why-l1-norm-for-sparse-models>.
- [23] David Cournapeau. *Scikit-learn*. 2018. Último acceso: 20-06-2018. URL: <http://scikit-learn.org/stable/>.
- [24] Cross Validated. *How does a Support Vector Machine (SVM) work?* 2013. Último acceso: 07-08-2018. URL: <https://stats.stackexchange.com/questions/23391/how-does-a-support-vector-machine-svm-work/58216>.
- [25] Kunlun Li y col. "Multi-class text categorization based on LDA and SVM". En: *Procedia Engineering* 15 (2011). CEIS 2011, págs. 1963 -1967. ISSN: 1877-7058. DOI: <https://doi.org/10.1016/j.proeng.2011.08.366>. URL: <http://www.sciencedirect.com/science/article/pii/S1877705811018674>.
- [26] Fotini Simistira, Vassilis Katsouros y George Carayannis. "Recognition of online handwritten mathematical formulas using probabilistic SVMs and stochastic context free grammars". En: *Pattern Recognition Letters* 53 (2015), págs. 85 -92. ISSN: 0167-8655. DOI: <https://doi.org/10.1016/j.patrec.2014.11.015>. URL: <http://www.sciencedirect.com/science/article/pii/S0167865514003651>.
- [27] Zbigniew Krajewski y Ewaryst Tkacz. "Protein structural classification based on pseudo amino acid composition using SVM classifier". En: *Biocybernetics and Biomedical Engineering* 33.2 (2013), págs. 77 -87. ISSN: 0208-5216. DOI: <https://doi.org/10.1016/j.bbe.2013.03.002>. URL: <http://www.sciencedirect.com/science/article/pii/S020852161300003X>.
- [28] Cross Validated. *Do all machine learning algorithms separate data linearly?* 2016. Último acceso: 13-08-2018. URL: <https://stats.stackexchange.com/questions/215696/do-all-machine-learning-algorithms-separate-data-linearly?noredirect=1>.
- [29] Stack Overflow. *Single neuron in neural network using C++*. 2016. Último acceso: 17-08-2018. URL: <https://stackoverflow.com/questions/38850538/single-neuron-in-neural-network-using-c>.
- [30] Rafał Weron. "Electricity price forecasting: A review of the state-of-the-art with a look into the future". En: *International Journal of Forecasting* 30.4 (2014), págs. 1030 -1081. ISSN: 0169-2070. DOI: <https://doi.org/10.1016/j.ijforecast.2014.08.008>. URL: <http://www.sciencedirect.com/science/article/pii/S0169207014001083>.
- [31] Wen-Yuan Chen, Sin-Horng Chen y Cheng-Jung Lin. "A speech recognition method based on the sequential multi-layer perceptrons". En: *Neural Networks* 9.4 (1996), págs. 655 -669. ISSN: 0893-6080. DOI: [https://doi.org/10.1016/0893-6080\(95\)00140-9](https://doi.org/10.1016/0893-6080(95)00140-9). URL: <http://www.sciencedirect.com/science/article/pii/0893608095001409>.

- [32] I. Kanellopoulos y col. “Classification of remotely-sensed satellite images using Multi-layer Perceptron Networks”. En: *Artificial Neural Networks*. Ed. por Teuvo KOHONEN y col. Amsterdam: North-Holland, 1991, págs. 1067-1070. ISBN: 978-0-444-89178-5. DOI: <https://doi.org/10.1016/B978-0-444-89178-5.50020-8>. URL: <http://www.sciencedirect.com/science/article/pii/B9780444891785500208>.
- [33] Oli Blum. *How to visualize a neural network?* 2016. Último acceso: 17-08-2018. URL: <https://stackoverflow.com/questions/29888233/how-to-visualize-a-neural-network>.
- [34] Keiron O’Shea y Ryan Nash. “An Introduction to Convolutional Neural Networks”. En: *CoRR* abs/1511.08458 (2015). arXiv: 1511.08458. URL: <http://arxiv.org/abs/1511.08458>.