



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Dirección General de Estudios de Posgrado

Facultad de Ingeniería de Sistemas e Informática

Unidad de Posgrado

**Técnica eficiente para reconocimiento facial global
utilizando wavelets y máquinas de vectores de soporte
en imágenes 3D**

TESIS

Para optar el Grado Académico de Doctor en Ingeniería de
Sistemas e Informática

AUTOR

Mg. José Augusto CADENA MOREANO

ASESOR

Dra. Nora Bertha LA SERNA PALOMINO

Lima, Perú

2021



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Cadena, J. (2021). *Técnica eficiente para reconocimiento facial global utilizando wavelets y máquinas de vectores de soporte en imágenes 3D*. [Tesis de doctorado, Universidad Nacional Mayor de San Marcos, Facultad Ingeniería de Sistemas e Informática, Unidad de Posgrado]. Repositorio institucional Cybertesis UNMSM.

HOJA DE METADATOS COMPLEMENTARIOS

Código ORCID del autor	https://orcid.org/0000-0002-1775-252X
DNI o pasaporte del autor	0501552798
Código ORCID del asesor	https://orcid.org/0000-0002-4292-344X
DNI o pasaporte del asesor	07665297
Grupo de investigación	Sistemas Inteligentes
Agencia financiadora	Universidad Técnica de Cotopaxi UTC
Ubicación geográfica donde se desarrolló la investigación	0°56'00"S 78°37'00"O
Año o rango de años en que se realizó la investigación	2018-2020
Disciplinas OCDE	Ingeniería de sistemas y comunicaciones https://purl.org/pe-repo/ocde/ford#2.02.04



Universidad Nacional Mayor de San Marcos
Universidad del Perú. Decana de América

Facultad de Ingeniería de Sistemas e Informática
Vicedecanato de Investigación y Posgrado
Unidad de Posgrado

**ACTA DE SUSTENTACIÓN VIRTUAL DE TESIS PARA OPTAR EL GRADO
ACADÉMICO DE DOCTOR EN INGENIERÍA DE SISTEMAS E INFORMÁTICA**

A los siete (07) días del mes de marzo del 2021, siendo las quince horas, se reunieron en la sala virtual meet.google.com/vuh-bcjj-zjm, el Jurado de Tesis conformado por los siguientes docentes:

Dra. Rosa Sumactika Delgadillo Avila (Presidente)
Dr. Erik Alex Papa Quiroz (Miembro)
Dr. Glen Darío Rodríguez Rafael (Miembro)
Dra. Nora la Serna Palomino (Miembro Asesor)

Se inició la Sustentación invitando al candidato a Doctor **Jose Augusto Cadena Moreano**, para que realice la exposición oral y virtual de la tesis para optar el Grado Académico de Doctor en Ingeniería de Sistemas e Informática, siendo la Tesis intitulada:

“Técnica Eficiente para Reconocimiento Facial Global Utilizando Wavelets y Máquinas de Vectores de Soporte en Imágenes 3D”

Concluida la exposición, los miembros del Jurado de Tesis procedieron a formular sus preguntas que fueron absueltas por el graduando; acto seguido se procedió a la evaluación correspondiente, habiendo obtenido la siguiente calificación:

.....18 (Dieciocho) .Muy Bueno.....

Por tanto el Presidente del Jurado, de acuerdo al Reglamento General de Estudios de Posgrado, otorga al Magíster **Jose Augusto Cadena Moreano** el Grado Académico de Doctor en Ingeniería de Sistemas e Informática

Siendo las...16: 16..... horas, el Presidente del Jurado de Tesis da por concluido el acto académico de Sustentación de Tesis.

Dra. Rosa Sumactika Delgadillo Avila
(Presidente)

Dr. Erik Alex Papa Quiroz
(Miembro)

Dr. Glen Darío Rodríguez Rafael
(Miembro)

Dra. Nora la Serna Palomino
(Asesor)

DEDICATORIA

- A Dios, mi madre +Celia, padres políticos: +Edelina y +Serafín
- A mi esposa Ofelia
- A mis hijas Aracely y María José
- A mi familia

Mg. José Augusto Cadena Moreano

Doctorando

AGRADECIMIENTO

Mi sincero agradecimiento a la Dra. Nora La Serna Palomino por haber guiado mi trabajo doctoral durante este tiempo. Igualmente, mi agradecimiento a mi esposa Luz Ofelia, mis hijas Aracely y María José por apoyarme en mis estudios doctorales, sacrificando en varias ocasiones el tiempo de estar con ellas, y por estar conmigo en los momentos más difíciles, gracias por no abandonarme. Mi agradecimiento a la Universidad Nacional Mayor de San Marcos y su personal docente por la oportunidad brindada en esta superación académica y finalmente agradezco a mi universidad auspiciante la Universidad Técnica de Cotopaxi de la república del Ecuador, quien hizo posible salir del país a estudiar este doctorado en Ingeniería de Sistemas e Informática.

