

UNIVERSIDAD AUTONOMA DE MADRID

ESCUELA POLITÉCNICA SUPERIOR



PROYECTO FIN DE CARRERA  
Ingeniería de Telecomunicación

CLASIFICADOR DE ATRIBUTOS FACIALES A PARTIR  
DE IMÁGENES EN ENTORNOS NO CONTROLADOS

ALEJANDRO HIDALGO FERNÁNDEZ-CAVADA

JUNIO 2016



# Clasificador de Atributos Faciales a partir de imágenes en entornos no controlados

AUTOR: Alejandro Hidalgo Fernández-Cavada

TUTOR: Rubén Vera Rodríguez



ATVS Grupo de Reconocimiento Biométrico

Dpto. de Tecnología Electrónica y de las Comunicaciones

Escuela Politécnica Superior Universidad Autónoma de  
Madrid

JUNIO 2016



# Resumen

En el presente proyecto fin de carrera se estudian, desarrollan y evalúan clasificadores de atributos faciales extraídos a partir de imágenes en entornos no controlados de iluminación y pose. Se partirá de las imágenes etiquetadas en la base de datos Facetracer, que contiene multitud de imágenes de rostros y etiquetados manuales.

Como punto de partida se ha estudiado el estado del arte en los sistemas de reconocimiento facial tradicionales así como otros trabajos que se adentran en la clasificación de atributos. A continuación se ha diseñado y analizado la extracción de una multitud de características faciales. Se estudiará así mismo la aplicación de análisis reductores de dimensionalidad de las características. Posteriormente se discutirán varias formas de construir clasificadores de atributos a partir de las características obtenidas previamente. Finalmente se discutirá como desplegar un sistema capaz de clasificar sobre una multitud de atributos faciales.

La parte experimental consiste por tanto de tres fases. En la primera se pretende evaluar cada elección de características mediante la construcción y evaluación de clasificadores locales construidos a partir de cada una de ellas.

En la segunda, se evaluarán varios métodos propuestos para construir clasificadores para cada atributo bajo estudio a partir de las características obtenidas de la fase anterior. A partir de estos resultados, se definirá la construcción de cada clasificador de atributos.

En la tercera, se desarrollará un sistema que integrará todos los clasificadores de atributos obtenidos y que permitirá la clasificación automática de cualquier imagen de entrada sobre un rango amplio de atributos faciales.

Por último se presentan las conclusiones extraídas a lo largo del proyecto y se proponen líneas de trabajo futuro.

## Palabras Clave

Reconocimiento facial, visión artificial, aprendizaje automático, clasificador de atributos, características faciales.

# Abstract

This final project pretends to study, develop and evaluate multiple automatic attribute classifiers, extracted from labeled face images in uncontrolled environments regarding light and pose. The results of this document are extracted from the images contained in the Facetracer database.

As a starting point, the current state of the art regarding facial recognition techniques and automatic attribute classification are studied and discussed, followed by an analysis of the features that are to be used in the classification. Methods of reducing the size of features will also be studied. Various methods of constructing each classifier will be discussed in order to produce a system capable of classifying any given face image over a variety of facial attributes.

The experimental phase will therefore consist of three main stages. In the first stage, classifiers will be constructed from each of the possible features discussed in this project in order to evaluate the discriminating value of each of the proposed features. In the second stage, various methods of constructing classifiers will be discussed following the results in the previous stage. The final stage will be dedicated to the construction of a system capable of classifying each proposed facial attribute.

Finally, conclusions extracted throughout the development of this project are presented and future lines of work are proposed.

## Key Words

Facial recognition, computer vision, machine learning, attribute classifiers, facial features.

# Agradecimientos

Ha sido un camino largo y lleno de retos. Soy afortunado porque no será fácil olvidar los muchos apoyos recibidos a lo largo de estos años.

A mis padres, por haber sabido siempre darme el consejo y motivación que necesitaba. A mi hermano, porque tú también me enseñas a mí. A toda mi familia, porque sois la mía y no querría otra.

A todos los investigadores del ATVS, por haberme acogido desde el principio. En especial a Javier Ortega por haber sabido orientar mi curiosidad y energías académicas, y también a Rubén Vera, por haber sido un tutor excepcional que no se ha dado por vencido.

También me gustaría agradecer a mis compañeros profesionales de Accenture Digital por haber confiado en mí.

Y por último a los que ya no están, porque me hicisteis ser fuerte.

# INDICE DE CONTENIDOS

1. Introducción.....	1
1.1 Motivación.....	1
1.2 Objetivos y Enfoque .....	2
1.3 Organización de la memoria.....	3
2 Estado del arte .....	5
2.1 Introducción.....	5
2.2 Sistemas de Reconocimiento Facial Forense.....	5
2.3 Clasificación de Atributos.....	6
3 Diseño del Clasificador de Atributos.....	7
3.1 Introducción.....	7
3.1.1 Fases Propuestas .....	7
3.1.2 Base de Datos Facetracer.....	9
3.2 Selección de Características Locales.....	10
3.2.1 Pre-Procesado: Normalización de Escala y Pose .....	10
3.2.2 Regiones Faciales.....	12
3.2.2.1 Regiones Elípticas .....	13
3.2.2.2 Regiones Compuestas .....	13
3.2.2.3 Regiones Rectangulares.....	14
3.2.3 Valores de Pixel.....	15
3.2.3.1 RGB {R}.....	15
3.2.3.2 HSV {H}.....	15
3.2.3.3 Escala de Grises {i} .....	16
3.2.3.4 Detección de Bordos: Magnitud {M} y Orientación {O} ..	16
3.2.4 Normalización.....	17
3.2.4.1 Normalización de Media {M} y de Energía {e} .....	17
3.2.4.2 Sin Normalización .....	18
3.2.5 Agregaciones.....	18
3.2.5.1 Histograma {H}.....	18
3.2.5.2 Sin Agregación {n} .....	18
3.3 Reducción de Dimensionalidad .....	19
3.3.1 Principal Component Analysis .....	19
3.4 Clasificadores Locales.....	20
3.4.1 Support Vector Machines.....	20
3.4.2 Validación Cruzada .....	21
3.4.3 Búsqueda por Cuadrados .....	22
3.4.4 Selección 5 Mejores Clasificadores Locales .....	24
3.5 Elección del Clasificador Global .....	24
3.5.1 Ponderación de Clasificadores Locales .....	25

3.5.2 Fusión de Características .....	26
3.5.3 Mejor Clasificador Local.....	27
4 Trabajo Experimental .....	28
4.1 Clasificadores Locales .....	28
4.2 Resultados de los Clasificadores Locales .....	33
4.3 Clasificadores Globales.....	36
4.4 Resultados de los Clasificadores Globales .....	37
4.5 Implementación del Clasificador de Atributos .....	40
5 Conclusiones y trabajo futuro .....	42
5.1 Conclusiones.....	42
5.2 Trabajo futuro.....	42
Referencias.....	45
APENDICE.....	I
A    Resultados Ampliados de los Clasificadores Locales.....	I
B    Resultados ampliados Clasificadores Globales.....	IX

## INDICE DE FIGURAS

FIGURA 1: ESQUEMA DEL PROCEDIMIENTO PARA LA SELECCIÓN DE CARACTERÍSTICAS LOCALES.....	8
FIGURA 2: ESQUEMA DEL PROCEDIMIENTO PARA LA SELECCIÓN DE CARACTERÍSTICAS LOCALES.....	8
FIGURA 3: COORDENADAS DE LAS REGIONES OCULARES PROVISTAS EN LA BASE DE DATOS DE FACETRACER.....	10
FIGURA 4: ILUSTRACIÓN DEL PREPROCESADO PARA EL ALINEAMIENTO .....	11
FIGURA 5: DESCOMPOSICIÓN DE LAS VARIABLES EN EL ESPACIO DE COLOR HSV.....	16
FIGURA 6: ELECCIÓN DE LOS COMPONENTES DEL PCA EN FUNCION DE UN UMBRAL DE CONSERVACION DE ENERGIA .....	19
FIGURA 7: EER PARA LAS CARACTERISTICAS ‘WIEN’ DEL ATRIBUTO ‘HOMBRE’.....	22
FIGURA 8: MEJORA DEL EER MEDIANTE AJUSTE DE VALORES C,Γ POR BUSQUEDA POR CUADRADOS .....	23
FIGURA 9: METODOS PROPUESTOS PARA LA CONSTRUCCION DEL CLASIFICADOR GLOBAL	24

FIGURA 10: CONSTRUCCIÓN DEL CLASIFICADOR GLOBAL COMO LA PONDERACIÓN DE LOS MEJORES CLASIFICADORES LOCALES .....	25
FIGURA 11: CONSTRUCCIÓN DEL CLASIFICADOR GLOBAL COMO EL CLASIFICADOR RESULTANTE DE ENTRENAR LA FUSION DE LAS MEJORES CARACTERÍSTICAS .....	26
FIGURA 12: CONSTRUCCIÓN DEL CLASIFICADOR GLOBAL COMO EL CLASIFICADOR RESULTANTE DE ENTRENAR LA FUSION DE LAS MEJORES CARACTERÍSTICAS .....	27
FIGURA 13: : ELIMINACION DE RUIDO DEBIDO A MÁSCARA ELÍPTICA.....	29
FIGURA 14: SELECCIÓN DE CARACTERISTICAS SEGÚN 5-FOLD-CROSS-VALIDATION.....	30
FIGURA 15: REDUCCIÓN DE DIMENSIONALIDAD ‘PCA’ PARA LAS ETAPAS DE ENTRENAMIENTO Y TESTEO .....	31
FIGURA 16: OBTENCIÓN DE LOS CLASIFICADORES LOCALES PARA UN DETERMINADO ATRIBUTO $A_k$ .....	32
FIGURA 17: OPTIMIZACION DE LOS PARAMETROS SVM.....	32
FIGURA 18: CLASIFICADOR AUTOMATICO DE ATRIBUTOS.....	40
FIGURA 19: RESULTADOS DE CLASIFICACIÓN PARA BEBE.....	41
FIGURA 20: RESULTADOS DE CLASIFICACIÓN PARA HOMBRE DE RAZA NEGRA.....	41

## INDICE DE TABLAS

TABLA 1: ATRIBUTOS $A_k$ Y SU CLASE DE PERTENENCIA .....	9
TABLA 2: ESTÁNDAR ISO PARA LA EXTRACCION DE REGIONES FACIALES A PARTIR DE COORDENADAS OCULARES .....	11
TABLA 3: DEFINICIÓN DE LAS REGIONES FACIALES PROPUESTAS .....	12
TABLA 4: MÁSCARAS ELIPITICAS UTILIZADAS PARA LAS REGIONES FACIALES INDICADAS...	13
TABLA 5: LIMITES DE LAS REGIONES COMPUESTAS .....	14
TABLA 6: LIMITES DE LA REGION ‘CABEZA’ .....	14
TABLA 7: LIMITES DE LAS REGIONES RECTANGULARES .....	14

TABLA 8: CARACTERISTICAS MEJOR EVALUADAS.....	35
TABLA 9: RESULTADOS DE EVALUAR LOS CLASIFICADORES GLOBALES .....	39

# 1. INTRODUCCIÓN

## 1.1 MOTIVACIÓN

En los últimos tiempos, el advenimiento de las tecnologías de Aprendizaje automático y de Inteligencia artificial han permitido trasladar problemas matemáticos complejos al terreno de las Máquinas. El aumento en la capacidad de procesamiento, gracias en parte a la computación distribuida, la explosión reciente de las tecnologías del BigData y la naturaleza cada vez más abierta de multitud de investigaciones produce que vivamos hoy en el periodo histórico de la Humanidad donde más información tenemos disponible. La Biblioteca del Congreso de Estados Unidos contiene cerca de 20 petabytes de información, mientras que se estima que en los centros de Data de Google se pueden superar los 5 exabytes.

Queda patente que la capacidad computacional de las máquinas y ordenadores supera ampliamente ( y cada vez con más margen) a la de los humanos. Sin embargo, entre ellas y nosotros existe una diferencia cognitiva que la Neurociencia todavía estudia: ¿Por qué nuestro cerebro es capaz de distinguir y adaptarse a problemas cambiantes? Es con esta pregunta en mente que pretendemos estudiar las formas en que una maquina es capaz de *aprender* una tarea que nuestro cerebro realiza sin aparente dificultad.

En la Biometría tradicional, sobretodo en el ámbito forense de Reconocimiento Facial, se diseñan sistemas capaces de distinguir entre personas por comparaciones geométricas entre una multitud de características extraídas de regiones faciales y antropomórficas. En definitiva, se pretende resolver la pregunta *¿Qué rasgos diferencian a una persona del resto para poder clasificarlo?*

Este proyecto se centra en el estudio y desarrollo de un sistema de clasificación de atributos capaz de clasificar rasgos demográficos, como la edad, etnia o el sexo y atributos faciales de naturaleza más o menos subjetiva, como si está sonriendo o si lleva gafas a partir de imágenes de personas en entornos no controlados de iluminación y pose. De esta forma, la pregunta anterior ahora se reformula para responder a la principal motivación que se plantea en este trabajo: *¿Qué rasgos permiten clasificar grupos de personas?* Se buscaran por tanto el conjunto de características que permitan clasificar con un cierto grado de precisión estos atributos, con el fin último de ser capaz de extraer una multitud de información secundaria, o atributos faciales, a partir de una sola imagen de una persona.

## 1.2 OBJETIVOS Y ENFOQUE

El objetivo principal de este trabajo es diseñar un sistema capaz de extraer y clasificar atributos de manera automática a partir de imágenes de personas sacadas de entornos poco controlados de luminosidad y de pose, donde son frecuentes las oclusiones debidas a la aparición de varios individuos por imagen y donde no es homogénea la expresión facial de los sujetos.

Para ello se utilizará un subconjunto de la Base de Datos pública llamada Facetracer, que contiene una gran cantidad de imágenes faciales sacadas del mundo real y de Internet. Se aprovechará el hecho de que todas las imágenes están asociadas a una multitud de atributos faciales y etiquetados manuales que permitirán entrenar cada clasificador. Como son imágenes sacadas de entornos reales y poco controlados, deberían ofrecer una representación fiel de lo que distingue a un segmento de otro en la vida real.

En primera instancia se procede a una primera fase de experimentación que permitirá evaluar el grado de discriminación que ofrece cada una de las características propuestas para clasificar un determinado atributo. Para ello se definirán un conjunto de normas para la extracción de estas características que se aplicarán a las imágenes provistas en la base de datos Facetracer. El objetivo de esta fase será construir, evaluar y ranquear varios clasificadores SVM construidos a partir de cada conjunto de características estudiadas en este trabajo para así evaluar el grado de discriminación que ofrecen según para que atributo bajo estudio. El grado de precisión de los clasificadores obtenidos se obtendrá mediante la tasa de igual error, EER. De esta forma, obtendremos una multitud de clasificadores “débiles” asociados localmente a cada atributo bajo estudio.

Tras esta primera etapa de evaluación de características se pretenderá particularizar, para cada atributo, la mejor forma de tratar las características obtenidas de la etapa anterior para la construcción de un clasificador único, o global. Para ello se estudiarán y evaluarán varios métodos que permitan construir, a partir de las mejores características obtenidas, clasificadores “globales” más robustos para cada atributo bajo estudio.

Una vez evaluado el rendimiento de cada clasificador global se desarrollará una fase final de despliegue donde se integrarán en un único sistema los mejores clasificadores hallados anteriormente junto con su respectiva extracción de características. De esta forma se conseguiría formular un sistema capaz de clasificar cualquier imagen de entrada sobre un rango extenso de atributos que es el fin último de este proyecto.

### 1.3 ORGANIZACIÓN DE LA MEMORIA

La memoria consta de los siguientes capítulos:

- 1. Introducción
- 2. Estado del Arte
- 3. Diseño del Clasificador de Atributos
- 4. Trabajo Experimental
- 5 Conclusiones y Trabajo futuro



## 2 ESTADO DEL ARTE

### 2.1 INTRODUCCIÓN

El presente trabajo se puede entender como una intersección entre varios campos. Por un lado, se pretenden integrar las técnicas más establecidas en el ámbito de Reconocimiento facial para la elección de características discriminantes entre segmentos de personas. Por otro lado, este trabajo se esfuerza en aunar conceptos del Análisis de Datos y Aprendizaje automático para poder establecer modelos y algoritmos complejos que permitan descubrir tendencias ocultas en un flujo de datos para así poder producir clasificaciones fiables y repetibles.

En los últimos años se ha identificado la necesidad de diseñar clasificadores de atributos por varios motivos. El más inmediato sería para complementar sistemas de reconocimiento facial tradicionales: La inclusión de los resultados de estos clasificadores pueden servir como características adicionales a las propuestas según la teoría de antropometría facial. Por tanto la tarea de reconocimiento de un sujeto se serviría de información complementaria más subjetiva e intuitiva como puede ser la etnia, género o edad de un sujeto además de las distancias geométricas según la teoría del reconocimiento facial en el ámbito forense.

### 2.2 SISTEMAS DE RECONOCIMIENTO FACIAL FORENSE

Importantes avances técnicos en las últimas dos décadas han permitido propulsar el área de investigación de reconocimiento facial a cotas difícilmente imaginables en 1882 cuando el criminólogo francés Alphonse Bertillon diseñó las primeras reglas matemáticas que permitían la clasificación de rasgos faciales.

Sucesivos avances como el análisis de componentes principales (Principal Component Analysis, PCA) fueron utilizados por Sirovich [9] en 1987 para la compresión de los vectores de características que hacían realizables las tareas de identificación llevadas a cabo por Turk y Pentland [10] dado el estado de la computación en la época. Otro método de reducción de dimensionalidad que permitió un avance significativo fue el análisis discriminante lineal (Linear Discriminant Analysis, LDA) [11] basado en el análisis lineal de Fischer, por el que se pretende buscar una combinación lineal dadas las características más significativas de un conjunto dado. Contrastando con PCA, LDA pretende centrarse en las diferencias entre clases, produciendo en general mejores resultados que PCA. La correspondencia entre agrupaciones de grafos elásticos (Elastic Bunch Graph Matching, EBGM) [12] pretenden realizar un grafo representativo a partir de los puntos más característicos de la cara. En una primera etapa se normalizan las imágenes y se aplican una serie de transformaciones geométricas con el objetivo de ubicar puntos referenciales de las coordenadas de los ojos.

Posteriormente se añaden las etiquetas obtenidas utilizando el método Wavelets de Gabor, de forma que se puede caracterizar tanto en el dominio espacial como en el frecuencial.

## 2.3 CLASIFICACIÓN DE ATRIBUTOS

Trabajos anteriores se habían centrado mayoritariamente en la clasificación de los atributos de género y etnia. En trabajos como [11] se demostró como la clasificación de atributos sencillos, como “gafas”/ “no gafas” podía servirse de LDA. Moghadam, Yang [13] demostraron como la utilización de SVM permitía por primera vez un grado interesante de precisión a la hora de identificar el género de individuos sobre el banco de imágenes FERET.

Más adelante técnicas basadas en la selección de la combinación linear de clasificadores débiles, como el Adaboost, fueron utilizados por Shakhnarovich [14] para clasificar casi en tiempo real una variedad de atributos, utilizando las características Haar del detector facial “Viola-Jones” [15].

Uno de los primeros trabajos centrados en la clasificación de atributos faciales se remonta al año 2008 cuando Kumar [1] se propuso a diseñar un buscador de imágenes capaz de mostrar imágenes de personas que respondieran a una serie de atributos diversos, como la etnia o la edad. Para ello se servían de arquitecturas de clasificación basadas en Support Vector Machines (SVM’s) complementadas con técnicas de ‘boosting’ basadas en Adaboost.

En [3] se pretenden integrar algunas de las técnicas mencionadas anteriormente para producir un sistema de autenticación continua para entornos móviles basado en la extracción de atributos. Se combinan técnicas de LBP [17], o patrones binarios locales, complementados junto con histogramas orientados a gradientes, HOG, como método de extracción de características complementados además con una reducción de componentes basado en PCA. Basándose en los resultados obtenidos en [16], se parte de la base de que un sistema de autenticación, o verificación, basado en técnicas tradicionales de reconocimiento facial producirá resultados poco fiables cuando el entorno donde se realiza la fase de inscripción al sistema de un determinado usuario difiera considerablemente del entorno donde se testea. Cambios en el fondo de una imagen o cambios en la iluminación tienden a producir desviaciones a la hora de extraer distancias geométricas en los que se basa la teoría de reconocimiento facial tradicional, pero idealmente no afectarán tan gravemente a la clasificación de atributos faciales.

# 3 DISEÑO DEL CLASIFICADOR DE ATRIBUTOS

## 3.1 INTRODUCCIÓN

El objetivo de este trabajo es construir clasificadores que permitan predecir el grado de pertenencia de cualquier imagen de entrada a un determinado atributo de manera binaria, esto es “pertenece” o “no pertenece”. Las técnicas utilizadas para el entrenamiento de estos modelos binarios de clasificación se basarán en algoritmos de aprendizaje supervisado según la tecnología SVM [8].