Mg. José Augusto Cadena Moreano

Doctorando

INDICE GENERAL

INDICE GENERAL	iv
INDICE DE FIGURAS.....	viii
INDICE DE TABLAS	xi
RESUMEN	xii
ABSTRACT.....	xiii
CAPITULO I: INTRODUCCION.....	1
1.1 Situación Problemática.....	1
1.2 Formulación del problema	4
1.3 Justificación de la investigación.....	4
1.3.1 Justificación teórica	4
1.3.2 Justificación práctica	5
1.4 Objetivos	5
1.4.1 Objetivo General	5
1.4.2 Objetivos específicos.....	6
1.5 Hipótesis.....	6
1.6 Variables.....	6
1.7 Operacionalización de variables de la investigación.....	7
1.8 Organización de la tesis.....	8
CAPITULO II: MARCO TEORICO	10
2.1 Marco filosófico o epistemológico	12
2.2 Antecedentes de investigación.....	14
2.3 Reconocimiento facial	15
2.4 Trabajos relacionados	16
2.4.1 Reconocimiento facial utilizando características geométricas en 3D: PCA y SVM	16
2.4.2 Máquina vector de soporte para reconocimiento facial.....	17

2.4.3	Un enfoque de reconocimiento facial mejorado basado en vector discriminante común y SVM.....	18
2.4.4	Un nuevo método de reconocimiento facial basado en una máquina rápida de mínimos cuadrados vectoriales.....	19
2.4.5	Reconocimiento facial R-KDA con SVM no lineal para bases de datos de múltiples vistas.....	21
2.4.6	Modificaciones al método de Eigenphases para el reconocimiento facial basado en SVM	22
2.4.7	Detección de expresión facial basada en la característica de fusión de PCA y LBP con SVM	23
2.4.8	Reconocimiento facial mediante la clasificación de modelos vectoriales para la autenticación de usuarios.....	24
2.4.9	Extracción de características basado en SVM para reconocimiento facial	25
2.4.10	Evaluation of facial recognition techniques using SVM, wavelets and PCA ...	26
2.4.11	Uniform multi-lens design as an SVM model selection tool for facial recognition	26
2.4.12	Main Subclass Convex Shell Sample Selection Method for SVM in Facial Recognition	27
2.4.13	A new SVM + NDA classification model with a facial recognition application 28	
2.4.14	An efficient 3D face recognition approach based on the fusion of novel local low-level features.....	29
2.4.15	Multiscale 3D feature extraction and matching with an application to 3D face recognition	30
2.4.16	Multiple strategies to enhance automatic 3D facial expression recognition .	31
2.4.17	A 3D-2D facial recognition method based on the extended Gabor wavelet combining edge and curvature detection	35
2.4.18	An efficient P-KCCA algorithm for 2D-3D face recognition using SVM	37
2.4.19	Recognition of static and dynamic 3D facial expressions: a comprehensive investigation.....	41
2.4.20	3D-2D face recognition with pose and illumination normalization	42
2.5	Técnicas tratadas en el reconocimiento facial en dos dimensiones (2D) y en tres dimensiones (3D)	44
2.5.1	Análisis de Componentes Principales (PCA).....	44
2.5.2	K vecinos más cercanos (K-nn)	46
2.5.3	Redes neuronales artificiales (RNA).....	46

2.5.4	Máquina de vectores soporte (SVM)	47
2.5.5	Análisis discriminante lineal (LDA).....	57
2.5.6	Análisis de componentes independientes (ICA)	57
2.6	Bases de datos de caras	58
2.6.1	Bases de datos de caras 2D	58
2.6.2	Bases de datos de caras 3D	62
2.7	Análisis de las técnicas y bases de datos revisados	65
2.8	Filtrado de Imágenes.....	67
2.8.1	Filtro de Gabor	68
2.9	Extracción de Características.....	70
2.9.1	Extracción de características por wavelets de Gabor	71
2.10	Resumen de la revisión de literatura.....	75
2.10.1	Descripción de la metodología de la revisión de la literatura.....	75
2.10.2	Tipos de Investigación	77
2.10.3	Comparación de técnicas de Reconocimiento Facial.....	77
2.11	Validación cruzada	78
CAPITULO III: METODOLOGIA DE LA INVESTIGACION.....		80
3.1	Tipo y diseño de la investigación	80
3.2	Unidad de análisis	81
3.3	Población de estudio	81
3.4	Tamaño de la muestra.....	81
3.5	Técnicas de recolección de datos	84
3.6	Técnicas de análisis de datos.....	85
3.7	Validación del modelo para reconocimiento facial en 2D y 3D	86
CAPITULO IV: TECNICA EFICIENTE PARA RECONOCIMIENTO FACIAL GLOBAL EN 2D		88
4.1	Selección y justificación de las tecnologías utilizadas.....	88
4.1.1	Bases de datos 2D seleccionados	88
4.1.2.	Algoritmo de extracción de características seleccionado	89
4.1.3	Algoritmo de clasificación.....	90
4.2	Modelo desarrollado para reconocimiento facial global en 2D.....	90

4.2.1.	Componentes del modelo de reconocimiento facial global en 2D	91
4.3	Implementación del modelo	92
4.4	Validación del Modelo.....	97
4.5	Descripción de los experimentos y sus resultados	103
4.6	Discusión de los resultados	108
CAPITULO V: TECNICA EFICIENTE PARA RECONOCIMIENTO FACIAL GLOBAL EN 3D		
5.1	Selección y justificación de las tecnologías para reconocimiento facial 3D.....	111
5.1.1	Bases de datos 3D seleccionados	111
5.1.2.	Algoritmos de extracción de características y de clasificación 3D	116
5.2	Modelo propuesto para reconocimiento en imágenes 3D	118
5.2.1	Modelo de imágenes facial 3D-2D con puntos de referencia	118
5.2.2	Modelo de imágenes facial 3D-2D con máscaras	121
5.3	Validación del modelo obtenido.....	123
5.3.1	Validación del modelo con base de datos TEXAS3DFRD.....	123
5.3.2	Validación del modelo con base de datos BU-3DFE	127
5.4	Descripción de los experimentos y sus resultados	129
5.4.1	Descripción de los experimentos y sus resultados con BDD TEXAS3DFRD ..	129
5.4.2	Descripción de los experimentos y sus resultados con BDD BU-3DFE	132
5.5	Discusión de los resultados	135
5.6	Comprobación de hipótesis.....	138
5.7	Conclusiones	138
CAPITULO VI: CONCLUSIONES Y TRABAJOS FUTUROS		
6.1	Conclusiones	139
6.2	Trabajos futuros	140
BIBLIOGRAFIA		
ANEXOS		

INDICE DE FIGURAS

Figura 2.1 Estructura de un árbol binario para 8 clases para un reconocimiento (Guo et al., 2001).....	17
Figura 2.2 Región basada en representación facial 3D (Lei et al., 2013)	30
Figura 2.3 Face de Normalización (X. Li et al., 2015)	33
Figura 2.4 Esquemas de división descritos en base a una imagen de textura neutral (X. Li et al., 2015)	33
Figura 2.5 Pesos de diferentes bloques de una imagen. El bloque más brillante tiene un mayor peso; viceversa (X. Li et al., 2015)	34
Figura 2.6 Diagrama de bloques de sistema 3D FR propuesto (Torkhani et al., 2017)	36
Figura 2.7 Configuración del sistema de reconocimiento facial (Kamencay et al., 2015).....	38
Figura 2.8 Algoritmo P-KCCA de diagrama de bloque propuesto (Kamencay et al., 2015) ...	40
Figura 2.9 Algoritmo P-KCCA usando SVM (Kamencay et al., 2015).....	40
Figura 2. 10 Red neuronal artificial (ANN).....	47
Figura 2.11 Esquema general del SVM	48
Figura 2.12 Esquema gráfico de una máquina de vectores de soporte	50
Figura 2. 13 Un esquema de dos clases con varios hiperplanos	52
Figura 2. 14 Un esquema de dos clases con un hiperplano óptimo	52
Figura 2. 15 Un esquema de un caso separable linealmente	53
Figura 2. 16 Un esquema de un caso no separable linealmente	54
Figura 2. 17 Esquema de un ejemplo transformado a un caso separable linealmente	54
Figura 2. 18 Ejemplo de sesión completa para una persona de la base de datos de Yale (Shao et al., 2014).	59
Figura 2.19 Ejemplo de una base de datos ampliada de rostros de Yale B. (Chan & Tahir, 2013).....	59
Figura 2.20 Ejemplo de imágenes tomadas en la base de datos de rostros CAS-PEAL.(Gao, Y., Ma, J., Zhao, M., 2017).....	60
Figura 2.21 Imágenes de ejemplo de la base de datos de caras de FERET(Lu, J., Tan, Y.-P., & Wang, 2013), (Sadhya & Kumar, 2019), (Benini et al., 2019)	61
Figura 2.22 Imágenes de muestra de la base de datos facial ORL. (Xu, Y., Fang, X., Li, X., Yang, J., You, J., Liu, H., & Teng, 2014)	61

Figura 2.23 Bases de datos MUCT	62
Figura 2. 24 Bases de datos Texas 3DFRD (Gupta et al., 2010a)	63
Figura 2.25 Bases de datos de caras de CASIA 3D (Casia, 2011)	64
Figura 2.26 Ejemplo de imágenes clasificadas como neutrales en la base de datos de FRGC v2 (Passalis et al., 2014)	64
Figura 2.27 Base de datos BU-3DFE (Dou & Kakadiaris, 2017)	65
Figura 2.28 Imagen original (izquierda) que ha sido filtrada (derecha)	68
Figura 2.29 Dos filtros de Gabor, cada uno de ellos con distinta frecuencia central, escalado y orientación (García, Escaramilla, & Nariko, 2015).	69
Figura 2. 30 El conjunto de 40 wavelets Gabor. a) La magnitud a cinco escalas. b) Las partes reales a cinco escalas y ocho orientaciones (Shen & Bai, 2006)	73
Figura 2. 31 Resumen de trabajos que involucran al algoritmo SVM según la base de datos registrada	76
Figura 2. 32 Resumen de trabajos revisados que involucran al algoritmo SVM según el año de publicación.	76
Figura 3. 1 Bdd FERET	82
Figura 3. 2 Bdd MUCT	83
Figura 3. 3 Base de dattos TEXAS3DFRD	83
Figura 3. 4 Base de datos BU-3DFE	84
Figura 3. 5 Proyección de un modelo sobre los planos respectivos	86
Figura 3. 6 Esquema Validación cruzada del modelo obtenido aplicado al conjunto de datos de entrenamiento	87
Figura 4. 1 Base de datos utilizado FERET	88
Figura 4. 2 Base de datos utilizado MUCT	89
Figura 4.3 Modelo del proceso de reconocimiento facial en 2D	91
Figura 4. 4 Dataset Feret utilizada.....	93
Figura 4. 5 Dataset MUCT utilizada	94
Figura 4. 6 Resultado del filtrado de una imagen por Gabor.....	95
Figura 4. 7 Banco de vectores caracterísitcas de bdd FERET	96
Figura 4. 8 Validación modelo, bdd Feret kernel lineal	97
Figura 4. 9 Validación modelo, bdd Feret kernel cúbico	98