Para ello será necesaria una primera fase de obtención del conjunto de características que más información discriminante ofrecen entre las posibles clases mediante la construcción y evaluación de clasificadores entrenados con cada posible elección de las características propuestas en este trabajo.

Una vez obtenidas las características que mejores clasificadores producen, se procederá a la evaluación de distintas técnicas que permitan mejorar la robustez del clasificador final. Finalmente, se integrarán en un único sistema los clasificadores obtenidos para así poder evaluar todos los atributos propuestos para cualquier imagen de entrada provista de coordenadas oculares.

### 3.1.1 FASES PROPUESTAS

Para cada Atributo  $\mathbf{A}_k$  [Tabla 3] bajo estudio se pretenderá construir un *Clasificador Global*  $\mathbf{CG}_k$  a partir de la combinación de múltiples *Clasificadores Locales*  $\mathbf{CL}_k^i$  menos robustos, entrenados a partir de una selección de características extraídas a partir de transformaciones sobre imágenes de la base de datos Facetracer. Partiendo de la hipótesis planteada en [1], definiremos las posibles características de entrenamiento de cada clasificador  $\mathbf{CL}_k^i$  como una combinación de un total de 270 posibles distintas, tal que  $\mathbf{CL}_k^i$   $i=1,\dots,270$ . La precisión obtenida en cada Clasificador Local permitirá evaluar la relevancia de cada selección de características extraídas.

Se puede entender el proceso de diseño de los clasificadores globales  $\mathbf{CG}_k$  como la implementación de dos etapas. En la primera etapa, se seleccionan las características que más información discriminatoria contienen mediante la construcción y evaluación de distintos Clasificadores Locales  $\mathbf{CL}_k^i$   $i=1,\dots,270$  entrenados con estas características extraídas de imágenes etiquetadas con el Atributo  $\mathbf{A}_k$  frente a imágenes de la misma clase  $C_p$  que no la cumplan según un esquema de entrenamiento “One-vs-Rest”. En este trabajo se tendrán en cuenta las características locales que permitan construir los 5 mejores  $\mathbf{CL}_k^i$  para cada uno de los distintos atributos  $\mathbf{A}_k$ . La implementación de esta etapa se ilustra en la figura 1.

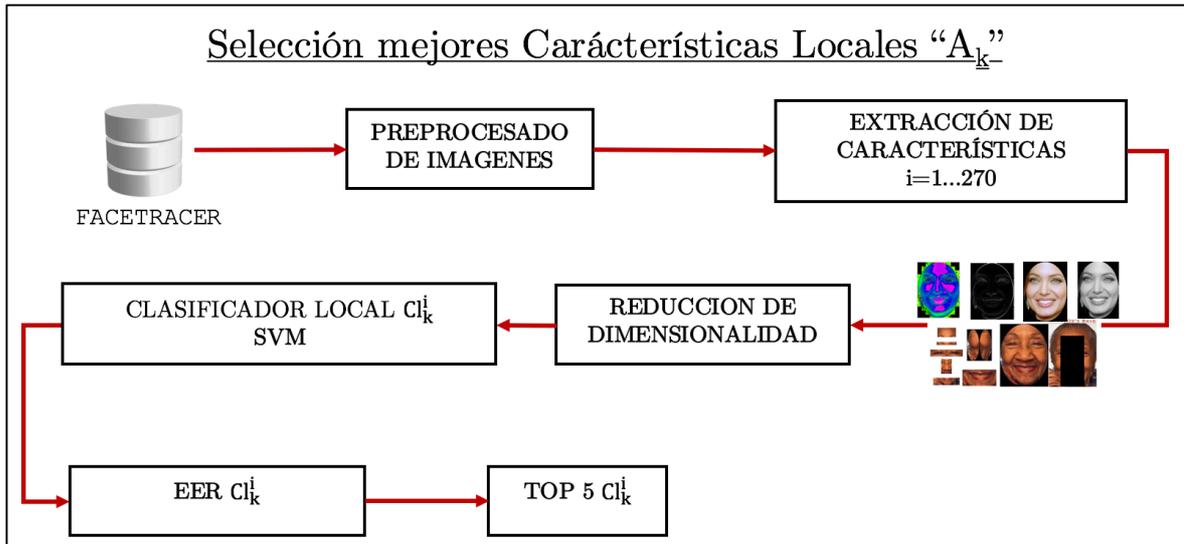


FIGURA 1: ESQUEMA DEL PROCEDIMIENTO PARA LA SELECCIÓN DE CARACTERÍSTICAS LOCALES

En la segunda etapa se construirán cada uno de los distintos  $CG_k$  mediante la evaluación de distintas técnicas de combinación de características extraídos a partir de los resultados de la etapa anterior. El diseño de esta etapa se ilustra en la figura 2.

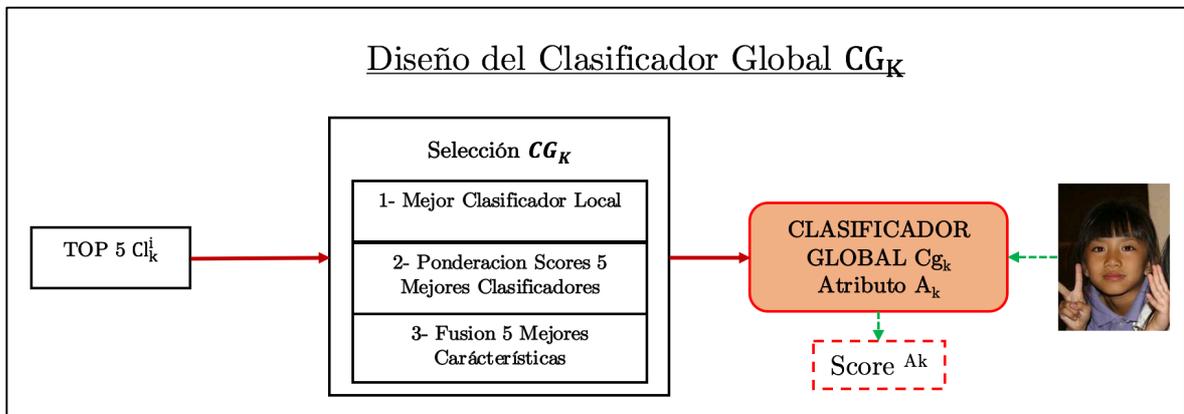


FIGURA 2: ESQUEMA DEL PROCEDIMIENTO PARA LA SELECCIÓN DE CARACTERÍSTICAS LOCALES

A partir de la construcción de los clasificadores  $CG_k$  se procederá a implementar un sistema capaz de puntuar cualquier imagen de entrada provista de coordenadas oculares sobre cada uno de los distintos atributos bajo estudio.

Cada una de las etapas provistas se detallarán en los apartados sucesivos.

### 3.1.2 BASE DE DATOS FACETRACER

Para este trabajo se utilizarán las imágenes contenidas en la base de datos Facetracer[3], que contiene 15000 imágenes de personas sacadas de Internet. La riqueza de esta fuente reside en que ofrece etiquetados manuales para los ojos y para una multitud de Atributos.

La base de datos solo contiene enlaces URL's al sitio donde se alojan las imágenes y en este trabajo se utilizaran aquellas que tenían un enlace válido en el momento de escribirse. Como consecuencia, la muestra con la que se ha realizado este trabajo no abarca toda la casuística con la que se diseñó en origen esta base de datos, pero permite no obstante agilizar los tiempos de computación y aproximar suficientemente los resultados. En la Tabla 1 se recogen las volúmetrías para cada atributo etiquetado

Los Atributos  $A_K$  que se pretenderán clasificar se detallan a continuación.

Atributo $A_K$	Clase $C_P$	Cantidad de Imágenes
Asiático	Raza	166
Negro	Raza	150
Blanco	Raza	156
Bebe	Edad	150
Niño	Edad	154
Joven	Edad	154
Mediana Edad	Edad	159
Anciano	Edad	157
Hombre	Genero	137
Mujer	Genero	128
Sonriente	Sonrisa	148
Serio	Sonrisa	134
Gafas de sol	Gafas	162
Gafas de ver	Gafas	149
Sin Gafas	Gafas	153

TABLA 1: ATRIBUTOS  $A_K$  Y SU CLASE DE PERTENENCIA

## 3.2 SELECCIÓN DE CARACTERÍSTICAS LOCALES

La primera etapa del proceso de construcción del clasificador global  $\mathbf{CG}_k$  consistirá en determinar que transformaciones realizadas sobre las imágenes permiten clasificar de mejor manera cada clasificador local  $\mathbf{CI}_k^i$ .

### 3.2.1 PRE-PROCESADO: NORMALIZACIÓN DE ESCALA Y POSE

Dada la naturaleza no-controlada de las imágenes de la Base de Datos FaceTracer, donde cada imagen tiene una resolución y orientación de ojos distinta, se requiere establecer un marco de normalización para definir correctamente las regiones bajo estudio. Sirviéndonos del etiquetado previo [Figura 3] de los extremos de las regiones oculares  $x_{i,r}^{1,2,3,4}$  en FaceTracer podemos deducir los contornos de interés sucesivos en referencia a unas posiciones comunes de entre todas las imágenes de entrenamiento. Para este proceso inicial de normalización se partirá del código provisto “cropFaceISO” [7]

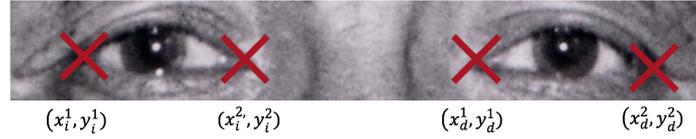


FIGURA 3: COORDENADAS DE LAS REGIONES OCULARES PROVISTAS EN LA BASE DE DATOS DE FACETRACER

La localización de las pupilas  $P_{d,i}^{x,y}$  se puede calcular como el valor medio entre los extremos de cada ojo.

$$\begin{aligned}
 p_d^x &= \frac{x_d^1 + x_d^2}{2} : \text{Coordenada 'x' de la pupila derecha } x1 \\
 p_d^y &= \frac{y_d^1 + y_d^2}{2} : \text{Coordenada 'y' de la pupila derecha } y1 \\
 p_i^x &= \frac{x_i^1 + x_i^2}{2} : \text{Coordenada 'x' de la pupila izquierda } x2 \\
 p_i^y &= \frac{y_i^1 + y_i^2}{2} : \text{Coordenada 'y' de la pupila izquierda } y2
 \end{aligned}$$

La rotación de imagen se aborda resolviendo el problema de trigonometría resultante de encontrar el ángulo que conforman las pupilas y aplicando la rotación correspondiente a la transformada afín.

$$\varphi = \pm \cos^{-1} \left( \frac{\sqrt{(p_d^x - p_i^x)^2}}{\sqrt{(p_d^x - p_i^x)^2 + (p_d^y - p_i^y)^2}} \right)$$

Acto seguido, se deberá asegurar que todas las imágenes a procesar se escalan al mismo tamaño. Así se podrá, en función de los puntos fiduciales oculares marcados, delimitar el resto de regiones asegurando que el contenido de los mismos es idéntico para todas las imágenes procesadas. Para ello nos serviremos de la normalización geométrica del estándar ISO.

La normalización del estándar ISO se sirve de las distancias indicadas en la Tabla 2. Este proyecto utiliza una distancia de ancho de imagen  $W=300$  Píxeles que garantiza una suficiente cantidad de información y asegurando una confluencia con la mayoría de sistemas automáticos de extracción de regiones.

Puesto que la posición de la región facial bajo estudio para cada imagen preprocesada caerá en diferentes posiciones por la naturaleza no-controlada del origen de las imágenes, será necesario finalmente alinear las imágenes para contener los rostros. De esta forma se puede garantizar que a partir de este punto todos los procesados de imagen serán efectuados sobre las mismas regiones faciales.

Características	Valor	Pixel
Ancho de la imagen	$W$	300
Alto de la imagen	$W/0.75$	400
Coordenada Y de los ojos	$0.6*W$	180
Coordenada X del ojo derecho	$(0.375*W)-1$	112
Coordenada X del ojo izquierdo	$(0.625*W)-1$	187

TABLA 2: ESTÁNDAR ISO PARA LA EXTRACCION DE REGIONES FACIALES A PARTIR DE COORDENADAS OCULARES

Por tanto podemos resumir el preprocesado de imágenes en tres etapas, ilustradas en la figura 4:

1. Compensación de rotación por transformación afín.
2. Escalado al estándar ISO según las dimensiones propuestas
3. Alineamiento de rostros

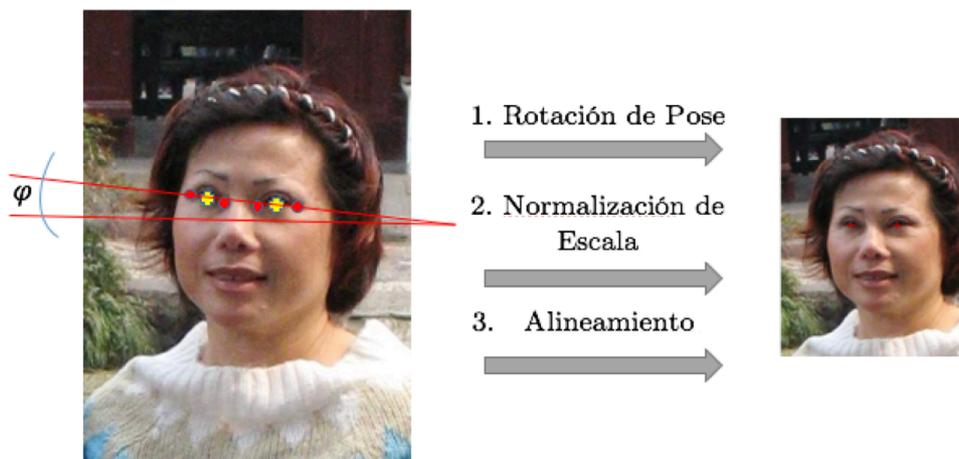


FIGURA 4: ILUSTRACIÓN DEL PREPROCESADO PARA EL ALINEAMIENTO

Una vez que se dispongan de las imágenes preprocesadas, se procede a la extracción de características. Teniendo presente los resultados obtenidos en [1] y en [3]], se proponen las posibles extracciones como una elección de regiones faciales, espacios de color, detección de bordes, normalizaciones de energía y agregaciones tal que se puedan distinguir hasta 270 distintas posibles características distintas.

### 3.2.2 REGIONES FACIALES

Se pretende descomponer cada imagen facial original en distintas regiones a partir de las Coordenadas oculares provistas en la Base de Datos de FaceTracer. Sirviéndonos de las regiones propuestas en [1], en total se distinguen 9 regiones. En la tabla 3. se analiza cada descomposición.

Para este proyecto, modificaremos el extractor de rasgos propuesto en [6] para permitir la extracción de regiones elípticas y la composición de regiones compuestas. La clave de de este sistema se basa en la aplicación de Offsets respecto a los puntos oculares marcados a la entrada, para delimitar las regiones faciales en función de estos puntos.

Muestra	Etiquetado
	Imagen original de FaceTracer '4507.jpg' Coordenadas Oculares: <b>Resolución:</b> 500px × 697px
	“Cara Completa” {W}
	“Frente” {F}
	“Cejas” {B}
	“Ojos” {E}
	“Nariz” {N}
	“Mejillas” {K}
	“Pelo” {H}
	“Barbilla” {C}
	“Boca” {M}

TABLA 3: DEFINICIÓN DE LAS REGIONES FACIALES PROPUESTAS

### 3.2.2.1 REGIONES ELÍPTICAS

La composición de regiones elípticas permite concentrar la región bajo estudio de manera suficientemente precisa para descartar el ruido provocado por el fondo de la imagen pero sin descartar la aportación de información de otras regiones colindantes. Con este fin, se delimitan dos regiones de principal relevancia para este estudio: La cara completa y las mejillas.

Partiendo de que una elipse centrada en  $(X_c, Y_c)$  se define como:

$$\frac{(x - X_c)^2}{a^2} + \frac{(y - Y_c)^2}{b^2} = 1$$

Definiremos los límites de la ecuación para cada región en píxeles tal y como aparecen en la tabla 4, sirviéndonos de que las coordenadas de las pupilas son idénticas para todas las imágenes gracias a la previa normalización de escala y pose. La aplicación de estas máscaras servirá para delimitar las regiones.

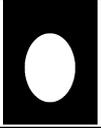
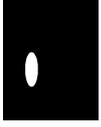
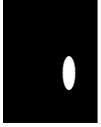
Región	$X_c$	$Y_c$	a	B	Máscara
Cara Completa	$\frac{(p_d^x + p_d^x)}{2} = 150$	220	80	110	
Mejilla Izquierda	90	240	20	55	
Mejilla Derecha	210	240	20	55	

TABLA 4: MÁSCARAS ELIPITICAS UTILIZADAS PARA LAS REGIONES FACIALES INDICADAS

### 3.2.2.2 REGIONES COMPUESTAS

Se llamarán regiones compuestas a la concatenación de varias regiones que agruparemos en una sola. Este permitirá concentrar el área de estudio para cada región, despreciando información redundante recogida en otras descomposiciones regionales. En particular, centraremos el uso de estas regiones compuestas para dos casos concretos: Los ojos y las cejas. Para ello se definirá cada región compuesta como la concatenación de

rectángulos extraídos alrededor de las coordenadas de las pupilas normalizadas. Se definen a continuación las regiones delimitadas en la Tabla 5.

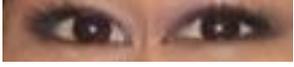
Ojos	$X_{min}$	$Y_{min}$	Ancho	Alto	Resultado
Ojo Izquierdo	82	169	53	23	
Ojo Derecho	165	169	53	23	
Cejas	$X_{min}$	$Y_{min}$	Ancho	Alto	Resultado
Ojo Izquierdo	80	145	70	23	
Ojo Derecho	150	145	70	23	

TABLA 5: LIMITES DE LAS REGIONES COMPUESTAS

### 3.2.2.3 REGIONES RECTANGULARES

Para el resto de posibles regiones a extraer se utilizará el extractor de regiones propiedad de la ATVS y desarrollado en [7] cuya definición de las regiones corresponde con aplicar un desplazamiento rectangular en el sentido horizontal y vertical según un offset respecto a la distancia entre pupilas, IPD.

Los valores de estos offsets delimitarán las regiones rectangulares que servirán de contenedor para la región deseada. Para ello se define primero la región “cabeza”, Tabla 6, a partir de la cual el resto de regiones serán delimitadas.

Región	$X_{min}$	$Y_{min}$	Ancho	Alto
Cabeza	57	40	188	282

TABLA 6: LIMITES DE LA REGION ‘CABEZA’

El resto de regiones se descomponen como rectángulos desplazados respecto al nuevo centro de pupilas de la región “Cabeza” según se define en la tabla 7. Un caso especial es la región que contiene el pelo, que se define aplicando una máscara.

Región	$X_{min}$	$Y_{min}$	Ancho	Alto
Frente	29	47	132	71
Nariz	57	118	75	111
Boca	38	208	113	56
Barbilla	150	145	70	23
Mascara Pelo	47	70	93	213

TABLA 7: LIMITES DE LAS REGIONES RECTANGULARES

A partir de este punto, definimos el conjunto de regiones según la nomenclatura indicada en la tabla 3, que corresponde con la definición de regiones según [1]. La idea fundamental de esta separación de regiones consistirá en encontrar aquellas que, a priori y sin entrar todavía en el post procesamiento de imágenes, contengan la mayor información discriminatoria para cada atributo  $\mathbf{A}_k$  buscado.

Con la definición de regiones provista se asegura que el sistema de clasificación disponga de un conjunto de información suficientemente amplio para sacar provecho de la geometría común entre las caras al mismo tiempo que se resaltan sus diferencias. A su vez, la generosidad en tamaño de las regiones permite un cierto grado de solapamiento, lo que provee al sistema de cierta robustez en caso de un etiquetado de pupilas no óptimo.

### 3.2.3 VALORES DE PIXEL

Toda vez que hayamos extraído las posibles regiones faciales que queramos estudiar, resulta de gran interés en este trabajo discernir posibilidades de procesamiento de imágenes. Según lo planteado en [1], son de especial relevancia la elección de los espacios de color así como la detección de bordes.

Habrà asimismo que asumir un criterio para el procesamiento de los espacios multidimensionales. Puesto que algunas de los procesamientos propuestos ocuparán varios canales de información, se optará por continuar el procesamiento de imágenes de manera independiente para cada canal. De esta forma se podrá adaptar el conjunto de operadores para el procesado de imágenes a cada canal de información. A continuación se detallan las codificaciones utilizadas en este trabajo.

#### 3.2.3.1 RGB {R}

La totalidad de imágenes contenidas en la Base de datos ‘*Facetracer*’ están comprimidas en formato ‘jpg’. La deducción de los canales RGB resulta trivial usando operadores por defecto en MATLAB.

#### 3.2.3.2 HSV {H}

El espacio de colores HSV, también conocido como HSB, es una representación en coordenadas cilíndricas usada para modelar una gama de colores. La principal motivación para usar este espacio de colores consiste en ofrecer una representación más intuitiva de la conformación de un determinado color.

De la misma manera que la gama de colores del espectro visible se puede construir a partir de la mezcla de los canales rojo (R), verde (G) y azul (B), el esquema HSV propone descomponer colores en función de su matiz (Hue, H), saturación (S) y brillo (value/brightness, V) tal y como se ilustra en la figura 5.

Estos términos son más entendibles desde el punto de vista perceptual para comprender como se conforma un color. A modo de ejemplo, la diferencia entre el color naranja y el color marrón se podría representar como un cambio en el valor de la saturación (S), mientras que implicaría cambiar el valor de las componentes RGB en su totalidad usando este espacio de colores.

De esta forma, cambios sutiles en la tonalidad de la piel se reflejarían inmediatamente como cambios en las variables S,V y en mucha menor medida en el parámetro H. Si reflejásemos los mismos cambios de tonalidad en el espacio RGB, la variabilidad de estos canales sería mucha mayor y por ende la clasificación se complica.

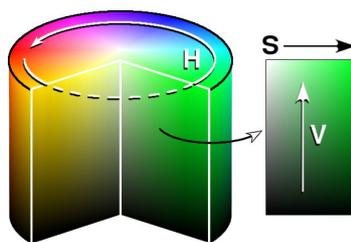


FIGURA 5: DESCOMPOSICIÓN DE LAS VARIABLES EN EL ESPACIO DE COLOR HSV

### 3.2.3.3 ESCALA DE GRISES {I}

El uso de la escala de Grises permite darnos una idea de la intensidad de brillo de una imagen como combinación del resto de canales. De esta forma, integramos en un único canal la información de luminosidad de una determinada imagen. Utilizando la definición del espacio de colores HSV, una escala de grises no sería otra cosa que eliminar la información de las componentes H y S, quedándonos solo con la información de brillo, o intensidad de la imagen, de la variable V.

Por tanto el uso de esta escala monocromática permitiría entrenar un modelo donde la información cromática no es especialmente relevante y por ende encontrar relaciones ocultas más intrínsecamente relacionadas con la distribución geométrica de los píxeles.

### 3.2.3.4 DETECCIÓN DE BORDES: MAGNITUD {M} Y ORIENTACIÓN {O}

Una técnica fundamental y ampliamente utilizada en el ámbito de extracción de características y procesamiento de imágenes consiste en aplicar un conjunto de operadores matemáticos capaces de informar acerca de discontinuidades dadas en una determinada imagen. Estas discontinuidades pueden deberse a cambios en la luminosidad, diferencias de texturas, relieves etc. La aplicación de estas técnicas permitirá estudiar la información de contorno de una determinada región facial.

En este trabajo se utilizará el Operador de Sobel, que consiste en encontrar una aproximación a los Gradientes en el eje X e Y,  $G_x$  y  $G_y$  respectivamente, dada una imagen

monocromática  $\mathbf{A}$ . Aquellas regiones con alta variabilidad de luminosidad se identificarán como bordes de un contorno.

Según Sobel, estos operadores se conforman de una pareja de Kernels convolucionales en dos dimensiones según las definiciones:

$$\mathbf{G}_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * \mathbf{A} \quad \mathbf{G}_y = \begin{bmatrix} +1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} * \mathbf{A}$$

Se deducirán la Magnitud de Borde  $|G|$  y la Orientación de Borde  $\theta$  entonces como:

$$|G| = \sqrt{\mathbf{G}_x^2 + \mathbf{G}_y^2} \quad \theta = \tan^{-1} \left( \frac{\mathbf{G}_x}{\mathbf{G}_y} \right)$$

### 3.2.4 NORMALIZACIÓN

Resultará especialmente interesante la normalización de las características atendiendo a varias necesidades. Por tratarse de imágenes sacadas de entornos poco controlados, la variabilidad en iluminación entre imágenes podría añadir incertidumbre al clasificador. Se propondrán varias formas de normalizar las ganancias y los offsets debidos a los efectos de iluminación, previa eliminación del ruido introducido en alguna de las etapas anteriormente descritas del procesamiento de imágenes.

#### 3.2.4.1 NORMALIZACIÓN DE MEDIA $\{M\}$ Y DE ENERGÍA $\{E\}$

Una vez dispongamos de un único vector fila para cada canal de información será opcional aplicar alguna de las normalizaciones propuestas para compensar la variabilidad de iluminación entre las imágenes a tratar.

La normalización de Media  $\{M\}$  será aquella que normalice los valores del vector fila de características respecto a la media de sus valores. De forma que para un vector de entrada  $[x]$ , con media  $\mu$  la salida será:

$$[\hat{x}] = \frac{[x]}{\mu}$$

De manera similar, para eliminar la contribución de ganancias y offsets de iluminación se definirá la normalización de energía para un vector de entrada  $[x]$ , con media  $\mu$  y desviación típica  $\sigma$  como:

$$[\hat{x}] = \frac{[x] - \mu}{\sigma}$$

### 3.2.4.2 SIN NORMALIZACIÓN

Alternativamente se propone evaluar la información discriminante de las características sin concurrir en normalizar las mismas.

### 3.2.5 AGREGACIONES

Para concluir el apartado de extracción de características, se plantea agregar, opcionalmente, la información estadística de varias maneras. La motivación detrás de esto es determinar si es posible reducir la dimensión del entrenador PCA que se detallará más adelante. En el caso de vectores de entrada multi-canal, se construirá un único vector fila resultado de la concatenación de los canales agregados.

#### 3.2.5.1 HISTOGRAMA {H}

Un Histograma es una representación gráfica que relaciona la frecuencia de aparición de determinados rangos de valores para una variable de entrada con el objetivo de caracterizar vectores de entrada generalmente grandes con, relativamente, pocos valores. Será con el vector Contenedor resultante que reduciremos las dimensiones de los vectores de entrada.

Se establecen 100 regiones separadoras teniendo en cuenta que los límites de las regiones contenedoras deberán ser almacenados entre las fase de entrenamiento y de test.

#### 3.2.5.2 SIN AGREGACIÓN {N}

Alternativamente, se propone no agregar la información con vistas a que la información agregada no sea suficientemente discriminante y no proporcione los resultados esperados. La información extraída de las etapas anteriores será enviada como un vector fila para cada imagen.

## 3.3 REDUCCIÓN DE DIMENSIONALIDAD

Una vez deducidos los vectores de características para las imágenes de entrenamiento y de testeo, se procederá a reducir la dimensión de los mismos con el objeto de encontrar la información más relevante con la que entrenar cada modelo. Para ello se plantea el Análisis de componentes principales. Esta reducción de componentes no se estudia en [1] y se plantea como un tratamiento adicional, similarmente a como han hecho otros trabajos como [3].

### 3.3.1 PRINCIPAL COMPONENT ANALYSIS

Este análisis, inventado por Karl Pearson en 1901 plantea una reducción de dimensionalidad mediante una transformación lineal de la matriz de covarianza en la que se escoge un nuevo sistema de coordenadas por la cual la mayor varianza de entre el conjunto de datos es el primer eje de coordenadas (primer componente principal), la segunda varianza es el segundo eje y sucesivamente. De esta forma, un vector de características se puede reducir a su proyección en los componentes principales que conservan la mayor parte de la energía. La cantidad de Coeficientes obtenidos depende exclusivamente de la cantidad de características entrenadas, según las propiedades de la matriz de covarianza subyacente en este método.

En este trabajo se fija el umbral objetivo del 98% de energía conservada para la elección de la cantidad de componentes con la que reducir la dimensionalidad de las características. Como se observa en la figura 6, la mayor parte de la energía recae sobre los coeficientes principales de menor orden, de forma que se consigue reducir significativamente el tamaño de las características de entrada.

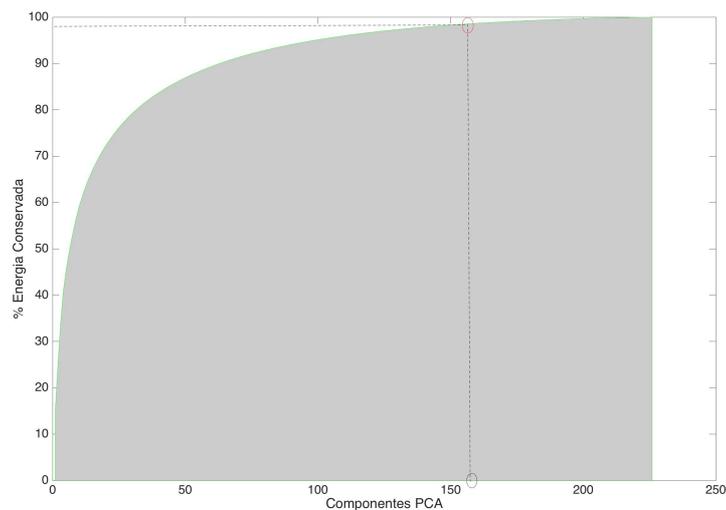


FIGURA 6: ELECCIÓN DE LOS COMPONENTES DEL PCA EN FUNCIÓN DE UN UMBRAL DE CONSERVACION DE ENERGIA

## 3.4 CLASIFICADORES LOCALES

El objetivo de los clasificadores locales  $\mathbf{cl}_k^i$  es evaluar la elección de características  $i=1, \dots, 270$  de las etapas anteriores como candidatos para entrenar el clasificador global  $\mathbf{cg}_k$ . De esta forma, se podrá afirmar que si una selección determinada de características produce un clasificador poco preciso entonces las características empleadas no contienen información relevante para clasificar el Atributo  $A_K$  buscado.

### 3.4.1 SUPPORT VECTOR MACHINES

Toda vez que se dispongan de las características dimensionalmente reducidas por el Análisis de Componentes Principales se estará en disposición de entrenar los clasificadores locales  $\mathbf{cl}_k^i$  y evaluar la selección de características. En este trabajo se resaltarán las ventajas de la utilización de un conjunto de algoritmos de clasificación conocidos como “Support Vector Machines” [8]. Para ello se utilizará la librería LIBSVM [4].

La clasificación según SVM consistirá en separar una determinada muestra de características clasificadas binariamente proyectadas en un hiper espacio con un hiper-plano que garantiza la máxima separación entre clases. Cuando una separación lineal no es posible, se pueden combinar con Kernels que conforman separaciones no lineales. El estudio de estos Kernels, y sus mejores parámetros, será por tanto una pieza de estudio fundamental en este trabajo. Dado una determinada muestra de entrenamiento  $\mathbf{x}_i, i = 1, \dots, l$ , donde  $\mathbf{x}_i \in R^n$ , acompañada del etiquetado de sus clases,  $\mathbf{y}_i \in \{1, -1\}^l$  se propone la solución al problema SVM [8] como la optimización de:

$$\min_{\mathbf{w}, b, \xi} \quad \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^l \xi_i$$

con las condiciones:

$$\begin{aligned} y_i(\mathbf{w}^T \phi(\mathbf{x}_i) + b) &\geq 1 - \xi_i, \\ \xi_i &\geq 0. \end{aligned}$$

Los vectores de entrenamiento  $\mathbf{x}_i$  se trasladan a un espacio multidimensional según la función  $\phi$ , y se encuentra el hiper-plano separador con mayor margen.  $C > 0$  es una constante de error.

Se definirá la función Kernel como:  $K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$

En función de los valores de esta función, los Kernels más típicos y que están implementados en la librería LIBSVM son:

- Lineal:  $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$
- Polinómico:  $K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^T \mathbf{x}_j)^3, \gamma > 0$
- Radial (RBF):  $K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \gamma > 0$

Donde se pretenderá encontrar los valores  $C$  y  $\gamma$  que mejor ajustan cada atributo clasificador local. Además, la librería LIBSVM permite ofrece dos maneras de puntuación para la clasificación: Cálculo de probabilidades [0,1] y por distancia al Hiper-Plano. En este trabajo para la puntuación de salida de un clasificador se empleará el cálculo de probabilidades.

En la fase de experimentación de este proyecto se demostrará que para la mayoría de situaciones bajo estudio la utilización del Kernel Lineal proporciona la mejor relación entre coste computacional y precisión en la clasificación. Por ello en las fases posteriores la optimización de los parámetros del SVM para cada clasificador local se reducirá a la búsqueda del parámetro ‘ $C$ ’.

### 3.4.2 VALIDACIÓN CRUZADA

Para garantizar fiabilidad en los resultados obtenidos de evaluar el rendimiento de cualquier tipo de clasificador, una estrategia ampliamente utilizada [1], [3], [4] consiste en entrenar el 80% de las características etiquetadas y testeando el 20% restante a lo largo de 5 iteraciones, lo que se conoce como una “5-Fold-Cross-Validation”. De esta forma en cada iteración se irán generando puntuaciones hasta tener puntuado el conjunto completo de características etiquetadas y así disponer de suficiente casuística para evaluar rigurosamente el rendimiento de cada posible selección de características  $i=1, \dots, 270$ .

El rendimiento del clasificador  $CI_k^i$  se evaluará entonces como la tasa de *Tasa de Igual Error* (EER por sus siglas en Ingles) como el punto donde se encuentran las curvas de Falsa aceptación (FA) y de Falso rechazo (FR) dadas las puntuaciones obtenidas en cada iteración y el etiquetado realmente esperado. El EER de un sistema permitirá obtener un umbral de decisión a partir del cual clasificar binariamente cada característica de test, ‘Thress<sub>EER</sub>’. Esto permitirá construir un Decisor para el clasificado de las imágenes de Test como se verá más adelante. Un ejemplo de una curva EER obtenida a partir de los resultados de un clasificador local para el atributo “Hombre” se refleja en la figura 7.

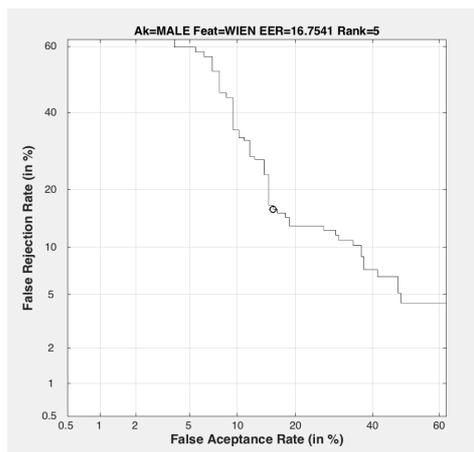


FIGURA 7: EER PARA LAS CARACTERISTICAS ‘WIEN’ DEL ATRIBUTO ‘HOMBRE’

### 3.4.3 BÚSQUEDA POR CUADRADOS

Una parte fundamental en el entrenamiento de clasificadores SVM consistirá en encontrar los parámetros  $C$  y  $\gamma$  que mejor tasa **EER** arroja para una determinada entrada de características etiquetadas. Puesto que en este trabajo se entrenaran y evaluarán los Clasificadores construidos con Kernel Lineal, será necesario por tanto encontrar únicamente el valor del parámetro  $C$ . En este trabajo se propondrá un método sencillo pero que permite aproximar la elección de parámetros con un bajo coste computacional.

El método de búsqueda por cuadrados, o “grid search” en inglés, consiste en entrenar clasificadores probando secuencias de  $C$  con valores incrementales de potencias de 2, tal que:

$$C = 2^x, x \in [-9, \dots, 9]$$

De forma que se probarán 19 valores de  $C$  para cada iteración según el esquema 5-fold-cross-validation indicado anteriormente. La elección del mejor parámetro  $C$  será aquella para la cual el EER de las puntuaciones obtenidas para cada iteración es mínimo, según la figura 8.

Según [4] la fortaleza de medir el EER como el resultado de los scores obtenidos de las 5 iteraciones reside en que se consigue no sobre ajustar la elección de estos parámetros puesto que se recoge múltiple casuística a la hora de entrenar los clasificadores. Otra alternativa sería definir  $C$  según la media de los EER obtenidos para cada iteración. Sin embargo esta aproximación es muy susceptible al sobreajuste de parámetros y ofrece resultados poco fiables.

Como una posible expansión de la búsqueda por cuadrados aplicada a Kernels no-lineales se sugiere el siguiente método tal que en una primera instancia:

$$C \in (2^x, x = \text{mejorC} - \text{intervalo} : \frac{\text{intervalo}}{2} : \text{mejorC} + \text{intervalo}) : \text{mejorC} = 1;$$

$$\gamma \in (2^x, x = \text{mejorG} - \text{intervalo} : \frac{\text{intervalo}}{2} : \text{mejorG} + \text{intervalo}) : \text{mejorG} = -1;$$

$$\text{intervalo} = 10$$

Una vez hallada la mejor combinación de los pares  $(C, \gamma)$ , es decir, aquella que ofrezca la EER media más baja de entre las 5 iteraciones según las reglas de la validación cruzada, se procede a repetir el proceso recentrando los valores de *mejorC*, *mejorG* y concentrando el intervalo de búsqueda alrededor de estos valores.

De esta forma encontraremos un nuevo par de valores  $(C, \gamma)$  más precisos concentrados alrededor de los mejores valores iniciales. Se repetirá el proceso hasta que la ganancia respecto al EER previo sea  $\leq 0.005$ . A continuación en la figura 8 se muestra un ejemplo de los resultados obtenidos para un ajuste automático de mejores parámetros para un kernel polinómico. Nótese que de escoger un valor distinto la precisión del clasificador podría variar hasta 15 puntos, y que la ganancia en precisión por ajuste iterativo puede parecer marginal pero sirve para reforzar la idea de que una selección óptima de parámetros es crítica para obtener buenos resultados.

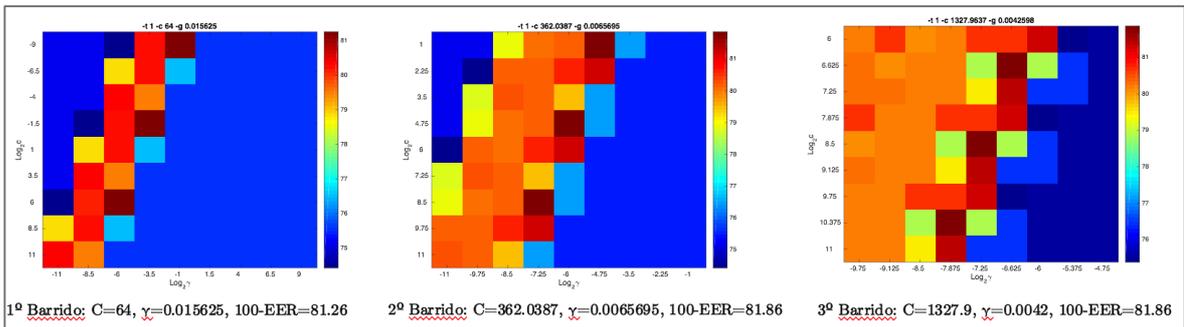


FIGURA 8: MEJORA DEL EER MEDIANTE AJUSTE DE VALORES  $C, \gamma$  POR BUSQUEDA POR CUADRADOS

Una vez que hayamos encontrado el conjunto de parámetros SVM ( $C$  y opcionalmente  $\gamma$ ) que mejor EER ofrece para una determinada selección de características, almacenaremos el clasificador local  $Cl_k^i$ , el EER obtenido de la validación cruzada y la precisión, o ‘accuracy’ calculado como el % total de imágenes de test, ‘verdaderas’ y ‘falsas’, clasificadas correctamente a partir de la decisión sobre ‘Thresh<sub>EER</sub>’.

### 3.4.4 SELECCIÓN 5 MEJORES CLASIFICADORES LOCALES

A partir de los resultados obtenidos para los 270 clasificadores locales  $Cl_k^i$ , para cada Atributo  $A_k$ , se procederá a seleccionar los 5 clasificadores que menor tasa de EER ofrecen. De esta forma se obtienen el conjunto de características más relevantes extraídas en las etapas previas que mejor clasifican un determinado atributo.

Con esto presente, se puede comenzar a diseñar  $Cg_k$ , que es el objetivo de este trabajo para cada  $A_k$  bajo estudio.