Figura 4. 10 Validación modelo, bdd Feret kernel Gaussiano	99
Figura 4. 11 Validación modelo, bdd Muct kernel Lineal	100
Figura 4. 12 Validación modelo, bdd Muct kernel Cúbico	101
Figura 4. 13 Validación modelo, bdd Muct kernel Gaussiano	102
Figura 4.14 Porcentaje de reconocimiento de clases con Bdd FERET.....	105
Figura 4.15 Porcentaje de reconocimiento de clases con Bdd MUCT	107
Figura 5. 1 Puntos fiduciales antropométricos (a) en una imagen en color, y (b) en una imagen de rango	111
Figura 5. 2 Proyección de un modelo 3D a los planos (x-z), (y-z) y (z-y)	113
Figura 5. 3 Imágenes preprocesadas (a) de color y (b) de rango de la Base de datos Texas 3DFRD	114
Figura 5. 4 Base de datos TEXAS3DFRD.....	115
Figura 5. 5 Base de datos BU-3DFE	116
Figura 5. 6 Modelo de reconocimiento facial 3D TEXAS3DFRD	119
Figura 5. 7 Modelo de reconocimiento facial 3D con BU-3DFE	121
Figura 5.8 Proyección de un modelo de cara 3D en los planos	122
Figura 5. 9 Validación modelo, bdd TEXAS3DFRD, kernel lineal	124
Figura 5. 10 Validación modelo, bdd TEXAS3DFRD kernel cúbico	125
Figura 5. 11 Validación modelo, bdd TEXAS3DFRD kernel Gaussiano	126
Figura 5. 12 Validación modelo, bdd BU-3DFE kernel lineal.....	127
Figura 5. 13 Validación modelo, bdd BU-3DFE kernel cúbico.....	128
Figura 5. 14 Validación modelo, bdd BU-3DFE kernel Gaussiano.....	128
Figura 5.15 Bdd TEXAS3DFRD.....	130
Figura 5.16 Porcentaje de reconocimiento de clases con Bdd TEXAS3DFRD	132
Figura 5.17 Bases de datos BU-3DFE.....	133
Figura 5.18 Porcentaje de reconocimiento de clases con bdd BU-3DFE	135

INDICE DE TABLAS

Tabla 1.1 Operacionalización de variables de la investigación	7
Tabla 2.1 Metodología de la investigación para el estado del arte	11
Tabla 2.2 Resumen de los resultados obtenidos para siete entrenamientos con 8 técnicas (Wen, 2012)	19
Tabla 2.3 Resultados obtenidos en el reconocimiento (Kong & Zhang, 2011)	20
Tabla 2.4 Bases de datos de rostros en 3D (Sandbach et al., 2012)	41
Tabla 2.5 Reconocimiento facial en UHDB11 utilizando sistemas 3D-3D, 2D-2D y 3D-2D (Kakadiaris et al., 2017).....	44
Tabla 2. 6 Comparación de técnicas de Reconocimiento Facial	77
Tabla 2. 7 Proceso de Validación Cruzada	79
Tabla 4. 1 Resumen de validación de modelos	102
Tabla 4.2 Resumen de resultados con Bdd FERET	103
Tabla 4.3 Porcentaje de reconocimiento de clases con Bdd FERET	104
Tabla 4.4 Resumen de resultados con Bdd MUCT	106
Tabla 4.5 Porcentaje de reconocimiento de clases con Bdd MUCT.....	107
Tabla 4. 6 Resumen de comparación con otrso trabajos relacionados	109
Tabla 5. 1 Resumen de validación de modelos	129
Tabla 5.2 Resumen de resultados con Bdd TEXAS3DFRD	130
Tabla 5.3 Porcentaje de reconocimiento de clases con Bdd TEXAS3DFRD.....	131
Tabla 5.4 Resultados según la base de datos BU-3DFE	133
Tabla 5.5 Porcentaje de reconocimiento aplicando BDD BU-3DFE	134
Tabla 5. 6 Comparación de resultados con otros trabajos	136
Tabla 5. 7 Comparación de resultados con otros trabajos	137

RESUMEN

La investigación que se presenta en esta Tesis Doctoral se desarrolla en el marco de los Sistemas de Reconocimiento facial automático de imágenes. Que consisten en procesar las imágenes de caras de personas utilizando métodos estadísticos y matemáticos de extracción de características y de clasificación de imágenes, para conocer si un individuo se encuentra en una determinada clase, y finalmente hallar su identidad. El tratamiento automático de una cara es complicado, debido a que se presenta varios factores que le afectan, como la posición de la cara, la expresión, la edad, la raza, el tipo de iluminación, el ruido, y objetos como lentes, sombrero, barba entre otros. El procesamiento se realiza de forma global, en donde se procesa toda la cara. Se sabe que procesar las imágenes de manera global es más rápido, práctico y fiable que las basadas en rasgos. Además, se conoce que procesar imágenes en tres dimensiones es más real y consistente que en dos dimensiones. El principal objetivo de la tesis que se propuso fue desarrollar una técnica eficiente de reconocimiento facial con rasgos globales, y con imágenes en tres dimensiones. Para ello, se seleccionó los algoritmos más eficientes para extracción de características, filtros de Gabor, y el algoritmo para clasificación, Máquina de vectores de soporte (SVM). Este último algoritmo, su eficiencia varía de acuerdo a la función núcleo o kernel, por ello en esta tesis se trabajaron con tres kernel: lineal, gauseano y cúbico. Estos sistemas constan de dos procesos necesarios: 1) Entrenamiento, y 2) Pruebas. Lo que permitió establecer un modelo de reconocimiento facial global para dos y tres dimensiones respectivamente. La técnica fue procesada primero para imágenes 2D, luego para imágenes 3D. Y se utilizó el método de validación cruzada en ambos casos para aprobarlo. Los mejores resultados obtenidos con la técnica alcanzada son 96% de eficiencia con base de datos de imágenes de dos dimensiones; y 98,4% con base de datos de imágenes de tres dimensiones. Finalmente, se hace una comparación de los resultados alcanzados con otros trabajos de investigación similares, obteniéndose mayor eficiencia con este trabajo.

PALABRAS CLAVE: Modelo de reconocimiento facial, Características de Gabor, Bases de datos faciales 2D y 3D, Vectores soporte, kernel.

ABSTRACT

The research presented in this Doctoral Thesis is carried out within the framework of automatic facial image recognition systems. They consist of processing the images of people's faces using statistical and mathematical methods of extracting characteristics and classifying images, to know if an individual is in a certain class, and finally find their identity. The automatic treatment of a face is complicated, due to the fact that it presents several factors that affect it, such as the position of the face, expression, age, race, type of lighting, noise, and objects such as glasses, hat, beard among others. Processing is done globally, where the entire face is processed. Processing images globally is known to be faster, more practical, and more reliable than feature-based images. Furthermore, it is known that processing images in three dimensions is more real and consistent than in two dimensions. The main objective of the proposed thesis was to develop an efficient facial recognition technique with global features, and with three-dimensional images. For this, the most efficient algorithms for feature extraction, Gabor filters, and the algorithm for classification, Support vector machine (SVM), were selected. This last algorithm, its efficiency varies according to the kernel or kernel function, therefore, in this thesis we worked with three kernels: linear, gaussian and cubic. These systems consist of two necessary processes: 1) Training, and 2) Testing. This allowed establishing a global facial recognition model for two and three dimensions, respectively. The technique was processed first for 2D images, then for 3D images. And the cross validation method was used in both cases to approve it. The best results obtained with the technique achieved are 96% efficiency with a two-dimensional image database; and 98.4% with a three-dimensional image database. Finally, a comparison is made of the results achieved with other similar research works, obtaining greater efficiency with this work.

KEY WORDS: Facial recognition model, Gabor characteristics, 2D and 3D face databases, Support vectors, kernel.

CAPITULO I: INTRODUCCION

1.1 Situación Problemática

En la sociedad actual, la inseguridad se ha vuelto una de las formas de vida diaria que lleva la humanidad avanzar de una manera muy acelerada, sin que al momento haya una forma de contrarrestarla. En los últimos años, la seguridad de algunos países se ha visto intimidada por los ataques terroristas, especialmente en los países con mayor poder en el mundo (Cadena, Montaluisa, Flores, Chancúsig, & Guaypatín, 2017). Dichos ataques han demostrado las falencias en los sistemas de inteligencia y de seguridad nacional. Debido a esta situación los gobiernos de todos los países del mundo han utilizado su presupuesto para mejorar estos sistemas en distintos lugares como; aeropuertos, oficinas de investigación, entidades publicas, etc. En función de esto, el reconocimiento biométrico facial es indispensable para un sistema de seguridad ciudadana en general (Arguello, 2011). Actualmente los sistemas de reconocimiento facial tienen altos porcentajes de reconocimiento, sin embargo, no se ha logrado obtener un cien por ciento de efectividad, debido a varios inconvenientes que se presentan principalmente con las características faciales del ser humano.

Por un lado, los seres humanos a menudo utilizan rostros para reconocer individuos, dada su capacidad discriminativa y por otro lado avances en el campo de la informática en los últimos tiempos permiten registros parecidos en forma automática. Desde este punto de vista en estos últimos tiempos se habla de reconocimiento de imágenes faciales, que consiste en captar la imagen de una persona a través de ciertas técnicas, las mismas que no son intrusivas, es decir la persona no se siente obligada a ser identificada. El ser humano nace con la capacidad de reconocer rostros, misma que va desarrollando conforme avanza su crecimiento. Sin embargo, es necesario automatizar esta actividad que realizamos los seres humanos, por cuanto es imposible que la persona pueda estar en el momento que se da una acción no permitida como: robos, asesinatos, secuestros, etc. De allí que en la actualidad se cuenta con un sistema de reconocimiento facial controlado por computador. Este reconocimiento facial de

rostros humanos es un problema que aún sigue desafiando en informática por cuanto aún no llegan a una eficiencia esperada (Bah & Ming, 2020).

Las aplicaciones de un Sistema de reconocimiento están relacionadas con la seguridad, tales como la autenticación de identidad, control de acceso, vigilancia, etc (Cadena & Flores, 2018). Sin embargo, no es fácil reconocer automáticamente a diferentes personas (cientos o miles) por la imagen de su rostro, debido a la variación de las imágenes de la misma cara por la iluminación, pose, y por la variación de la misma imagen pasado un tiempo (Manju & Radha, 2020). Hay que tener en cuenta que el reconocimiento facial presenta problemas debido a las diversas características que se presentan en cada persona.