## 3.5 ELECCIÓN DEL CLASIFICADOR GLOBAL

Después de seleccionar los 5 mejores clasificadores locales  $Cl_k^i$  y sus correspondientes características asociadas, se tratará de evaluar la mejor manera de construir el clasificador único, o global  $Cg_k$  para cada Atributo  $A_k$  bajo estudio. Para ello se desarrollan tres métodos diferentes [figura 9], que son los siguientes:

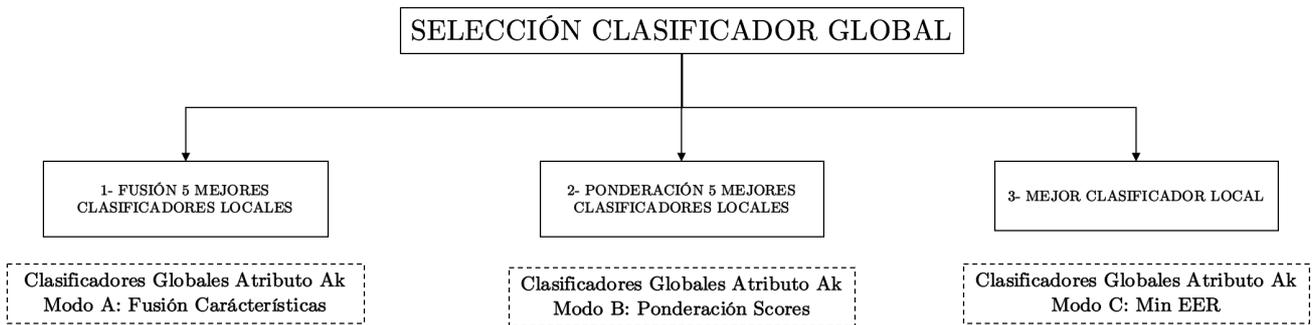


FIGURA 9: METODOS PROPUESTOS PARA LA CONSTRUCCION DEL CLASIFICADOR GLOBAL

- 1- Ponderación de los 5 mejores Clasificador Locales: Ponderación Scores
- 2- Fusión de los 5 mejores Clasificadores Locales: Fusión Características
- 3- Mejor Clasificador Local: Mínimo EER

Una vez se obtengan los resultados de los tres métodos diferentes, se escogerá el que menor tasa EER produzca, para así poder asegurar que el clasificador global  $Cg_k$  implementado en la fase operativa del sistema sea el que mejor permita clasificar cada  $A_k$ .

Si se diera el caso de que las 5 mejores puntuaciones corresponden a más de 5 clasificadores, para el análisis del clasificador global se utilizarían los 5 que primero aparezcan, independientemente de que tengan el mismo valor que los siguientes.

A continuación se desarrolla la metodología empleada para cada uno de los métodos.

### 3.5.1 PONDERACIÓN DE CLASIFICADORES LOCALES

Un método utilizado en [3] consiste en construir el clasificador global como la ponderación de los scores locales  $S_i^{Ak} \in [0,1]$  para cada uno de los mejores cinco clasificadores locales  $\{i=1,\dots,5\}$  teniendo en cuenta el ‘EER’ de cada clasificador local seleccionado. De forma que la puntuación otorgada a una determinada imagen de entrada ‘p’ sea :

$$S_p^{Ak} = \sum_i^5 \frac{S_i^{Ak} \times (100 - EER_i)}{100 - EER_i}$$

A partir de las puntuaciones obtenidas para cada imagen de test debidamente etiquetadas se puede evaluar el rendimiento a partir de la nueva tasa de Igual Acierto,  $EER_{POND}$  y su decisión de umbral,  $Thress_{POND}$ . El procedimiento completo se adjunta a continuación en la figura 10.

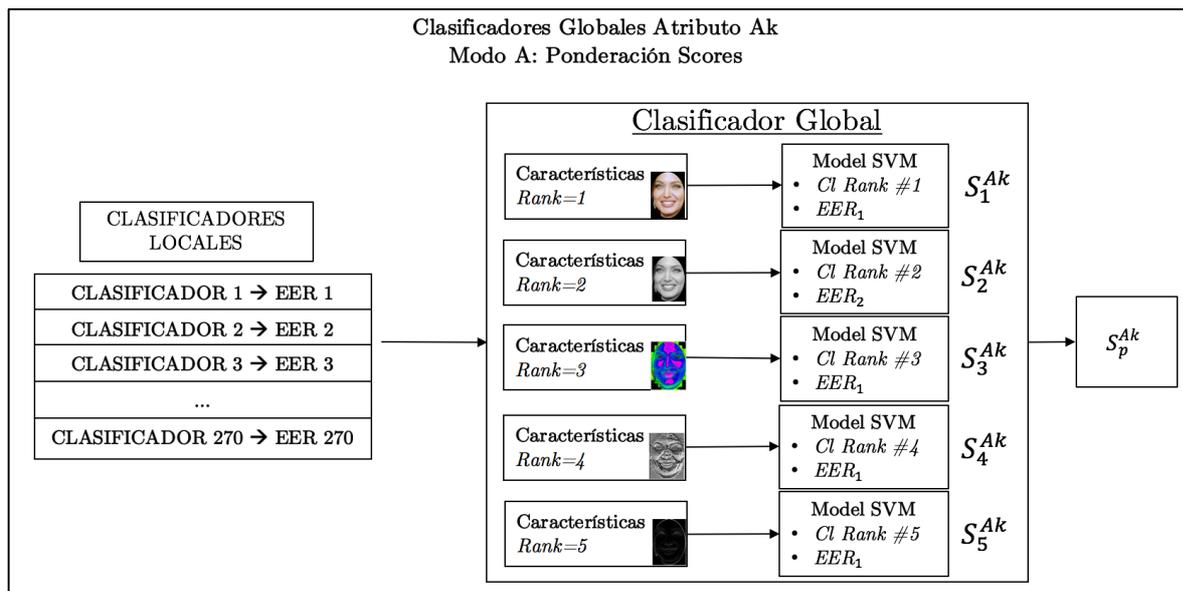


FIGURA 10: CONSTRUCCIÓN DEL CLASIFICADOR GLOBAL COMO LA PONDERACIÓN DE LOS MEJORES CLASIFICADORES LOCALES

Con este método se pretende atenuar el efecto de una mala clasificación por alguno de los 5 clasificadores locales utilizados, de forma que se tienen más en cuenta los clasificadores más robustos frente a los que menos.

### 3.5.2 FUSIÓN DE CARACTERÍSTICAS

En el tercer método, se diseña el clasificador global mediante la fusión de las características con las que se entrenaron los 5 clasificadores locales mejor puntuados. De esta forma se obtendría un nuevo clasificador que se incorporaría a la lista de los 270 clasificadores Locales. Este nuevo clasificador se obtendría de igual manera a el resto de  $\mathbf{Cl}_k^i$ . Se optimizaría el parámetro C y se evaluaría para obtener su propio  $EER_{FUSION}$  y  $Thresh_{FUSION}$ .

Con este método se pretende construir por tanto un clasificador único entrenado con la información más discriminante obtenida en las etapas anteriores. La fusión de características suele proporcionar mejoras en las tasas de reconocimiento si la información es complementaria, pero puede confundir la clasificación si se fusionan características demasiado débiles. El flujo del diseño del clasificador por fusión de características se enseña a continuación en la figura 11.

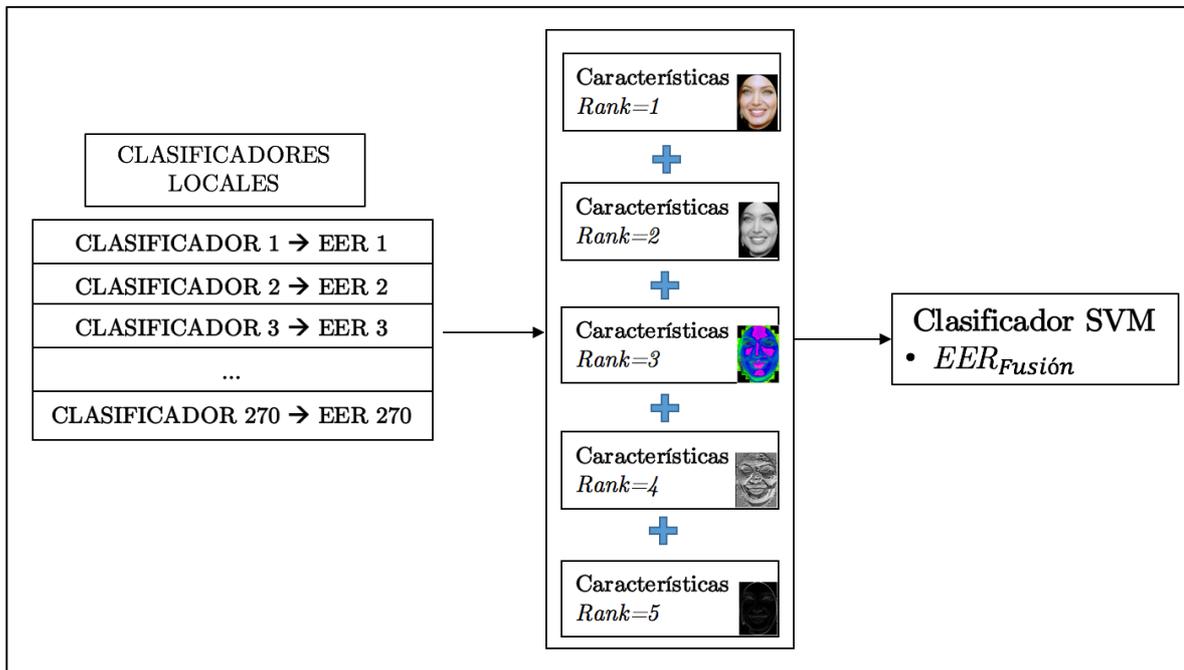


FIGURA 11: CONSTRUCCIÓN DEL CLASIFICADOR GLOBAL COMO EL CLASIFICADOR RESULTANTE DE ENTRENAR LA FUSION DE LAS MEJORES CARACTERÍSTICAS

### 3.5.3 MEJOR CLASIFICADOR LOCAL

Si los métodos anteriores no proporcionan mejoría sobre el mejor clasificador Local extraído entonces se utilizará el mejor clasificador local extraído  $Cl_k^{Top1}$ . Así que directamente este clasificador sería el mismo clasificador global [Figura 12]:

$$Cg_k = Cl_k^{Top1}$$

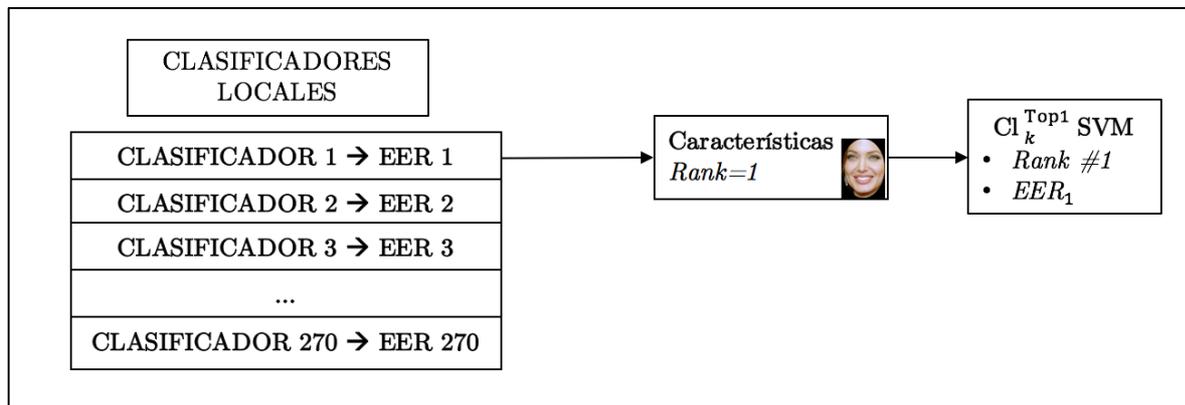


FIGURA 12: CONSTRUCCIÓN DEL CLASIFICADOR GLOBAL COMO EL CLASIFICADOR RESULTANTE DE ENTRENAR LA FUSION DE LAS MEJORES CARACTERÍSTICAS

## 4 TRABAJO EXPERIMENTAL

Los métodos representados anteriormente serán replicados en el entorno de MATLAB para poder evaluar la calidad de los métodos utilizados en este trabajo.

### 4.1 CLASIFICADORES LOCALES

El objetivo de este apartado es detallar el procedimiento experimental realizado para la construcción y evaluación de los distintos 270 clasificadores locales  $\mathcal{C}_k^i$  para cada atributo  $A_K$ .

Dado un atributo  $A_K$  se partirá del fichero “Facelabels” proporcionado por la base de datos Facetracer, que contiene las etiquetas de atributo para un determinado número de imágenes así como a la clase que pertenece el determinado atributo tal que cada línea contiene la id de la imagen, el atributo  $A_N$  al que pertenece y la clase  $C_p$  a la que pertenece el atributo. Así se podrán escoger aquellas imágenes del fichero que correspondan con el atributo buscado y aquellas que no lo hagan pero que pertenezcan a la misma clase, tal que:

$$\begin{aligned} \text{Atributo } A_k &\in C_p \\ \text{Clase } C_p &= \{A_1, A_2, \dots, A_N\} \end{aligned}$$

$$\begin{aligned} \text{Imágenes True: } &A_N \in C_p \quad A_N = A_k \\ \text{Imágenes False } &A_N \in C_p \quad A_N \neq A_k \end{aligned}$$

Puesto que el objetivo de este trabajo es entrenar clasificadores binarios según la aproximación ‘One-vs-Rest’ deberemos entrenar aquellas imágenes del atributo buscado contra aquellas que pertenecen a la misma clase, para asegurar la casuística con la que se diseñó la base de datos. A modo de ejemplo, se entrenará el atributo “Bebe” de la clase “Edad” frente al resto de imágenes de la misma clase, “Niño”, “Joven”, “Mediana edad” y “Senior”.

Las etiquetas serán “1” para una imagen perteneciente al atributo  $A_K$  buscado y “0” para las imágenes pertenecientes a la misma clase  $C_p$ . Una vez se dispongan de las imágenes y sus correspondientes etiquetas, se aleatorizará el orden de los mismos y se almacenará el nuevo orden con el fin de que el orden de la dupla imagenID y Atributo sea el mismo para las 270 evaluaciones de cada Característica bajo estudio, de forma que se garantiza coherencia a la hora de evaluar los clasificadores locales.

Un punto importante es el limpiado de la base de datos. Debido a que solo es posible acceder a una muestra de las imágenes de la base de datos Facetracer algunas de las etiquetas deberán ser eliminadas. Así mismo puede ocurrir que algunas de las imágenes contenidas en la muestra estén corruptas o no correspondan a la imagen buscada y se deberán borrar también de la base de datos y del maestro de etiquetas.

Del fichero “Facestats” extraeremos las coordenadas de los puntos fiduciales correspondientes a los extremos de las regiones oculares, y se procederá con la etapa de preprocesado implementando en MATLAB los métodos detallados en la sección 3.2.1, como combinación del código desarrollado por Pedro Tomé para la normalización de escalado y pose.

En este punto y a partir de las imágenes preprocesadas se comenzará con la etapa de transformación de características. A partir del código desarrollado en [7] se implementarán las nuevas regiones estudiadas en este trabajo en la función desarrollada `transform_face_regionsPar` para poder llevar a cabo una de las 270 transformaciones sobre el conjunto etiquetado de imágenes, de forma que se dispongan de las características para cada imagen contenida en la muestra de Facetracer.

Debido a que MATLAB solo puede operar con matrices rectangulares y que algunas de las etapas de procesamiento como la extracción de regiones elípticas o la detección de bordes introducen necesariamente valores nulos para delimitar las regiones, será necesario dividir una manera de eliminar esta aportación innecesaria de Ruido al sistema.

Para ello encontraremos los límites más frecuentes donde empieza realmente la aportación de información de cada fila y para cada canal para el conjunto de imágenes a procesar. Debemos almacenar estos límites para evitar confundir este ruido con aportaciones nulas no inducidas. Puesto que la longitud de cada fila delimitada será variable, se deberán concatenar en único vector fila. A continuación se ilustra en la figura 13 un ejemplo sencillo del funcionamiento para un solo canal de información.

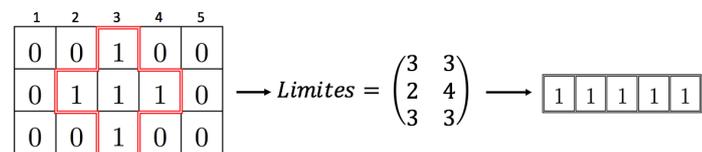


FIGURA 13: : ELIMINACION DE RUIDO DEBIDO A MÁSCARA ELÍPTICA

Así mismo se almacenarán también los límites extraídos de los contenedores para la fase de agregación por histograma.

Se requiere dividir el conjunto de imágenes en distintas iteraciones de “Entrenamiento” y de “Test” según el esquema de la validación cruzada, “5-fold-cross-validation”. Para ello se dividirán los conjuntos de imágenes “true” y “false” en 5 conjuntos distintos de test y de entrenamiento tal que el 80% de las imágenes son de entrenamiento y el restante 20% de test. Combinaremos las imágenes de entrenamiento para cada clase “true” y false” y lo mismo para las imágenes de test, según el esquema “OVR”, [Figura 14]. Con ello se pretende que cada una de las imágenes de la muestra pueda ser clasificada por un clasificador entrenado con el conjunto de entrenamiento de la iteración correspondiente.

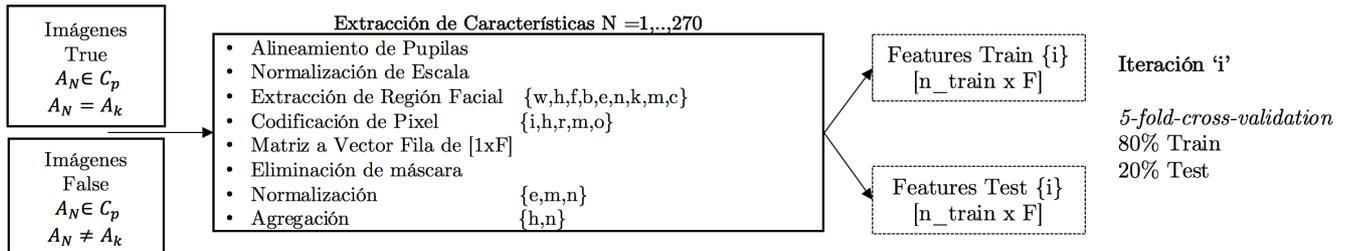


FIGURA 14: SELECCIÓN DE CARACTERÍSTICAS SEGÚN 5-FOLD-CROSS-VALIDATION

Una vez transformadas las imágenes según la combinación de características bajo estudio se procederá a reducir la dimensionalidad de las mismas mediante la aplicación del Principal Component Analysis. Para dar el mismo peso a todos los coeficientes extraídos, será necesario que las características de entrenamiento y de test se encuentren escaladas en el rango [1,0]. Esto obligará a almacenar los valores de escalado para cada sesión de entrenamiento y validación.

Una vez normalizadas las características de entrenamiento y de test se extraerán los coeficientes del PCA utilizando la función `princomp` de Matlab. Los coeficientes resultantes deberán ser almacenados para las etapas de test. La cantidad de Coeficientes obtenidos depende exclusivamente de la cantidad de características entrenadas, según las propiedades de la matriz de covarianza subyacente en este método. Adicionalmente se seleccionará una cantidad de coeficientes tal que la cantidad de información almacenada supere en todo caso el 98% y para ello se utilizarán las gráficas de componentes de PCA como la ilustrada en la figura 6. En la figura 15 se ilustra el procedimiento seguido.

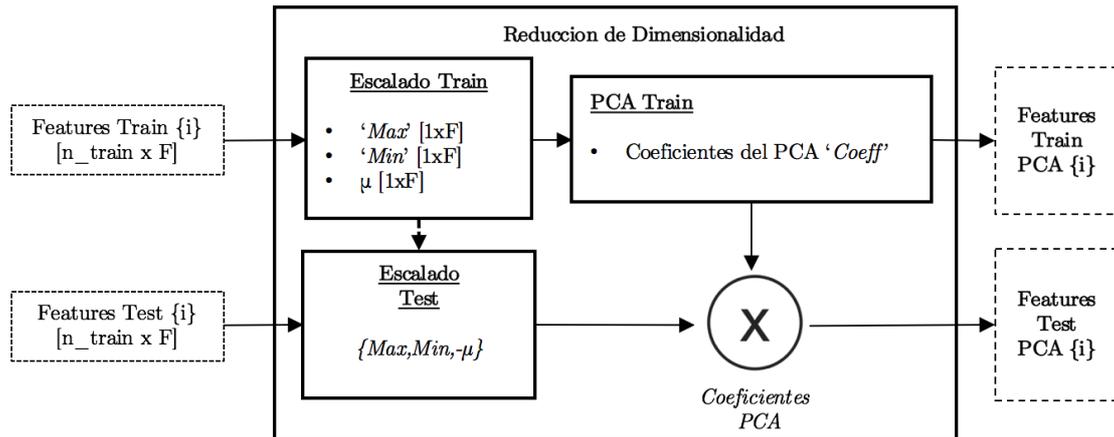


FIGURA 15: REDUCCIÓN DE DIMENSIONALIDAD 'PCA' PARA LAS ETAPAS DE ENTRENAMIENTO Y TESTEO

Según [4] resulta muy importante escalar las características reducidas entre  $[-1,1]$  o entre  $[0,1]$  para entrenar un clasificador SVM. Esto se recomienda para evitar que variables que se mueven en rangos numéricos mayores dominen a aquellos que lo hagan en rangos numéricos menores. Otra ventaja de escalar las características reside en simplificar la complejidad de los cálculos del Kernel.