El intento de efectuar por medios computacionales el proceso de reconocimiento facial, no es sencillo, el hardware y software utilizados, las limitaciones observadas y la calidad de investigaciones previas respecto al rostro que necesitamos reconocer y el método que se usa. Se destaca los variados inconvenientes existentes en este campo como pose, expresión facial o iluminación, edad, movimiento de la persona, entre otros. Es necesario destacar que los algoritmos juegan un papel importante en este proceso de reconocimiento, por cuanto toda aplicación informática está diseñada en función de un algoritmo. En la actualidad se tiene aplicaciones para el reconocimiento facial, sin embargo según (Belén, Díaz, & Físicas, 2004), existen muchas causas que producen la deficiencia en el reconocimiento facial que son las siguientes: “La posición de la cara, su rotación respecto de las tres direcciones del espacio, la distancia entre la cara y el sensor, la escala, la resolución, el tipo de iluminación, el color, el maquillaje, la posición de la fuente de iluminación, la presencia de sombras, el peinado, la presencia de barba, bigote o perilla, las oclusiones y los gestos”.

Para estas adaptaciones es muy común usar aplicaciones de erradicación de datos. La información extraída para que la investigación se ocupe del contenido de textos de estudio importantes de un dominio (o escenario) predeterminado, llamado dominio de extracción. La finalidad de un sistema de extracción de información es detectar la información real y separar el informe irrelevante (Cowie & Wilks, 1996).

En lo referente al reconocimiento facial se han presentado varios avances referentes a este campo. El reconocimiento facial es una tecnología que captura e identifica el rostro de la persona, la información que se obtiene es almacenada en una base de datos. El sistema obtiene la información y automáticamente inicia la localización y determinación de las características faciales que identifica a cada persona (Viola y Jones, 2001). Reconocer el rostro humano en el registro facial se usa como el primer paso en el sistema. Asimismo, tiene un impacto significativo en el resultado del desarrollo, ya sea en una serie de imágenes o videos en inmediato tiempo. En ese sentido, debe poder identificar rostros libremente de los submúltiplos anteriores.

Para este reconocimiento facial, es necesario el uso de algoritmos que permitan la extracción y la clasificación de la información obtenida. En un informe realizado por los autores (Kim, Park, Toh, & Lee, 2010), señalan que la finalidad principal para que el sistema funcione, es identificar un algoritmo eficiente que permita el reconocimiento de características del rostro. Este se ha desarrollado para hipersuperficie no lineal, hay que tener en cuenta que existen limitaciones para el LDA (Análisis Discriminante Lineal) no lineal para enfrentar las aplicaciones físicas en virtud de factores ambientales complejos. Esta delimitación incluye el uso de funciones de covarianza común entre cada categoría, y la dimensionalidad limitada inherente a la conceptualización de la dispersión entre la clase. Debido a que son problemas inherentes ocasionados en el criterio de Fisher (Sandoval, Rubio, & Eds, 2019), que no pueden resolver en el marco LDA convencional por lo que utiliza el método kernel no lineal, como es un polynomial (Zhao, Fu, Ji, Zhou, & Tang, 2011).

Dentro de los algoritmos que permiten el reconocimiento facial se encuentra el SVM. El estudio realizado por (Guo, Li, & Chan, 2001), indica que es posible utilizar un método de red de aprendizaje para reconocimiento de patrones bipartita, incorporando al sistema SVM una estrategia de reconocimiento de árbol binario para manejar el problema de reconocimiento facial multi clase. El rendimiento del SVM se basa principalmente en comparar el enfoque eigenface estándar, y el algoritmo actual plantea la línea característica más cercana que es un método de clasificación eficiente pero simple que permite el reconocimiento de patrones (NFL, Guo et al., 2001).

Respecto de la Curvatura de Gabor extendida y mapas de los bordes, son métodos importantes utilizados para completar la extracción de características de una imagen reducida sus vértices características y puntos de alta prominencia, el trabajo de (Torkhani, Ladgham, Sakly, & Mansouri, 2017) aplica este método aprovechando las ventajas del impacto sobresaliente de las ondas de Gabor en la simulación de la forma de la cara, explotando propiedades visuales pertinentes, localizando frecuencias de características especiales y el control de la selectividad de orientación. Con respecto a la teoría de la wavelet Gabor cada uno de los filtros corresponde a una onda sinusoidal modulada por una envolvente gaussiana diseñada mediante la orientación y una escala espacial o una frecuencia.

1.2 Formulación del problema

Hay muchos trabajos de investigación y comerciales generales de reconocimiento facial, pero no logran ser eficientes al cien por ciento, para ser aplicados en el contexto de seguridad, debido a las complejidades de las imágenes de caras.

Problema: ¿De qué manera se logrará obtener un sistema eficiente de reconocimiento facial utilizando técnicas eficientes de extracción de características, clasificación y bases de datos adecuadas para 3D?