Por convenio en este trabajo todos los cálculos relativos al SVM se harán para vectores de características obtenidas del PCA escaladas entre  $[0,1]$ . Habrá por tanto que almacenar la proporción de escalado para la fase de testeo junto con aquellos obtenidos previamente en el PCA.

La siguiente etapa experimental se centra en la búsqueda por cuadrados de los mejores parámetros  $C$ , y de manera adicional a efectos experimentales también el de  $\gamma$ , que permiten construir el clasificador local  $\mathbf{Cl}_k^i$ . Para ello se calculara el EER de las scores obtenidos tras hacer 5-fold-cross-validation para cada uno de los distintos pares  $C, \gamma$ . Seleccionando los parámetros que mejor tasa EER ofrecen se almacenaran asociados al clasificador local  $\mathbf{Cl}_k^i$ . Adicionalmente y afectos comparativos con otros trabajos, se calculara la tasa de acierto, o 'Accuracy' como el total de imágenes El esquema del procedimiento seguido para la construcción de los clasificadores locales se ilustra en la figura 16.

## Clasificadores Locales

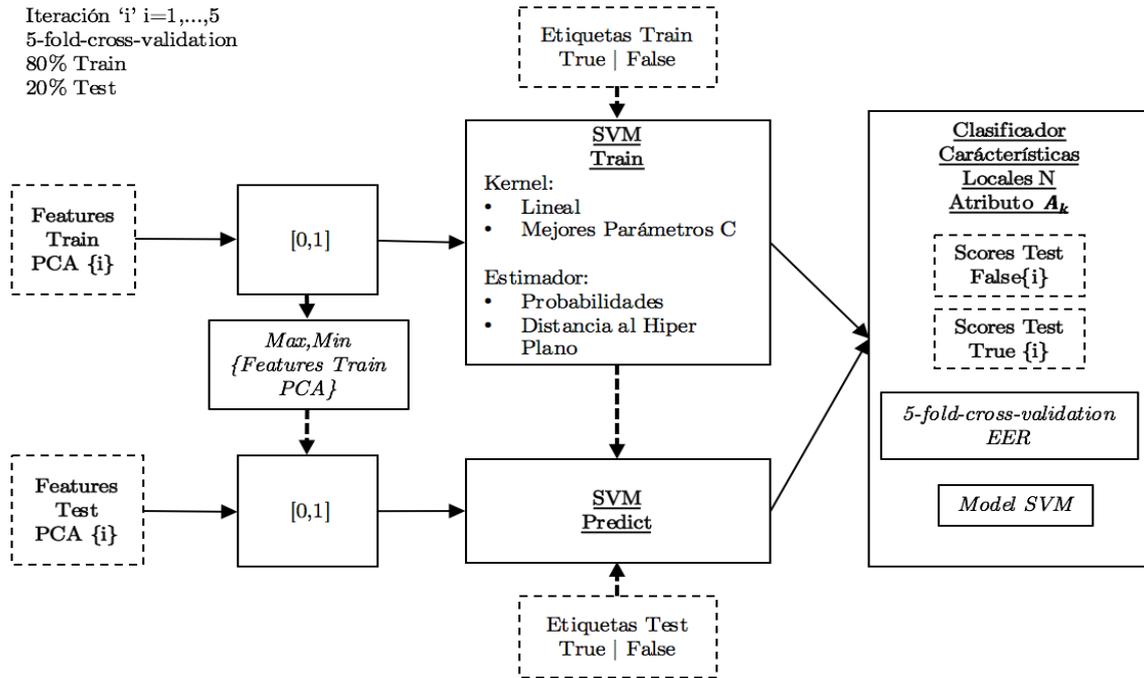


FIGURA 16: OBTENCIÓN DE LOS CLASIFICADORES LOCALES PARA UN DETERMINADO ATRIBUTO  $A_k$

Así mismo, se almacenarán las Scores de la validación cruzada [Figura 17], los límites de los contenedores de las agregaciones por histograma si procede y los límites de las máscaras en todo caso para la etapa siguiente de selección del clasificador global.

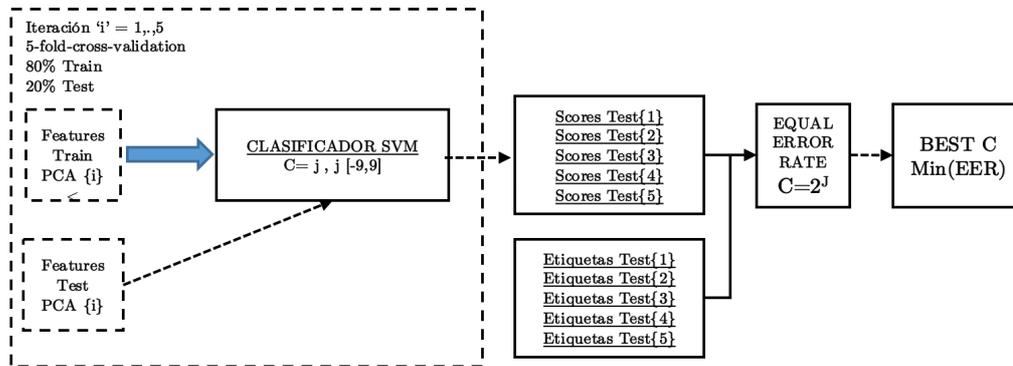


FIGURA 17: OPTIMIZACIÓN DE LOS PARÁMETROS SVM

Una vez obtenidos los mejores parámetros SVM para el clasificador local buscado y la tasa EER de las 5 iteraciones train-test se está en disposición de poder evaluar la selección de características estudiada ( $i=1, \dots, 270$ ) para entrenar el clasificador global  $C_{g_k}$ , que es el objetivo de este trabajo para cada  $A_k$  bajo estudio. Se escogerán las 5 combinaciones de transformaciones de características estudiadas en la sección 3.2 que mejores resultados EER ofrecen como resultado de la validación cruzada. Los resultados para cada atributo  $A_k$  se describen en la sección siguiente.

## 4.2 RESULTADOS DE LOS CLASIFICADORES LOCALES

Puesto que se evaluarán cientos de características diferentes, quedará fuera del alcance de esta publicación indicar el rendimiento de todas y cada una de ellas. Produciremos los resultados para las 5 mejores características extraídas para cada atributo Ak [Tabla 8]. En el Anexo A, se adjuntan los resultados de las 15 mejores características obtenidas.

Atributo Ak	Características	EER Clk	Umbral	C	Accuracy
Hombre	'wrnn'	12.59	0.55	'-t 0 -c 0.25'	87.55
	'wren'	13.42	0.54	'-t 0 -c 0.5'	86.79
	'wrmn'	13.87	0.59	'-t 0 -c 0.5'	86.42
	'wimn'	16.06	0.59	'-t 0 -c 0.25'	84.15
	'wien'	16.06	0.55	'-t 0 -c 0.25'	84.15
Mujer	'wrnn'	12.5	0.44	'-t 0 -c 0.25'	87.55
	'wren'	13.28	0.47	'-t 0 -c 0.25'	86.79
	'wrmn'	14.06	0.42	'-t 0 -c 0.5'	86.04
	'wimn'	16.41	0.41	'-t 0 -c 0.25'	83.77
	'wien'	16.41	0.46	'-t 0 -c 0.25'	83.77
Negro	'whmn'	8.67	0.4	'-t 0 -c 0.25'	91.53
	'whnn'	9.33	0.39	'-t 0 -c 1'	90.68
	'wren'	10.5	0.5	'-t 0 -c 0.125'	89.83
	'when'	10.67	0.37	'-t 0 -c 0.5'	89.41
	'wrmn'	11.33	0.43	'-t 0 -c 0.0039062'	88.77
Blanco	'when'	14.1	0.37	'-t 0 -c 0.5'	86.02
	'whnn'	14.1	0.37	'-t 0 -c 0.5'	86.02
	'wrnn'	14.74	0.34	'-t 0 -c 16'	85.38
	'whmn'	16.03	0.39	'-t 0 -c 0.5'	84.11
	'wren'	17.5	0.39	'-t 0 -c 0.0625'	82.63
Asiático	'wrmn'	15.06	15.06	'-t 0 -c 0.125'	84.96
	'wren'	15.66	15.66	'-t 0 -c 0.5'	84.53
	'whnn'	16.87	16.87	'-t 0 -c 0.5'	83.26
	'when'	17.47	17.47	'-t 0 -c 2'	82.63
	'winn'	17.82	17.82	'-t 0 -c 1'	82.42
Gafas de ver	'when'	22.15	22.15	'-t 0 -c 0.5'	78.02
	'hmen'	22.15	22.15	'-t 0 -c 512'	78.02
	'whnn'	22.82	22.82	'-t 0 -c 0.5'	77.37
	'whmn'	24.13	24.13	'-t 0 -c 0.5'	76.29
	'nhen'	24.13	24.13	'-t 0 -c 4'	76.29

Gafas de Sol	'wimn'	5.56	0.31	'-t 0 -c 0.25'	94.61
	'wren'	5.56	0.36	'-t 0 -c 0.25'	94.61
	'wrmn'	5.7	0.33	'-t 0 -c 0.25'	94.4
	'wien'	6.17	0.42	'-t 0 -c 0.125'	93.97
	'ninn'	6.17	0.35	'-t 0 -c 2'	93.97
Sin Gafas	'nmen'	8.5	0.65	'-t 0 -c 0.0625'	91.59
	'wmmn'	9.15	0.41	'-t 0 -c 1'	90.95
	'wmnn'	10.13	0.36	'-t 0 -c 32'	90.09
	'nmmn'	10.13	0.41	'-t 0 -c 0.5'	90.09
	'wmen'	10.46	0.44	'-t 0 -c 0.5'	89.66
Sonriendo	'wien'	9.6	0.48	'-t 0 -c 0.25'	90.61
	'wimn'	11.18	0.51	'-t 0 -c 0.5'	89
	'winn'	11.79	0.5	'-t 0 -c 1'	89
	'mrnn'	11.79	0.51	'-t 0 -c 1'	88.67
	'wren'	12.42	0.48	'-t 0 -c 0.25'	87.7
Serio	'wien'	9.46	0.5	'-t 0 -c 0.5'	90.61
	'nrnn'	11.49	0.49	'-t 0 -c 2'	88.67
	'mrnn'	12.12	0.49	'-t 0 -c 1'	88.35
	'winn'	12.16	0.49	'-t 0 -c 1'	88.03
	'wrnn'	12.16	0.49	'-t 0 -c 0.5'	88.03
Bebe	'wren'	11.13	0.29	'-t 0 -c 0.125'	89.15
	'whmn'	12	0.3	'-t 0 -c 0.25'	88.11
	'when'	12	0.24	'-t 0 -c 0.5'	88.11
	'wmmn'	12	0.23	'-t 0 -c 2048'	88.11
	'nren'	12	0.21	'-t 0 -c 0.25'	88.11
Niño	'wrmn'	23.38	0.22	'-t 0 -c 0.25'	76.87
	'wrnn'	24.03	0.2	'-t 0 -c 2'	76.1
	'nrnn'	24.03	0.2	'-t 0 -c 1'	76.1
	'winn'	24.68	0.2	'-t 0 -c 0.5'	75.45
	'wren'	24.68	0.21	'-t 0 -c 0.5'	75.45
Joven	'wrmn'	24.04	0.21	'-t 0 -c 0.5'	75.97
	'wren'	25.32	0.2	'-t 0 -c 1'	74.68
	'wimn'	26.62	0.21	'-t 0 -c 0.25'	73.39
	'kren'	26.93	0.2	'-t 0 -c 1'	73.26
	'wrnn'	27.27	0.2	'-t 0 -c 0.25'	72.74
Mediana Edad	'nren'	31.45	0.2	'-t 0 -c 0.25'	68.6
	'mrmn'	31.45	0.21	'-t 0 -c 16'	68.6
	'woen'	31.64	0.21	'-t 0 -c 0.125'	68.48
	'winn'	32.08	0.21	'-t 0 -c 0.5'	67.96
	'wren'	32.08	0.21	'-t 0 -c 0.25'	67.96
Anciano	'wren'	19.47	0.24	'-t 0 -c 0.0019531'	80.75

	'whmn'	19.75	0.23	'-t 0 -c 0.5'	80.36
	'wrmn'	19.75	0.25	'-t 0 -c 0.25'	80.36
	'hhen'	19.75	0.21	'-t 0 -c 2'	80.36
	'hhnn'	19.75	0.22	'-t 0 -c 0.5'	80.36

TABLA 8: CARACTERISTICAS MEJOR EVALUADAS

A raíz de estos resultados se aprecia que la mayor parte de los clasificadores locales ofrecen resultados buenos para cada atributo clasificado. No obstante se observan diferencias notables en la elección de características y en las tasas globales de EER.

La totalidad de los Atributos contienen al menos una transformación de la región “w”, que corresponde con la cara completa según la aplicación de una máscara elíptica y su posterior eliminación de ruido. Esto resulta entendible, puesto que en esta región cabe la mayoría de la información deducida en el resto de regiones. Es decir, a partir de esta región se podrían deducir grosso modo el resto de regiones. Siendo esta región facial la más popular para llevar a cabo sucesivas transformaciones, resulta llamativo como, en principio, la utilización de una región relativamente grande no conlleva a aumentar la incertidumbre del clasificador. Se deduce por tanto que con la optimización de los parámetros SVM se es capaz de obviar la información no relevante y relacionar aquellas regiones que realmente aportan información clasificable.

Esto sería especialmente aplicable a los atributos donde a priori la elección de una característica sobre otra no es evidente, como puede ser el caso de los atributos de Edad o de Genero. Sin embargo, parece que incluso para aquellos atributos donde la elección de las regiones se convierte en algo relativamente intuitivo, como el caso de elegir la región ocular para averiguar si lleva o no gafas, resulta que la región completa W clasifica relativamente mejor. Posiblemente sea conveniente revisar, en trabajos futuros, el tamaño de estas regiones para comprobar si efectivamente la generosidad en el solapamiento de las regiones no ha sido suficiente.

La elección del valor de Pixel parece ser más variable, pudiendo encontrar valores de RGB, HSV y monocromáticos en las posiciones mejor rankeadas para todos los atributos. De esto se puede deducir que existen particularidades de cada atributo que son identificables según el espacio de color donde se examinen, como podría parecer intuitivo en el caso de examinar la tonalidad de piel de un sujeto, pero más complicado de asimilar en la coloración debido al envejecimiento por ejemplo.

Las normalizaciones aparecen también en las primeras posiciones, indicando que el tratamiento para corregir variación en la iluminación parece ofrecer buenos resultados, pero de nuevo subjetivo a las particularidades encontradas por el SVM ya que no siempre es el caso.

Finalmente se puede apreciar que la agregación por histogramas no ofrece ninguna ventaja para la clasificación de atributos. Debido a la posterior etapa de reducción de dimensionalidad, el valor de clasificación de estas características queda muy por debajo de aquellas sin normalizar al incurrir en una agregación excesiva de información que ofrece resultados pobres en la clasificación.

## 4.3 CLASIFICADORES GLOBALES

Toda vez que se disponen de los resultados de evaluación de los clasificadores locales para cada atributo  $A_k$ , se procede a la construcción del Clasificador Global. Seleccionando las 5 mejores características anteriormente descritas, se evaluará el rendimiento de cada una de las 3 metodologías propuestas en el apartado 3.5. Para ello, se partirán de los Scores almacenados de la etapa de clasificación local para aquellos clasificadores mejor rankeados. Para ello se diseña la función `evalClasificador` que tiene por objetivo evaluar cada uno de los métodos propuestos.

### Modo A: Ponderación de Scores

A partir de los scores y EER obtenidos para cada uno de los 5 mejores clasificadores, se evaluará la puntuación global obtenida como la ponderación de las puntuaciones obtenidas para cada mejor clasificador local y para cada iteración de la validación cruzada en función de valor  $EER_i$  obtenido localmente, de forma que las nuevas puntuaciones son:

$$S_p^{Ak} = \sum_i^5 \frac{S_i^{Ak} \times (100 - EER_i)}{100 - EER_i}$$

Se calcularán el nuevo  $EER_{POND}$  y el umbral  $Thres_{POND}$  correspondiente para su posterior comparación.

### Modo B: Fusión de Características

A partir de las características reducidas de Entrenamiento y Test se fusionarán para cada iteración según la validación cruzada. La discrepancia entre los tamaños de los coeficientes PCA para cada iteración, debido a que la división de los grupos de test y entrenamiento no son homogéneos para cada iteración como consecuencia de la cantidad de imágenes disponibles para clasificar cada  $A_k$  obliga a almacenar los coeficientes particulares del PCA para cada iteración.

Una vez obtenidos los nuevos vectores de características fusionados, se procederá a entrenar un clasificador adicional para cada iteración de manera idéntica a los clasificados

anteriormente, por lo que se deberán optimizar los mejores parámetros SVM para estos nuevos clasificadores y sus correspondientes Scores. Esto permite, de nuevo, obtener una puntuación para cada una de las imágenes disponibles a partir de clasificador obtenido para esa iteración y evaluar, sin sobreajustar los parámetros SVM, el comportamiento de un clasificador entrenado a partir de características fusionadas. A partir de estas Scores, se procederá a calcular el nuevo  $EER_{FUSION}$  y  $Thres_{FUSION}$  que permitirán evaluar el comportamiento de este clasificador global.

## Modo C: Mejor Clasificador Local

A partir de los resultados EER obtenidos para los clasificadores locales se utilizara el mejor de los clasificadores locales para cada Atributo  $A_k$  como benchmark sobre los Clasificadores Globales obtenidos anteriormente.

En esta etapa, adicionalmente, se puede comprobar el efecto de utilizar un Kernel distinto al lineal puesto que también se habrían almacenado las características reducidas obtenidas de la etapa de clasificación Local. La optimización de los parámetros  $C$  y  $\gamma$  sería por tanto necesaria según se detalla en la sección 3.4.3. En este trabajo se estudiara el efecto de aplicar el kernel RBF para los dos atributos que mejor y peor clasificación local obtuvieron, “Gafas de Sol” y “Mediana edad” respectivamente.

## 4.4 RESULTADOS DE LOS CLASIFICADORES GLOBALES

Se adjuntan los resultados obtenidos de evaluar cada uno de los métodos propuestos anteriormente para cada atributo  $A_k$  bajo estudio [Tabla 9]. En el Anexo B se adjuntan también las curvas EER comparativas. La elección del método elegido para la construcción final del Clasificador Global se basa en escoger aquel con menor EER, y en caso de empate, se priorizara de forma que:

$$MejorCL_K > Ponderación > Fusion.$$

Atributo	Modo Clasificador	EER Clk	Umbral	C	Accuracy
Hombre	Ponderación	12.59	0.556	-	87.55
	Fusión	13.14	0.571	'-t 0 -c 0.0625'	87.17
	<b>Mejor <math>CL_K</math></b>	<b>12.59</b>	<b>0.547</b>	<b>-</b>	<b>87.55</b>
Mujer	Ponderación	12.5	0.45	-	87.55
	Fusión	13.28	0.441	'-t 0 -c 0.0625'	86.79
	<b>Mejor Clk</b>	<b>12.5</b>	<b>0.441</b>	<b>-</b>	<b>87.55</b>

Negro	Ponderación	8.67	0.436		91.53
	Fusión	9.33	0.492	'-t 0 -c 0.0625'	90.89
	Mejor Clk	8.67	0.405		91.53
Blanco	Ponderación	12.82	0.384		87.29
	Fusión	13.46	0.491	'-t 0 -c 0.03125'	86.65
	Mejor Clk	14.1	0.371		86.02
Asiático	Ponderación	13.86	0.368		86.23
	Fusión	14.46	0.392	'-t 0 -c 0.0625'	85.59
	Mejor Clk	15.06	0.402		84.96
Gafas de Ver	Ponderación	19.46	0.33		80.6
	Fusión	19.3	0.339	-t 0 -c 0.125'	81.03
	Mejor Clk	22.15	0.34		78.02
Gafas de Sol	Ponderación	5.7	0.374		94.4
	Fusión	5.56	0.4	'-t 0 -c 0.03125'	94.61
	Mejor Clk	5.56	0.308		94.61
	Mejor Clk RBF	5.56	0.3160	'-t 2 -c 64 -g 0.002	94.61
Sin Gafas	Ponderación	7.84	0.472		92.24
	Fusión	8.5	0.554	'-t 0 -c 512'	91.59
	Mejor Clk	8.5	0.651		91.59
Sonriendo	Ponderación	9.6	0.511		90.61
	Fusión	10.56	0.527	'-t 0 -c 0.0625'	89.64
	Mejor Clk	9.6	0.482		90.61
Serio	Ponderación	8.78	0.518		91.26
	Fusión	8.78	0.535	'-t 0 -c 0.125'	91.26
	Mejor Clk	9.46	0.5		90.61
Bebe	Ponderación	10.67	0.281		89.41
	Fusión	9.58	0.316	'-t 0 -c 512'	90.57
	Mejor Clk	11.13	0.286		89.15
Niño	Ponderación	22.08	0.213		78.04
	Fusión	22.73	0.216	'-t 0 -c 0.125'	77.39
	Mejor Clk	23.38	0.217		76.87
Joven	Ponderación	21.43	0.217		78.68
	Fusión	22.73	22.727	'-t 0 -c 0.125'	77.39
	Mejor Clk	24.04	0.209		75.97
Mediana Edad	Ponderación	27.59	0.212		72.74
	Fusión	27.67	0.215	-t 0 -c 0.0625'	72.35
	Mejor Clk	31.45	0.202		68.6
	Mejor Clk RBF	28.931	0.2271	-t 2 -c 370726 - g 0.21022	71.29
Anciano	Ponderación	16.56	0.244		83.46

	<b>Fusión</b>	<b>15.51</b>	<b>0.296</b>	<b>'-t 0 -c 0.0625'</b>	<b>84.63</b>
	<b>Mejor Clk</b>	<b>19.47</b>	<b>0.245</b>		<b>80.75</b>

TABLA 9: RESULTADOS DE EVALUAR LOS CLASIFICADORES GLOBALES

A partir de los resultados obtenidos se pueden sacar varias conclusiones. En general, los métodos propuestos de clasificador global por fusión de características y por ponderación de scores ofrecen alguna mejoría o por lo menos, no empeora la clasificación respecto el mejor clasificador local. La utilización de uno u otro método implicara guardar en memoria 5 clasificadores locales y los coeficientes de las transformaciones en el que caso del clasificador global ponderado, mientras que el clasificador como concatenación de características solo requiere almacenar un clasificador. Este también sería el caso si se utilizara el mejor clasificador local como clasificador global.

La utilización de alguna de estas dos técnicas permite obtener una tasa de clasificación de entorno a 4 puntos mejor para atributos con clasificadores locales más débiles, lo que supone una mejora relativamente importante, puesto que clasificar estos atributos es una tarea complicada en cualquier caso incluso para un humano.

La mejoría no es tan amplia o no existe si se aplica sobre atributos relativamente fuertes, lo que indica que la clasificación de estos atributos mediante SVM a partir de una muestra de la base de datos Facetracer alcanza un límite en este trabajo y bajo las condiciones experimentales propuestas.

Se deduce por tanto que la aplicación de alguna de estas dos técnicas aporta valor discriminatorio para los atributos más abstractos y complejos de clasificar, como la Edad, pero no supone una mejoría importante cuando se aplican a características suficientemente discriminatorias.

Al estar utilizando las mejores características obtenidas de la etapa de clasificación local, y como estas suelen ser regiones faciales similares con distintas transformaciones, se puede deducir que la fusión de regiones faciales similares no aporta valor discriminatorio adicional. Si se comparan estos resultados con aquellos obtenidos en [3] para los atributos estudiados en común y respecto a la misma muestra de la base de datos Facetracer, obtenemos mejoría en la mayoría de los casos:

Atributo AK	Accuracy [3]	Accuracy CGk	Diferencia
Asiático	87.90	86.23	-1.67
Gafas de ver	72.10	81.03	8.93
Gafas de sol	89.00	94.61	5.61
Serio	80.00	91.26	11.26
Sin Gafas	74.80	92.24	17.44
Niño	82.80	76.87	-5.93

Mediana Edad	73.20	72.74	-0.46
Negro	80.80	91.53	10.73
Mujer	88.00	87.55	-0.45
Anciano	79.33	84.63	5.30
Joven	69.20	78.68	9.48
Blanco	76.30	87.29	10.99

Por otro lado, se puede comprobar que la utilización del Kernel RBF, aplicado sobre el atributo mejor evaluado, “Gafas de Sol” no aporta ninguna mejoría y se entiende que el Kernel lineal es suficientemente bueno para clasificar este atributo. En el caso del atributo peor clasificado, “Mediana Edad” se nota una mejoría de casi 3 puntos que de nuevo puede ser obviada. Se concluye por tanto que, pese a que el Kernel RBF permite optimizar marginalmente, el coste computacional asociado a la extracción de los parámetros optimizados del SVM correspondiente no supone una mejoría dado el tamaño relativamente compacto de las características reducidas con PCA y del relativamente pequeño número de imágenes, o instancias, con las que entrenar el clasificador, que según [4], solo merece una atención especial cuando el número de imágenes con las que entrenar, o instancias, es mucho menor que el tamaño de las características.

## 4.5 IMPLEMENTACIÓN DEL CLASIFICADOR DE ATRIBUTOS

A partir de los clasificadores globales se propone un sistema clasificador adicional que, teniendo en cuenta las características utilizadas para los clasificadores locales y el método del clasificador Global, transforman las características necesarias para cada Atributo deseado de clasificar. De esta forma, se implementa el de manera operativa un Clasificador automático de atributos capaz de puntuar cualquier imagen de entrada.

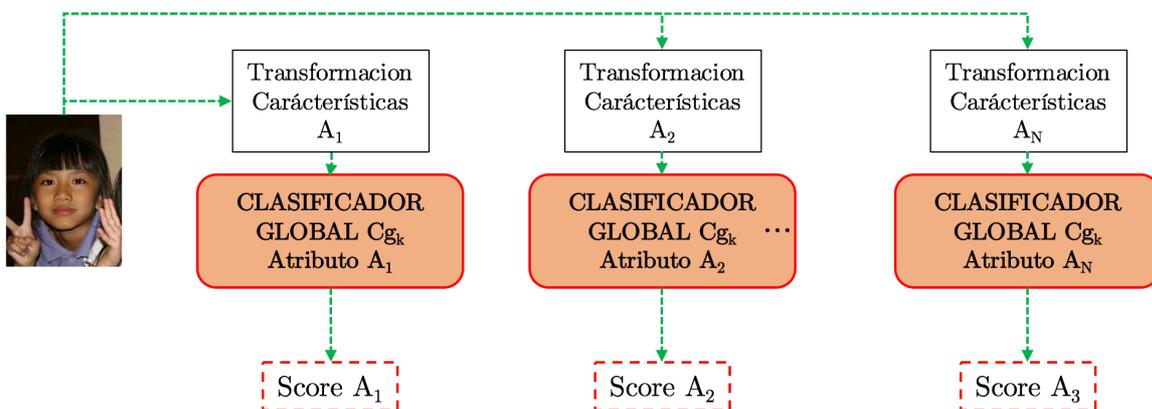


FIGURA 18: CLASIFICADOR AUTOMATICO DE ATRIBUTOS

Para ello se usaran los clasificadores obtenidos en la primera iteración de la validación cruzada para cada atributo Ak, para evitar entrenar de nuevo los PCA y SVM y con la garantía de que esos modelos están optimizados por los métodos descritos anteriormente.

De esta forma, se construirá la función `transform_clasificador_feat` que transformará cualquier imagen de entrada, y sus coordenadas oculares, según las características necesarias para entrenar el Clasificador Global del Atributo Ak, sirviéndose de los límites y coeficientes PCA extraídos y almacenados en las etapas anteriores.

Con ello se conseguirá puntuar sobre la totalidad de Atributos clasificados cualquier imagen de entrada al sistema propuesto, de manera que se llevan a la práctica y con resultados decentes los resultados extraídos en este trabajo. La puntuación obtenida se escala entre [-1,1] a partir de la construcción de un decisor que se sirve de los umbrales obtenidos en la evaluación EER, siendo los valores más positivos como clasificación positiva y viceversa. . En la figura 18 se puede ver el esquema de la implementación de este sistema.

Algunos resultados con imágenes encontradas en internet se pueden ver a continuación. [Figura 20, 21].

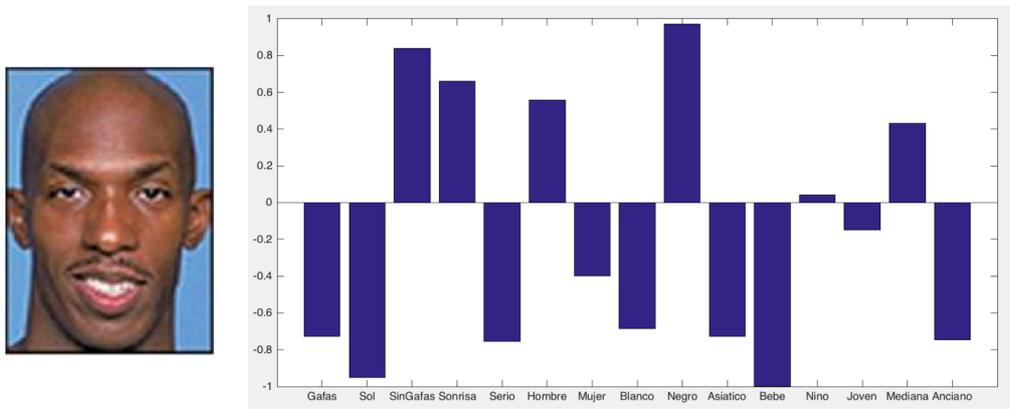


FIGURA 20: RESULTADOS DE CLASIFICACIÓN PARA HOMBRE DE RAZA NEGRA

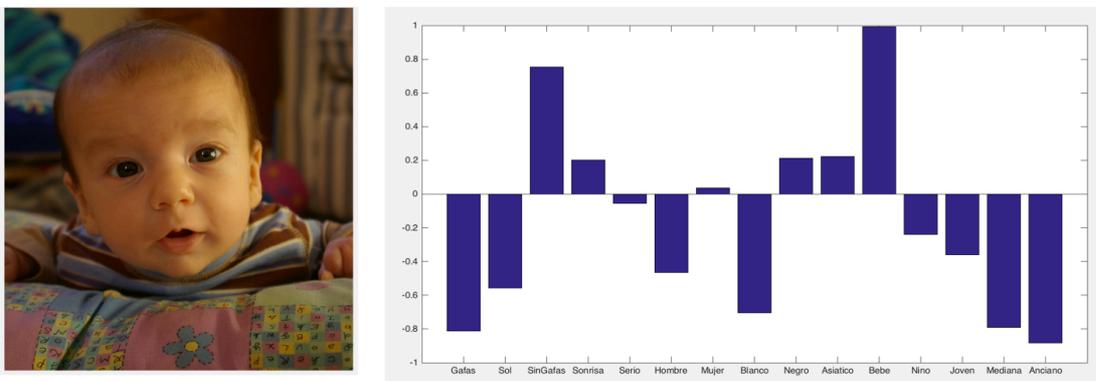


FIGURA 19: RESULTADOS DE CLASIFICACIÓN PARA BEBE

## 5 CONCLUSIONES Y TRABAJO FUTURO

### 5.1 CONCLUSIONES

El objetivo de este presente proyecto de fin de carrera ha sido examinar distintas técnicas utilizadas en la Clasificación de atributos más o menos subjetivos, de cara a producir un sistema Clasificador Automático funcional y operativo, encuadrado dentro del área de investigación del Aprendizaje Automático y de la Visión artificial.

Se examinan las ventajas y desventajas de entrenar atributos binarios mediante la extracción de una miríada de características faciales, su posterior reducción de dimensionalidad mediante el análisis de componentes principales y la clasificación SVM con parámetros optimizados.

El estudio se centra por tanto en dos partes, donde en la primera se pretende evaluar la calidad de una determinada característica como elemento diferenciador mediante la construcción de clasificadores locales. A raíz de estos resultados, en la segunda etapa se proponen diversos métodos capaces afinar los resultados sobre aquellos clasificadores locales. Se deduce que la fusión de características relevantes y la ponderación de los mejores scores ofrece un cierto grado de mejora si se comparan con los clasificadores débiles. No obstante se da preferencia a los métodos que menor tamaño de memoria requieren para clasificar.

A partir de los resultados se almacenaran los Clasificadores SVM Globales para cada atributo  $A_k$  y se implementaran en un sistema funcional capaz de extraer atributos faciales a partir de cualquier imagen de entrada.

### 5.2 TRABAJO FUTURO

A partir de los resultados obtenidos se puede comprobar que construir un Clasificador Automático de Atributos es una tarea relativamente sencilla si se conocen las características que mejor discriminan entre clases, en este caso Atributos.

Por otro lado, la elección de estos Atributos afecta directamente el grado con el que es posible discriminarlos. A la vista de los resultados, se puede apreciar que la definición de algunos Atributos, en especial los de rango de edad, se quedan especialmente vagos y abstractos. Sería quizás más apropiado concretizar y discretizar los rangos de edad todavía mas, de forma que los Atributos de edad peor clasificados se pudieran descomponer en rangos de edad todavía más estrictos para mejorar la clasificación. De la misma forma, atributos relacionados con la Raza, parecen ser demasiado vagos en algunos casos. A modo de ejemplo, se entiende “Asiático” tanto a la etnia India como a la China. La elección de la definición de las clases a clasificar por tanto es un punto fundamental.

Utilizar la base de datos Facetracer conllevó por un lado la rápida disponibilidad de un conjunto de atributos etiquetadas sobre una muestra relativamente saludable de instancias, pero por tratarse de imágenes sacadas de internet muchas de las imágenes han debido descartarse por estar mal descargadas. Adicionalmente, se encontró también que había imágenes que estaban mal etiquetadas, probablemente debido al cambio de URL's donde se encontraban alojadas que han afectado algunos resultados. Es la esperanza y firme convicción del autor que los resultados se podrían mejorar de utilizarse una fuente con mayor cantidad de imágenes etiquetadas y de mejor calidad.

La implementación funcional de un Clasificador Automático de atributos permite extraer una cantidad de información en forma de atributos faciales que está en línea con las tendencias Analíticas del presente. La capacidad de extraer información oculta es un tema de especial relevancia en el mundo del BigData, exacerbado con la reciente democratización de tecnologías de Aprendizaje Profundo, o Deep Learning.

Por ello las siguientes propuestas quedan planteadas para optimizar la tasa de clasificación.

- Discretización más exhaustiva de los atributos clasificados, de forma que la separación entre clases se traslada también a la elección de las mismas.
- Mejorar la elección de las regiones faciales descompuestas, ya que predomina la región facial. Se deberían construir regiones faciales más generosas en solapamiento
- La elección de características por otro lado quedaría en un plano secundario de utilizarse tecnología de clasificación más avanzada, como pueden ser las Redes Neuronales. Existen una variedad de herramientas disponibles, como TensorFlow de Google, que permitirían Clasificar clases binarias dejando la selección de características en un segundo plano, de ahí que se le conozca como tecnologías de Aprendizaje No Supervisado.



## REFERENCIAS

1. N. Kumar, P. N. Belhumeur, and S. K. Nayar. Face- Tracer: A Search Engine for Large Collections of Im- ages with Faces. In European Conference on Com- puter Vision (ECCV), pages 340–353, Oct 2008.
2. N.Kumar, A.C.Berg,P.N.Belhumeur,andS.K.Na- yar. Attribute and Simile Classifiers for Face Verification. In IEEE International Conference on Computer Vision (ICCV), Oct 2009.
3. P. Samangouei, V. M. Patel and R. Chellappa, "Attribute-based continuous user authentication on mobile devices," Biometrics Theory, Applications and Systems (BTAS), 2015 IEEE 7th International Conference on, Arlington, VA, 2015, pp. 1-8.
4. Chih-Chung Chang and Chih-Jen Lin, LIBSVM : a library for support vector machines. ACM Transactions on Intelligent Systems and Technology, 2:27:1--27:27, 2011.
5. B. E. Boser, I. Guyon, and V. Vapnik. A training algorithm for optimal margin classifiers. In Proceedings of the Fifth Annual Workshop on Computational Learning Theory, pages 144–152. ACM Press, 1992.
6. C. Cortes and V. Vapnik. Support-vector network. Machine Learning, 20:273–297, 1995.
7. Luis Blázquez Pérez, "Reconocimiento Facial Basado en Puntos Característicos de la Cara en entornos no controlados"
8. Christiannini, N., and J. Shawe-Taylor. "Support vector machines and other kernel-based learning methods." (2000).
9. L. Sirovich and M. Kirby. Low dimensional procedure for the characterization of human faces. Journal of optical society of America, vol. 4(no.3):519–524, 1987.
10. Pentland M. Turk. Eingenfaces for recognition. Cognitive Neuroscience, (3):72–86, 1991.
11. J.P. Hespanha P.L. Belhumeur and D.J. Kriegman. Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection. IEEE Trans. on PAMI, vol. 19, no.7, 1997.
12. C. Malsburg L. Wiskott, N. Kruger. Face recognition by elastic bunch graph matching. 1999.
13. Moghaddam, B., Yang, M.H.: Learning gender with support faces. TPAMI 24(5) (2002) 707–711

14. Shakhnarovich, G., Viola, P., Moghaddam, B.: A unified learning framework for real time face detection and classification. ICAFGR (2002) 14–21
15. Viola, P., Jones, M.: Rapid object detection using a boosted cascade of simple features. CVPR (2001)
16. M. E. Fathy, V. M. Patel, and R. Chellappa. Face- based active authentication on mobile devices. In IEEE International Conference on Acoustics, Speech and Signal Processing, 2015.
17. T. Ahonen, A. Hadid, and M. Pietikainen. Face de- scription with local binary patterns: Application to face recognition. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 28(12):2037–2041, 2006.

## APENDICE

### A RESULTADOS AMPLIADOS DE LOS CLASIFICADORES LOCALES

#### HOMBRE

Características	EER Clk	Umbral	C	Accuracy
'wrnn'	12.59	0.550	'-t 0 -c 0.25'	87.55
'wren'	13.42	0.540	'-t 0 -c 0.5'	86.79
'wrnn'	13.87	0.590	'-t 0 -c 0.5'	86.42
'wimn'	16.06	0.590	'-t 0 -c 0.25'	84.15
'wien'	16.06	0.550	'-t 0 -c 0.25'	84.15
'winn'	16.06	0.580	'-t 0 -c 1'	84.15
'whnn'	16.75	0.570	'-t 0 -c 1'	83.77
'wmmn'	16.75	0.520	'-t 0 -c 1'	83.77
'einn'	16.75	0.620	'-t 0 -c 0.25'	83.77
'whmn'	16.79	0.540	'-t 0 -c 2'	83.4
'nrnn'	16.79	0.510	'-t 0 -c 0.125'	83.4
'nhen'	17.52	0.520	'-t 0 -c 0.125'	82.64
'nrmn'	17.52	0.540	'-t 0 -c 0.125'	82.64
'when'	18.25	0.530	'-t 0 -c 4'	81.89
'wmnn'	18.25	0.520	'-t 0 -c 0.25'	81.89

#### MUJER

Características	EER Clk	Umbral	C	Accuracy
'wrnn'	12.5	0.440	'-t 0 -c 0.25'	87.55
'wren'	13.28	0.470	'-t 0 -c 0.25'	86.79
'wrnn'	14.06	0.420	'-t 0 -c 0.5'	86.04
'wimn'	16.41	0.410	'-t 0 -c 0.25'	83.77
'wien'	16.41	0.460	'-t 0 -c 0.25'	83.77
'winn'	16.41	0.420	'-t 0 -c 1'	83.77
'whmn'	16.41	0.480	'-t 0 -c 4'	83.77
'nrmn'	16.41	0.460	'-t 0 -c 0.125'	83.77
'whnn'	17.17	0.480	'-t 0 -c 0.0625'	83.4
'wmmn'	17.19	0.480	'-t 0 -c 1'	83.02
'nrnn'	17.19	0.510	'-t 0 -c 0.125'	83.02
'einn'	17.85	0.380	'-t 0 -c 0.25'	82.64
'nhen'	17.85	0.490	'-t 0 -c 0.5'	82.64
'when'	17.97	0.440	'-t 0 -c 0.5'	82.26
'ernn'	17.97	0.410	'-t 0 -c 0.25'	82.26

NEGRO

Características	EER Clk	Umbral	C	Accuracy
'whmn'	8.67	0.400	'-t 0 -c 0.25'	91.53
'whnn'	9.33	0.390	'-t 0 -c 1'	90.68
'wren'	10.5	0.500	'-t 0 -c 0.125'	89.83
'when'	10.67	0.370	'-t 0 -c 0.5'	89.41
'wrnn'	11.33	0.430	'-t 0 -c 0.0039062'	88.77
'wrnn'	11.33	0.470	'-t 0 -c 0.25'	88.77
'winn'	12.67	0.360	'-t 0 -c 2'	87.5
'kren'	13.33	0.360	'-t 0 -c 0.25'	86.86
'krnn'	14	0.300	'-t 0 -c 8'	86.02
'nhnn'	14.67	0.340	'-t 0 -c 4'	85.38
'krnn'	14.67	0.330	'-t 0 -c 1'	85.38
'wimn'	15.15	0.400	'-t 0 -c 0.125'	85.17
'nhen'	15.33	0.330	'-t 0 -c 2'	84.75
'nren'	15.33	0.450	'-t 0 -c 0.125'	84.75
'nrnn'	15.33	0.360	'-t 0 -c 4'	84.75