1.3 Justificación de la investigación

1.3.1 Justificación teórica

Esta investigación se realiza con el propósito de aportar al conocimiento existente sobre reconocimiento facial en 3D, a través de la revisión literaria sobre bases de datos, técnicas de extracción de características y algoritmos de clasificación de patrones, se destaca los trabajos más eficientes en este tema para analizar su metodología aplicada y poder sistematizarse en una propuesta, para ser incorporado como conocimiento al tema de reconocimiento facial, ya que se estaría demostrando que el uso de estos algoritmos mejoran el nivel de reconocimiento de imágenes pertenecientes a una base de datos.

En la actualidad, la tecnología ha contribuido de manera significativa en el desarrollo de la sociedad, y en el campo del reconocimiento facial está dando un gran aporte a la humanidad, sin embargo, es muy importante que esta investigación avance hasta conseguir una técnica eficiente que logre un reconocimiento facial de un rostro humano sin importar su posición en la que se encuentre (estática o movimiento), color, rostro semicubierto, etc.

Ante esta realidad es necesario trabajar en la búsqueda de un algoritmo más eficiente que garantice el proceso de reconocimiento de imágenes faciales por lo que resulta por demás justificado el tema propuesto. De allí la significación de continuar avanzando con la investigación propuesta, cabe mencionar que este tema está enmarcado dentro de la línea de investigación de sistemas inteligentes.

1.3.2 Justificación práctica

Esta investigación se realiza porque existe la necesidad de mejorar el nivel de eficiencia en el proceso de reconocimiento facial, mediante el uso de técnicas y algoritmos de clasificación. El tema propuesto en la tesis permitirá encontrar soluciones de optimizaciones del algoritmo, generará una nueva técnica, se aportará en la solución de problemas de seguridad ciudadana, que aprovecharán las instituciones educativas públicas y privadas, las municipalidades, la policía nacional y los organismos privados para seguridad pública, permitirá disminuir el número de incidencias delincuenciales, etc. Esta técnica eficiente permitirá obtener un sistema de reconocimiento facial de apoyo en el monitoreo de reconocimiento de individuos ante una situación que quieran delinquir, etc.

1.4 Objetivos

1.4.1 Objetivo General

Desarrollar una técnica de reconocimiento facial que tenga un porcentaje de eficiencia por encima del 97% utilizando algoritmos de wavelets de Gabor y

Máquinas de vectores soporte con sus diferentes kernels a través de imágenes 3D para contribuir a la seguridad ciudadana.

1.4.2 Objetivos específicos

- Revisar la literatura referente a bases de datos en 2D y 3D, extracción de características y algoritmos de clasificación.
- Seleccionar e implementar un algoritmo eficiente de extracción de características para imágenes faciales en 2D y 3D respectivamente
- Seleccionar e implementar un algoritmo de clasificación eficiente para 2D y 3D respectivamente que serán usado en la investigación.
- Establecer un modelo de reconocimiento facial utilizando los algoritmos de extracción y clasificación seleccionados para 2D y 3D respectivamente.
- Validar el modelo obtenido a través de los algoritmos de extracción y clasificación en 2D y 3D respectivamente.

1.5 Hipótesis

El desarrollo de una técnica de reconocimiento facial usando algoritmos eficaces como Gabor y Máquina de Vectores Soporte, permitirá la obtención de un proceso de reconocimiento facial global en 3D, por encima de 97% de eficiencia, que contribuya a la mejora de la seguridad ciudadana.

1.6 Variables

Variable independiente:

- Técnica de reconocimiento facial usando Gabor y Máquina de Vectores Soporte

Variable dependiente:

- Eficiencia del reconocimiento facial en 3D

1.7 Operacionalización de variables de la investigación

Tabla 1.1 Operacionalización de variables de la investigación

VARIABLES	TIPO DE VARIABLE	DEFINICIÓN DE VARIABLE	INDICADOR DE CUMPLIMIENTO	MEDICIÓN DE INDICADOR DE CUMPLIMIENTO	DEFINICIÓN DE INDICADOR
Técnica de reconocimiento facial usando Gabor y Máquina de Vectores Soporte	Independiente	Técnicas y métodos empleados para la extracción y clasificación de información	-	-	-
Eficiencia del reconocimiento facial en 3D	Dependiente	Porcentaje de efectividad del proceso de reconocimiento facial	Eficiencia	Porcentaje de eficiencia	Porcentaje de un grado de reconocimiento de la técnica

1.8 Organización de la tesis

En el capítulo I se desarrolla la Sección 1.1 correspondiente a la situación problemática, seguido de la Sección 1.2 en donde se realiza la formulación del problema, mientras que en la Sección 1.3 se plantea la justificación de la investigación. A continuación, en la Sección 1.4 se plantea los objetivos tanto el general como los específicos, seguidamente de la Sección 1.5 que hace referencia a la hipótesis de la investigación, seguido de la Sección 1.6 que indica la organización de la tesis, a continuación, la Sección 1.7 trata sobre las variables de la investigación y finalmente la Sección 1.8 que presenta la operacionalización de variables del análisis.