BLANCO

Características	EER Clk	Umbral	C	Accuracy
'when'	14.1	0.370	'-t 0 -c 0.5'	86.02
'whnn'	14.1	0.370	'-t 0 -c 0.5'	86.02
'wrnn'	14.74	0.340	'-t 0 -c 16'	85.38
'whmn'	16.03	0.390	'-t 0 -c 0.5'	84.11
'wren'	17.5	0.390	'-t 0 -c 0.0625'	82.63
'wien'	17.95	0.350	'-t 0 -c 2048'	82.2
'wrnn'	18.59	0.340	'-t 0 -c 2048'	81.57
'brnn'	18.59	0.320	'-t 0 -c 8'	81.57
'wimn'	19.87	0.350	'-t 0 -c 4'	80.3
'winn'	19.87	0.310	'-t 0 -c 2048'	80.3
'nrnn'	19.87	0.290	'-t 0 -c 1'	80.3
'hrnn'	20	0.350	'-t 0 -c 0.0039062'	80.08
'wmmn'	20.51	0.350	'-t 0 -c 1'	79.66
'hren'	20.51	0.360	'-t 0 -c 0.125'	79.66
'frnn'	20.51	0.330	'-t 0 -c 0.5'	79.66

### ASIATICO

Características	EER Clk	Umbral	C	Accuracy
'wrmn'	15.06	15.060	'-t 0 -c 0.125'	84.96
'wren'	15.66	15.660	'-t 0 -c 0.5'	84.53
'whnn'	16.87	16.870	'-t 0 -c 0.5'	83.26
'when'	17.47	17.470	'-t 0 -c 2'	82.63
'winn'	17.82	17.820	'-t 0 -c 1'	82.42
'whmn'	17.82	17.820	'-t 0 -c 0.25'	82.42
'wrnn'	17.82	17.820	'-t 0 -c 0.25'	82.42
'wimn'	18.07	18.070	'-t 0 -c 0.0019531'	81.99
'wien'	18.07	18.070	'-t 0 -c 0.5'	81.99
'nhmn'	19.28	19.280	'-t 0 -c 2'	80.93
'nhnn'	19.28	19.280	'-t 0 -c 2'	80.93
'wonn'	19.88	19.880	'-t 0 -c 0.25'	80.3
'nhen'	19.88	19.880	'-t 0 -c 8'	80.3
'nren'	19.88	19.880	'-t 0 -c 0.25'	80.3
'nrnn'	19.99	19.990	'-t 0 -c 2'	80.08

### GAFAS DE VER

Características	EER Clk	Umbral	C	Accuracy
'when'	22.15	22.150	'-t 0 -c 0.5'	78.02
'hmen'	22.15	22.150	'-t 0 -c 512'	78.02
'whnn'	22.82	22.820	'-t 0 -c 0.5'	77.37
'whmn'	24.13	24.130	'-t 0 -c 0.5'	76.29
'nhen'	24.13	24.130	'-t 0 -c 4'	76.29
'nhnn'	24.13	24.130	'-t 0 -c 2'	76.29
'hmnn'	24.16	24.160	'-t 0 -c 4'	75.86
'wrmn'	24.83	24.830	'-t 0 -c 1'	75.22
'hmmn'	24.83	24.830	'-t 0 -c 1'	75.22
'wrnn'	25.33	25.330	'-t 0 -c 512'	75
'wren'	25.5	25.500	'-t 0 -c 2'	74.57
'nhmn'	25.5	25.500	'-t 0 -c 4'	74.57
'wmmn'	26.17	26.170	'-t 0 -c 0.25'	73.92
'wmen'	26.52	26.520	'-t 0 -c 8'	73.71
'wien'	26.85	26.850	'-t 0 -c 512'	73.28

### GAFAS DE SOL

Características	EER Clk	Umbral	C	Accuracy
'wimn'	5.56	0.310	'-t 0 -c 0.25'	94.61
'wren'	5.56	0.360	'-t 0 -c 0.25'	94.61
'wrmn'	5.7	0.330	'-t 0 -c 0.25'	94.4
'wien'	6.17	0.420	'-t 0 -c 0.125'	93.97
'ninn'	6.17	0.350	'-t 0 -c 2'	93.97
'nrmn'	6.79	0.410	'-t 0 -c 0.0625'	93.32
'nren'	6.79	0.520	'-t 0 -c 0.0019531'	93.32
'hien'	7.12	0.400	'-t 0 -c 2'	93.1
'nrnn'	7.12	0.330	'-t 0 -c 2'	93.1
'whmn'	7.41	0.340	'-t 0 -c 0.125'	92.67
'when'	7.41	0.360	'-t 0 -c 512'	92.67
'whnn'	7.41	0.410	'-t 0 -c 0.125'	92.67
'wrnn'	7.41	0.270	'-t 0 -c 0.5'	92.67
'nhen'	7.41	0.400	'-t 0 -c 0.25'	92.67
'hmmn'	7.82	0.390	'-t 0 -c 0.5'	92.46

### SIN GAFAS

Características	EER Clk	Umbral	C	Accuracy
'nmen'	8.5	0.650	'-t 0 -c 0.0625'	91.59
'wmmn'	9.15	0.410	'-t 0 -c 1'	90.95
'wmnn'	10.13	0.360	'-t 0 -c 32'	90.09
'nmmn'	10.13	0.410	'-t 0 -c 0.5'	90.09
'wmen'	10.46	0.440	'-t 0 -c 0.5'	89.66
'nmnn'	13.73	0.360	'-t 0 -c 512'	86.42
'hmen'	15.69	0.370	'-t 0 -c 1'	84.48
'hmmn'	15.82	0.360	'-t 0 -c 0.5'	84.27
'emen'	16.99	0.390	'-t 0 -c 1'	83.19
'when'	17.65	0.370	'-t 0 -c 0.5'	82.54
'hmnn'	17.65	0.360	'-t 0 -c 0.5'	82.54
'emnn'	17.72	0.350	'-t 0 -c 0.5'	82.33
'whmn'	18.3	0.350	'-t 0 -c 4'	81.9
'nren'	18.36	0.380	'-t 0 -c 0.5'	81.68
'wren'	19.61	0.330	'-t 0 -c 2'	80.6

### SONRIENDO

Características	EER Clk	Umbral	C	Accuracy
'wien'	9.6	0.480	'-t 0 -c 0.25'	90.61
'wimn'	11.18	0.510	'-t 0 -c 0.5'	89
'winn'	11.79	0.500	'-t 0 -c 1'	89
'mrnn'	11.79	0.510	'-t 0 -c 1'	88.67
'wren'	12.42	0.480	'-t 0 -c 0.25'	87.7
'wmmn'	12.42	0.490	'-t 0 -c 0.25'	87.7
'nrnn'	12.42	0.500	'-t 0 -c 2'	87.7
'nmmn'	12.42	0.540	'-t 0 -c 0.5'	87.7
'minn'	12.42	0.530	'-t 0 -c 1'	87.7
'wrnn'	13.04	0.480	'-t 0 -c 1'	87.06
'wrmn'	13.66	0.500	'-t 0 -c 0.5'	86.73
'wmen'	13.66	0.530	'-t 0 -c 0.125'	86.41
'ninn'	13.66	0.490	'-t 0 -c 2'	86.41
'nmen'	13.66	0.580	'-t 0 -c 0.125'	86.41
'woen'	14.29	0.510	'-t 0 -c 2048'	85.76

SERIO

Características	EER Clk	Umbral	C	Accuracy
'wien'	9.46	0.500	'-t 0 -c 0.5'	90.61
'nrnn'	11.49	0.490	'-t 0 -c 2'	88.67
'mrnn'	12.12	0.490	'-t 0 -c 1'	88.35
'winn'	12.16	0.490	'-t 0 -c 1'	88.03
'wrnn'	12.16	0.490	'-t 0 -c 0.5'	88.03
'minn'	12.16	0.480	'-t 0 -c 1'	88.03
'wimn'	12.68	0.500	'-t 0 -c 0.5'	87.7
'wrmn'	12.68	0.490	'-t 0 -c 0.5'	87.7
'wren'	12.68	0.530	'-t 0 -c 0.25'	87.7
'wmmn'	12.84	0.520	'-t 0 -c 0.25'	87.38
'ninn'	13.25	0.470	'-t 0 -c 1'	87.06
'nmmn'	13.51	0.470	'-t 0 -c 1'	86.73
'wmen'	13.82	0.480	'-t 0 -c 8'	86.41
'nmen'	13.82	0.430	'-t 0 -c 0.25'	86.41
'woen'	14.38	0.500	'-t 0 -c 2048'	86.08

BEBE

Características	EER Clk	Umbral	C	Accuracy
-----------------	---------	--------	---	----------

'wren'	11.13	0.290	'-t 0 -c 0.125'	89.15
'whmn'	12	0.300	'-t 0 -c 0.25'	88.11
'when'	12	0.240	'-t 0 -c 0.5'	88.11
'wmmn'	12	0.230	'-t 0 -c 2048'	88.11
'nren'	12	0.210	'-t 0 -c 0.25'	88.11
'nrnn'	12	0.200	'-t 0 -c 0.5'	88.11
'wimn'	12.67	0.230	'-t 0 -c 0.5'	87.47
'wrnn'	12.67	0.180	'-t 0 -c 1'	87.34
'wmen'	12.97	0.270	'-t 0 -c 0.5'	87.21
'whnn'	13.29	0.280	'-t 0 -c 0.0039062'	87.08
'wien'	13.33	0.220	'-t 0 -c 0.5'	86.69
'wmnn'	13.33	0.250	'-t 0 -c 0.5'	86.69
'woen'	13.33	0.250	'-t 0 -c 0.25'	86.69
'ninn'	13.33	0.170	'-t 0 -c 0.5'	86.69
'nhmn'	13.59	0.250	'-t 0 -c 1'	86.56

### NIÑO

Características	EER Clk	Umbral	C	Accuracy
'wrmn'	23.38	0.220	'-t 0 -c 0.25'	76.87
'wrnn'	24.03	0.200	'-t 0 -c 2'	76.1
'nrnn'	24.03	0.200	'-t 0 -c 1'	76.1
'winn'	24.68	0.200	'-t 0 -c 0.5'	75.45
'wren'	24.68	0.210	'-t 0 -c 0.5'	75.45
'wimn'	25.32	0.210	'-t 0 -c 0.25'	74.68
'wien'	25.32	0.210	'-t 0 -c 0.0625'	74.68
'ninn'	25.97	0.200	'-t 0 -c 2'	74.42
'nren'	26.62	0.200	'-t 0 -c 1'	73.39
'nien'	26.93	0.200	'-t 0 -c 0.5'	73.26
'nhen'	27.92	0.200	'-t 0 -c 1'	72.09
'nhnn'	27.92	0.200	'-t 0 -c 2'	72.09
'nrmn'	27.92	0.210	'-t 0 -c 1'	72.22
'whmn'	28.57	0.200	'-t 0 -c 8'	71.45
'nhmn'	28.57	0.200	'-t 0 -c 16'	71.45

### JOVEN

Características	EER Clk	Umbral	C	Accuracy
'wrnn'	24.04	0.210	'-t 0 -c 0.5'	75.97
'wren'	25.32	0.200	'-t 0 -c 1'	74.68
'wimn'	26.62	0.210	'-t 0 -c 0.25'	73.39
'kren'	26.93	0.200	'-t 0 -c 1'	73.26
'wrnn'	27.27	0.200	'-t 0 -c 0.25'	72.74
'winn'	27.57	0.200	'-t 0 -c 1'	72.61
'wien'	28.21	0.210	'-t 0 -c 0.015625'	71.96
'ninn'	28.85	0.200	'-t 0 -c 0.0078125'	71.32
'mren'	28.85	0.210	'-t 0 -c 0.125'	71.32
'krmn'	29.17	0.200	'-t 0 -c 4'	71.19
'wmen'	29.22	0.210	'-t 0 -c 0.125'	70.8
'nrnn'	29.22	0.190	'-t 0 -c 0.5'	70.8
'mrnn'	29.22	0.220	'-t 0 -c 256'	70.8
'ernn'	29.49	0.200	'-t 0 -c 2'	70.67
'whmn'	29.81	0.190	'-t 0 -c 4'	70.54

### MEDIANA EDAD

Características	EER Clk	Umbral	C	Accuracy
'nren'	31.45	0.200	'-t 0 -c 0.25'	68.6
'mrmn'	31.45	0.210	'-t 0 -c 16'	68.6
'woen'	31.64	0.210	'-t 0 -c 0.125'	68.48
'winn'	32.08	0.210	'-t 0 -c 0.5'	67.96
'wren'	32.08	0.210	'-t 0 -c 0.25'	67.96
'wonn'	32.08	0.210	'-t 0 -c 0.5'	67.96
'nrnn'	32.08	0.200	'-t 0 -c 4'	67.96
'mren'	32.08	0.200	'-t 0 -c 0.0039062'	67.96
'mrnn'	32.08	0.210	'-t 0 -c 256'	67.96
'minn'	32.31	0.200	'-t 0 -c 0.5'	67.83
'wrnn'	32.7	0.210	'-t 0 -c 0.25'	67.31
'nrnn'	32.7	0.200	'-t 0 -c 4'	67.31
'nien'	32.99	0.200	'-t 0 -c 0.125'	67.18
'wimn'	33.33	0.210	'-t 0 -c 0.5'	66.67
'wien'	33.33	0.210	'-t 0 -c 0.25'	66.67

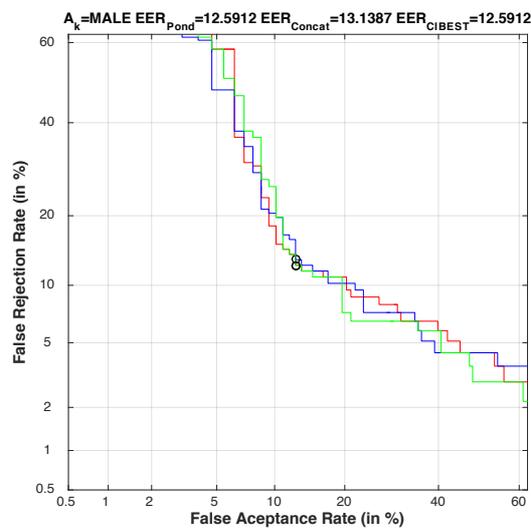
### ANCIANO

Características	EER Clk	Umbral	C	Accuracy
'wren'	19.47	0.240	'-t 0 -c 0.0019531'	80.75
'whmn'	19.75	0.230	'-t 0 -c 0.5'	80.36
'wrnn'	19.75	0.250	'-t 0 -c 0.25'	80.36
'hhen'	19.75	0.210	'-t 0 -c 2'	80.36
'hhnn'	19.75	0.220	'-t 0 -c 0.5'	80.36
'wien'	20.38	0.250	'-t 0 -c 0.125'	79.72
'when'	20.38	0.230	'-t 0 -c 0.25'	79.72
'wrnn'	20.38	0.220	'-t 0 -c 0.25'	79.72
'wmmn'	20.38	0.230	'-t 0 -c 1'	79.72
'wmen'	20.38	0.220	'-t 0 -c 1'	79.72
'wimn'	21.66	0.220	'-t 0 -c 0.5'	78.42
'wmnn'	21.66	0.220	'-t 0 -c 0.5'	78.55
'nhen'	21.66	0.230	'-t 0 -c 1'	78.42
'winn'	22.29	0.180	'-t 0 -c 32'	77.78
'whnn'	22.29	0.200	'-t 0 -c 4'	77.78

## B RESULTADOS AMPLIADOS CLASIFICADORES GLOBALES

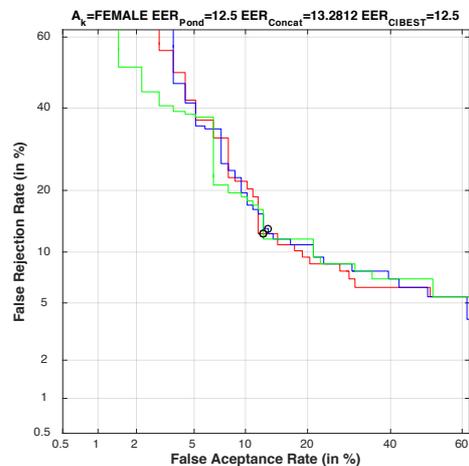
### HOMBRE

Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>12.59124088</b>	<b>0.556392986</b>	-	<b>87.54716981</b>
Fusion	13.13868613	0.570817723	'-t 0 -c 0.0625'	87.16981132
Mejor Clk	12.59124088	0.547289726	-	87.54716981



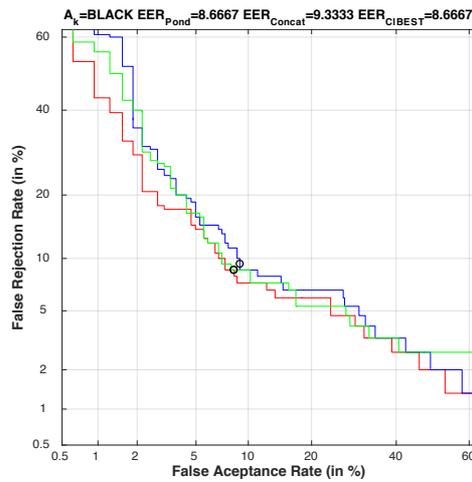
### MUJER

Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>12.50</b>	<b>0.450</b>	-	<b>87.55</b>
Fusion	13.28	0.441	'-t 0 -c 0.0625'	86.79
Mejor Clk	12.50	0.441	-	87.55



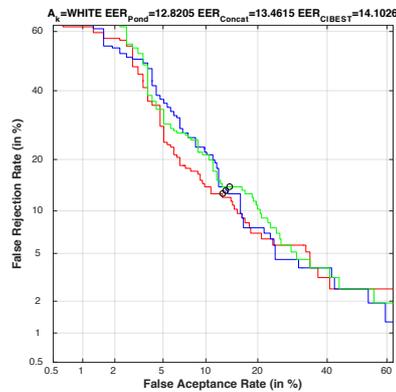
## NEGRO

Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>8.67</b>	<b>0.436</b>		<b>91.53</b>
Fusion	9.33	0.492	'-t 0 -c 0.0625'	90.89
Mejor Clk	8.67	0.405		91.53



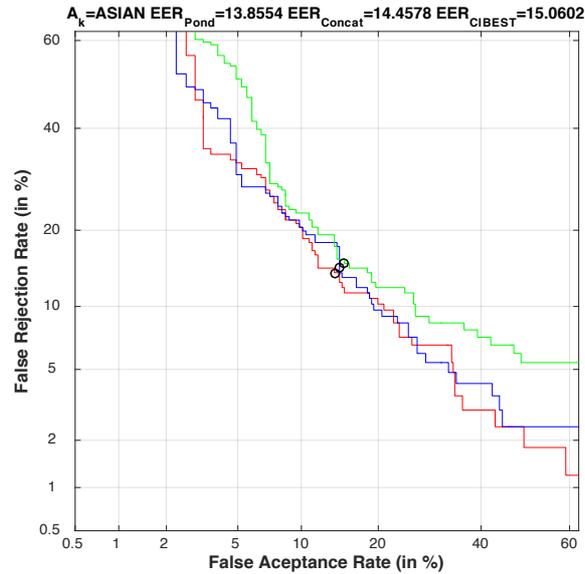
## BLANCO

Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>12.82</b>	<b>0.384</b>		<b>87.29</b>
Fusion	13.46	0.491	'-t 0 -c 0.03125'	86.65
Mejor Clk	14.10	0.371		86.02



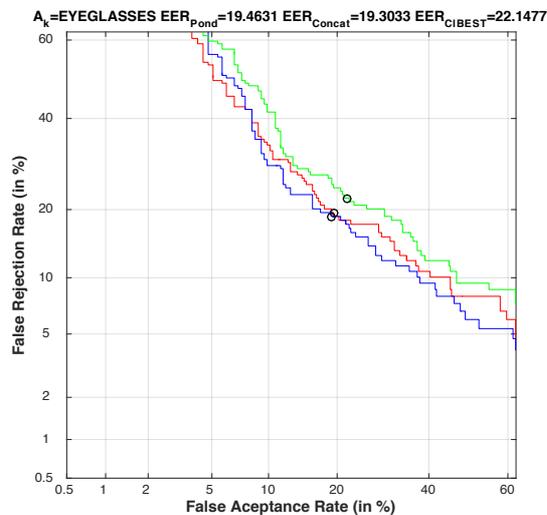
## ASIATICO

Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>13.86</b>	<b>0.368</b>		<b>86.23</b>
Fusion	14.46	0.392	'-t 0 -c 0.0625'	85.59
Mejor Clk	15.06	0.402		84.96



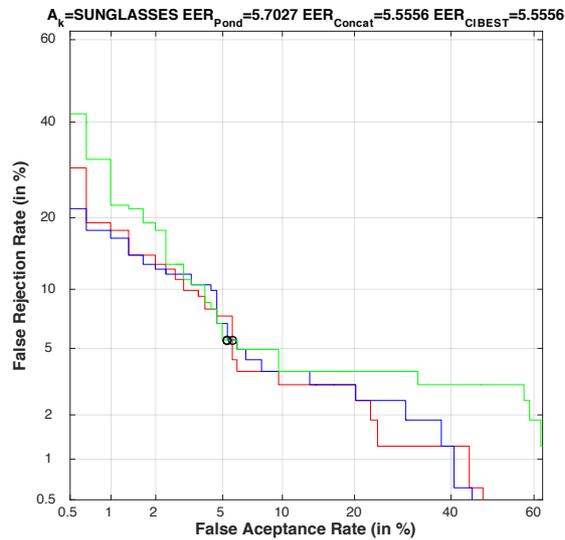
### GAFAS DE VER

Modo Clasificador	EER Clk	Umbral	C	Accuracy
Ponderacion	19.46	0.330		80.60
<b>Fusion</b>	<b>19.30</b>	<b>0.339</b>	<b>-t 0 -c 0.125'</b>	<b>81.03</b>
Mejor Clk	22.15	0.340		78.02



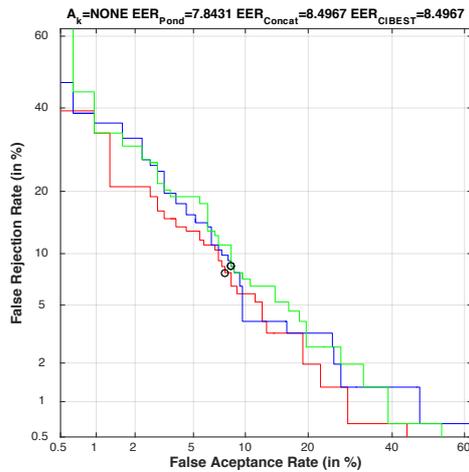
### GAFAS DE SOL

Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>5.70</b>	<b>0.374</b>		<b>94.40</b>
Fusion	5.56	0.400	'-t 0 -c 0.03125'	94.61
Mejor Clk	5.56	0.308		94.61



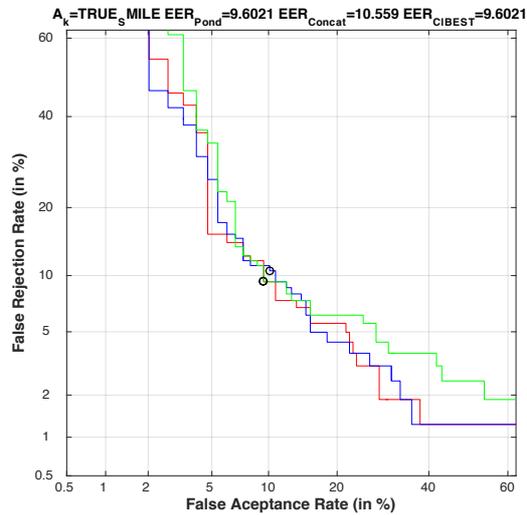
### SIN GAFAS

Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>7.84</b>	<b>0.472</b>		<b>92.24</b>
Fusion	8.50	0.554	'-t 0 -c 512'	91.59
Mejor Clk	8.50	0.651		91.59



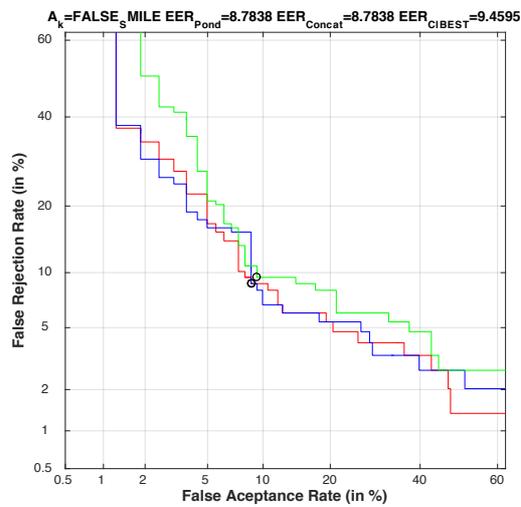
### SONRIENDO

Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>9.60</b>	<b>0.511</b>		<b>90.61</b>
Fusion	10.56	0.527	'-t 0 -c 0.0625'	89.64
Mejor Clk	9.60	0.482		90.61



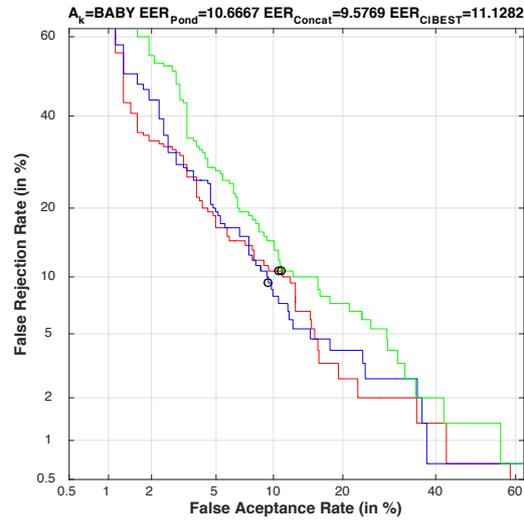
### SERIO

Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>8.78</b>	<b>0.518</b>		<b>91.26</b>
Fusion	8.78	0.535	'-t 0 -c 0.125'	91.26
Mejor Clk	9.46	0.500		90.61



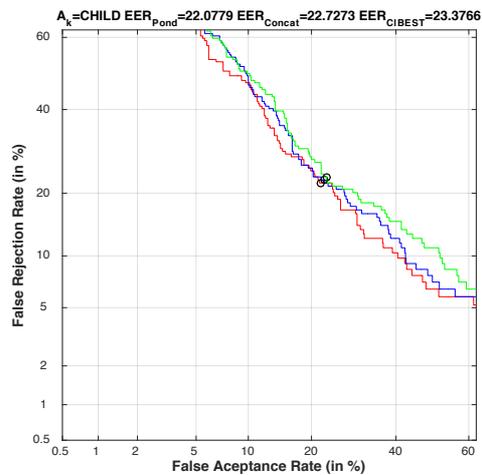
### BEBE

Modo Clasificador	EER Clk	Umbral	C	Accuracy
Ponderacion	10.67	0.281		89.41
<b>Fusion</b>	<b>9.58</b>	<b>0.316</b>	'-t 0 -c 512'	<b>90.57</b>
Mejor Clk	11.13	0.286		89.15



### NIÑO

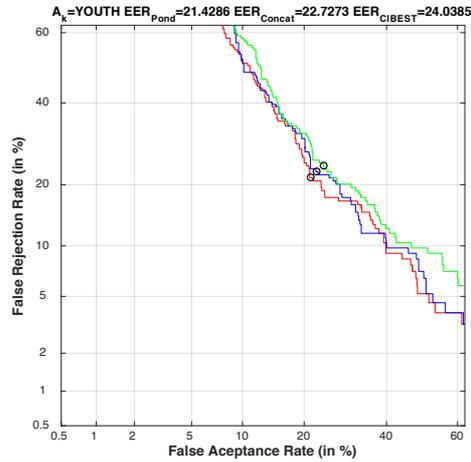
Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>22.08</b>	<b>0.213</b>		<b>78.04</b>
Fusion	22.73	0.216	'-t 0 -c 0.125'	77.39
Mejor Clk	23.38	0.217		76.87



### JOVEN

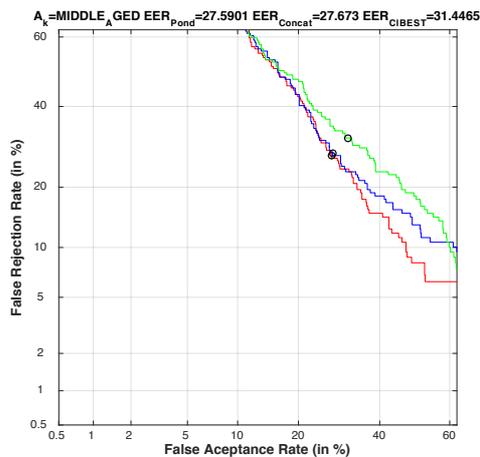
Modo Clasificador	EER Clk	Umbral	C	Accuracy
-------------------	---------	--------	---	----------

<b>Ponderacion</b>	<b>21.43</b>	<b>0.217</b>		<b>78.68</b>
Fusion	22.73	22.727	'-t 0 -c 0.125'	77.39
Mejor Clk	24.04	0.209		75.97



### MEDIANA EDAD

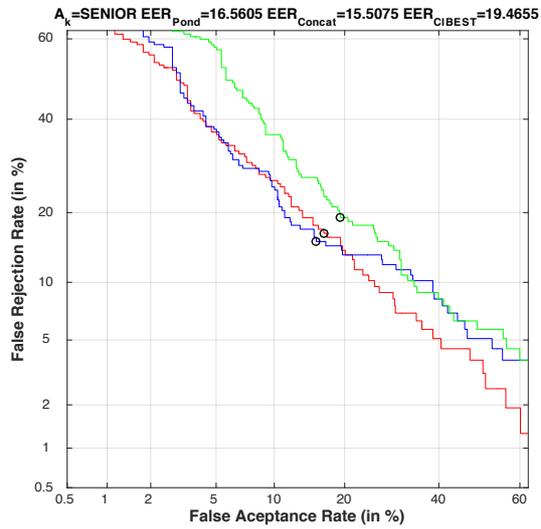
Modo Clasificador	EER Clk	Umbral	C	Accuracy
<b>Ponderacion</b>	<b>27.59</b>	<b>0.212</b>		<b>72.74</b>
Fusion	27.67	0.215	'-t 0 -c 0.0625'	72.35
Mejor Clk	31.45	0.202		68.60



### ANCIANO

Modo Clasificador	EER Clk	Umbral	C	Accuracy

Ponderacion	16.56	0.244		83.46
Fusion	15.51	0.296	'-t 0 -c 0.0625'	84.63
Mejor Clk	19.47	0.245		80.75





## PRESUPUESTO

- 1) Ejecución Material
  - Compra de ordenador personal (Software incluido)..... 2.000 €
  - Alquiler de impresora láser durante 3 meses..... 50 €
  - Material de oficina ..... 150 €
  - Total de ejecución material..... 2.200 €
  
- 2) Gastos generales
  - 16 % sobre Ejecución Material ..... 352 €
  
- 3) Beneficio Industrial
  - 6 % sobre Ejecución Material ..... 132 €
  
- 4) Honorarios Proyecto
  - 640 horas a 15 € / hora..... 9600 €
  
- 5) Material fungible
  - Gastos de impresión..... 60 €
  - Encuadernación ..... 200 €
  
- 6) Subtotal del presupuesto
  - Subtotal Presupuesto..... 12060 €
  
- 7) I.V.A. aplicable
  - 16% Subtotal Presupuesto ..... 1929,6 €
  
- 8) Total presupuesto
  - Total Presupuesto..... 13989,6 €

Madrid, Julio de 2016

El Ingeniero Jefe de Proyecto

Fdo.: Alejandro Hidalgo Fernández-Cavada  
Ingeniero de Telecomunicación

## PLIEGO DE CONDICIONES

Este documento contiene las condiciones legales que guiarán la realización, en este proyecto, de un CLASIFICADOR DE ATRIBUTOS FACIALES A PARTIR DE IMÁGENES EN ENTORNOS NO CONTROLADOS. En lo que sigue, se supondrá que el proyecto ha sido encargado por una empresa cliente a una empresa consultora con la finalidad de realizar dicho sistema. Dicha empresa ha debido desarrollar una línea de investigación con objeto de elaborar el proyecto. Esta línea de investigación, junto con el posterior desarrollo de los programas está amparada por las condiciones particulares del siguiente pliego.

Supuesto que la utilización industrial de los métodos recogidos en el presente proyecto ha sido decidida por parte de la empresa cliente o de otras, la obra a realizar se regulará por las siguientes:

### Condiciones generales

1. La modalidad de contratación será el concurso. La adjudicación se hará, por tanto, a la proposición más favorable sin atender exclusivamente al valor económico, dependiendo de las mayores garantías ofrecidas. La empresa que somete el proyecto a concurso se reserva el derecho a declararlo desierto.
2. El montaje y mecanización completa de los equipos que intervengan será realizado totalmente por la empresa licitadora.
3. En la oferta, se hará constar el precio total por el que se compromete a realizar la obra y el tanto por ciento de baja que supone este precio en relación con un importe límite si este se hubiera fijado.
4. La obra se realizará bajo la dirección técnica de un Ingeniero Superior de Telecomunicación, auxiliado por el número de Ingenieros Técnicos y Programadores que se estime preciso para el desarrollo de la misma.
5. Aparte del Ingeniero Director, el contratista tendrá derecho a contratar al resto del personal, pudiendo ceder esta prerrogativa a favor del Ingeniero Director, quien no estará obligado a aceptarla.
6. El contratista tiene derecho a sacar copias a su costa de los planos, pliego de condiciones y presupuestos. El Ingeniero autor del proyecto autorizará con su firma las copias solicitadas por el contratista después de confrontarlas.

7. Se abonará al contratista la obra que realmente ejecute con sujeción al proyecto que sirvió de base para la contratación, a las modificaciones autorizadas por la superioridad o a las órdenes que con arreglo a sus facultades le hayan comunicado por escrito al Ingeniero Director de obras siempre que dicha obra se haya ajustado a los preceptos de los pliegos de condiciones, con arreglo a los cuales, se harán las modificaciones y la valoración de las diversas unidades sin que el importe total pueda exceder de los presupuestos aprobados. Por consiguiente, el número de unidades que se consignan en el proyecto o en el presupuesto, no podrá servirle de fundamento para entablar reclamaciones de ninguna clase, salvo en los casos de rescisión.

8. Tanto en las certificaciones de obras como en la liquidación final, se abonarán los trabajos realizados por el contratista a los precios de ejecución material que figuran en el presupuesto para cada unidad de la obra.

9. Si excepcionalmente se hubiera ejecutado algún trabajo que no se ajustase a las condiciones de la contrata pero que sin embargo es admisible a juicio del Ingeniero Director de obras, se dará conocimiento a la Dirección, proponiendo a la vez la rebaja de precios que el Ingeniero estime justa y si la Dirección resolviera aceptar la obra, quedará el contratista obligado a conformarse con la rebaja acordada.

10. Cuando se juzgue necesario emplear materiales o ejecutar obras que no figuren en el presupuesto de la contrata, se evaluará su importe a los precios asignados a otras obras o materiales análogos si los hubiere y cuando no, se discutirán entre el Ingeniero Director y el contratista, sometiéndolos a la aprobación de la Dirección. Los nuevos precios convenidos por uno u otro procedimiento, se sujetarán siempre al establecido en el punto anterior.

11. Cuando el contratista, con autorización del Ingeniero Director de obras, emplee materiales de calidad más elevada o de mayores dimensiones de lo estipulado en el proyecto, o sustituya una clase de fabricación por otra que tenga asignado mayor precio o ejecute con mayores dimensiones cualquier otra parte de las obras, o en general, introduzca en ellas cualquier modificación que sea beneficiosa a juicio del Ingeniero Director de obras, no tendrá derecho sin embargo, sino a lo que le correspondería si hubiera realizado la obra con estricta sujeción a lo proyectado y contratado.

12. Las cantidades calculadas para obras accesorias, aunque figuren por partida alzada en el presupuesto final (general), no serán abonadas sino a los precios de la contrata, según las condiciones de la misma y los proyectos

particulares que para ellas se formen, o en su defecto, por lo que resulte de su medición final.

13. El contratista queda obligado a abonar al Ingeniero autor del proyecto y director de obras así como a los Ingenieros Técnicos, el importe de sus respectivos honorarios facultativos por formación del proyecto, dirección técnica y administración en su caso, con arreglo a las tarifas y honorarios vigentes.

14. Concluida la ejecución de la obra, será reconocida por el Ingeniero Director que a tal efecto designe la empresa.

15. La garantía definitiva será del 4% del presupuesto y la provisional del 2%.

16. La forma de pago será por certificaciones mensuales de la obra ejecutada, de acuerdo con los precios del presupuesto, deducida la baja si la hubiera.

17. La fecha de comienzo de las obras será a partir de los 15 días naturales del replanteo oficial de las mismas y la definitiva, al año de haber ejecutado la provisional, procediéndose si no existe reclamación alguna, a la reclamación de la fianza.

18. Si el contratista al efectuar el replanteo, observase algún error en el proyecto, deberá comunicarlo en el plazo de quince días al Ingeniero Director de obras, pues transcurrido ese plazo será responsable de la exactitud del proyecto.

19. El contratista está obligado a designar una persona responsable que se entenderá con el Ingeniero Director de obras, o con el delegado que éste designe, para todo relacionado con ella. Al ser el Ingeniero Director de obras el que interpreta el proyecto, el contratista deberá consultarle cualquier duda que surja en su realización.

20. Durante la realización de la obra, se girarán visitas de inspección por personal facultativo de la empresa cliente, para hacer las comprobaciones que se crean oportunas. Es obligación del contratista, la conservación de la obra ya ejecutada hasta la recepción de la misma, por lo que el deterioro parcial o total de ella, aunque sea por agentes atmosféricos u otras causas, deberá ser reparado o reconstruido por su cuenta.

21. El contratista, deberá realizar la obra en el plazo mencionado a partir de la fecha del contrato, incurriendo en multa, por retraso de la ejecución siempre que

éste no sea debido a causas de fuerza mayor. A la terminación de la obra, se hará una recepción provisional previo reconocimiento y examen por la dirección técnica, el depositario de efectos, el interventor y el jefe de servicio o un representante, estampando su conformidad el contratista.

22. Hecha la recepción provisional, se certificará al contratista el resto de la obra, reservándose la administración el importe de los gastos de conservación de la misma hasta su recepción definitiva y la fianza durante el tiempo señalado como plazo de garantía. La recepción definitiva se hará en las mismas condiciones que la provisional, extendiéndose el acta correspondiente. El Director Técnico propondrá a la Junta Económica la devolución de la fianza al contratista de acuerdo con las condiciones económicas legales establecidas.

23. Las tarifas para la determinación de honorarios, reguladas por orden de la Presidencia del Gobierno el 19 de Octubre de 1961, se aplicarán sobre el denominado en la actualidad "Presupuesto de Ejecución de Contrata" y anteriormente llamado "Presupuesto de Ejecución Material" que hoy designa otro concepto.

### Condiciones particulares

La empresa consultora, que ha desarrollado el presente proyecto, lo entregará a la empresa cliente bajo las condiciones generales ya formuladas, debiendo añadirse las siguientes condiciones particulares:

1. La propiedad intelectual de los procesos descritos y analizados en el presente trabajo, pertenece por entero a la empresa consultora representada por el Ingeniero Director del Proyecto.

2. La empresa consultora se reserva el derecho a la utilización total o parcial de los resultados de la investigación realizada para desarrollar el siguiente proyecto, bien para su publicación o bien para su uso en trabajos o proyectos posteriores, para la misma empresa cliente o para otra.

3. Cualquier tipo de reproducción aparte de las reseñadas en las condiciones generales, bien sea para uso particular de la empresa cliente, o para cualquier otra aplicación, contará con autorización expresa y por escrito del Ingeniero Director del Proyecto, que actuará en representación de la empresa consultora.

4. En la autorización se ha de hacer constar la aplicación a que se destinan sus reproducciones así como su cantidad.

5. En todas las reproducciones se indicará su procedencia, explicitando el nombre del proyecto, nombre del Ingeniero Director y de la empresa consultora.

6. Si el proyecto pasa la etapa de desarrollo, cualquier modificación que se realice sobre él, deberá ser notificada al Ingeniero Director del Proyecto y a criterio de éste, la empresa consultora decidirá aceptar o no la modificación propuesta.

7. Si la modificación se acepta, la empresa consultora se hará responsable al mismo nivel que el proyecto inicial del que resulta el añadirla.

8. Si la modificación no es aceptada, por el contrario, la empresa consultora declinará toda responsabilidad que se derive de la aplicación o influencia de la misma.

9. Si la empresa cliente decide desarrollar industrialmente uno o varios productos en los que resulte parcial o totalmente aplicable el estudio de este proyecto, deberá comunicarlo a la empresa consultora.

10. La empresa consultora no se responsabiliza de los efectos laterales que se puedan producir en el momento en que se utilice la herramienta objeto del presente proyecto para la realización de otras aplicaciones.

11. La empresa consultora tendrá prioridad respecto a otras en la elaboración de los proyectos auxiliares que fuese necesario desarrollar para dicha aplicación industrial, siempre que no haga explícita renuncia a este hecho. En este caso, deberá autorizar expresamente los proyectos presentados por otros.

12. El Ingeniero Director del presente proyecto, será el responsable de la dirección de la aplicación industrial siempre que la empresa consultora lo estime oportuno. En caso contrario, la persona designada deberá contar con la autorización del mismo, quien delegará en él las responsabilidades que ostente.