El capítulo II aborda el marco teórico acerca del tema planteado, es así que en la Sección 2.1 se plantea el marco filosófico y epistemológico del tema de investigación, la Sección 2.2 trata sobre los antecedentes de la investigación, a continuación la Sección 2.3 trata sobre el reconocimiento facial, mientras que en la Sección 2.4 se revisa exclusivamente trabajos relacionados con la técnica del SVM para el reconocimiento de rostros, seguido de la Sección 2.5 donde trata las técnicas de reconocimiento en dos dimensiones (2D) y tres dimensiones (3D), en la Sección 2.6 se realiza una conceptualización de las principales bases de datos de caras, de las cuales se elegirán las más apropiadas para el trabajo de investigación, seguido por la Sección 2.7 donde se realiza una evaluación de las técnicas revisadas sobre reconocimiento facial, a continuación en la Sección 2.8 se plantea una revisión sobre filtrado de imágenes, mientras en la Sección 2.9 trata la revisión sobre extracción de características, a continuación en la Sección 2.10 se realiza un resumen de la revisión de la literatura, y finalmente en la Sección 2.11 trata sobre la validación cruzada.

El capítulo III se enfoca sobre la metodología de investigación, es así que en la Sección 3.1 se indica sobre el tipo y diseño del análisis, mientras que la Sección 3.2 trata sobre la unidad de análisis, así también en la Sección 3.3 se indica sobre la población de estudio, mientras en la Sección 3.4 se aborda sobre el tamaño de la muestra, en la Sección 3.5 se realiza un enfoque a las técnicas de recolección de datos seguido de la Sección 3.6 que trata sobre las técnicas de análisis de datos para concluir con la Sección 3.7 sobre la validación de modelos para reconocimiento facial en 2D y 3D respectivamente.

En el capítulo IV se realiza un enfoque al primer aporte realizado en la investigación, en tal sentido en la Sección 4.1 se indica sobre la selección y justificación de la tecnología a utilizarse en el diseño del experimento, mientras que la Sección 4.2 trata sobre el modelo desarrollado para 2D con las bases de datos FERET y MUCT, en la Sección 4.3 se describe la implementación del modelo, continuando con la Sección 4.4 donde se describe la validación del modelo, en la Sección 4.5 se realiza una descripción de los experimentos y sus resultados, por último en la Sección 4.6 se refiere a la discusión de los resultados conseguidos.

El capítulo V trata sobre el segundo aporte, donde se realiza un enfoque al aporte realizado en la investigación, en tal sentido en la Sección 5.1 se habla sobre la selección y justificación de la tecnología a utilizarse en el diseño del experimento en 3D, mientras que en la Sección 5.2 trata sobre el modelo propuesto para 3D, el primero utiliza una base de rostros TEXAS3DFRD y el otro con la base de rostros BU-3DFE, seguido por la Sección 5.3 que aborda la validación del modelo obtenido para cada una de las bases de datos indicados anteriormente, a continuación viene la Sección 5.4 que trata sobre la descripción de los experimentos y sus resultados. Así también en la Sección 5.5 se realiza una discusión de resultados conseguidos en las pruebas realizadas en el proceso de reconocimiento facial, mientras que en 5.6 se plantea la comprobación de hipótesis y para concluir, en la Sección 5.7 se establece las respectivas conclusiones del segundo aporte de la investigación.

En el capítulo VI se establecen las conclusiones generales de la investigación y posibles trabajos futuros para quienes deseen continuar investigando sobre este tema.

Para concluir se presenta las respectivas referencias bibliográficas, anexos que contemplan las pruebas realizadas y sobre todo cinco publicaciones en revistas indexadas en scopus, web of science, cielo, latindex y dialnet, correspondientes a la investigación, que es fruto de un trabajo de mucha paciencia, dedicación, sacrificio y responsabilidad.

CAPITULO II: MARCO TEORICO

Este capítulo presenta el marco teórico basado en técnicas, modelos, filtros, clasificadores, implementaciones, extractores de características, herramientas para un reconocimiento facial con imágenes 2D y 3D, utilizando algoritmos de filtros de Gabor, extracción de características como Gabor, PCA, clasificador de patrones como Máquinas de Vectores Soporte (SVM). De acuerdo a García (Garcia, 2014), el estado del arte en el marco teórico es de gran importancia, se descubre nuevo enfoque y permite afianzar el grado de actualización del tema de análisis. Además, García (Garcia, 2014) manifiesta que un buen estado del arte acerca al investigador a la solución de su problema de análisis al comprender las soluciones al mismo problema en planteamiento similar, al que han llegado otros analistas.

En base a la motivación sobre el tema de reconocimiento facial, se llevo a cabo la investigación de los temas de interés en revistas indexadas, libros, artículos de revistas, conferencias en congresos científicos, etc, se buscó información en las primordiales bibliotecas digitales y motores de búsqueda de información como: IEEE Xplore, Science Direct, Scopus, Springer, etc. Las demarcaciones de búsqueda fueron: Reconocimiento de rostros en 2D, reconocimiento de rostros en 3D, clasificadores de patrones, técnicas de extracción de características de rostros, filtrado de imágenes, bases de datos de caras, clasificadores de patrones, máquinas de vectores de soporte (SVM).

De los resultados encontrados, se realizó la lectura de los títulos y se suprimió información que no cumplía con los parámetros de la investigación. De los artículos relacionados con el tema se leyó su abstract, descartando los análisis que no eran compatibles con el desarrollo del tema. Continuando con los seleccionados se analizó la introducción y las conclusiones y se excluyó a los trabajos de investigación que resolvían un sentido más amplio o hacían referencia a ello.

Finalmente, de los artículos resultantes, se realizó su lectura completamente y se eliminó material que no coincidían con el tema y no contribuían con información relevante sobre reconocimiento de rostros. Por otro lado, también se llevó a cabo un registro de todos los documentos descargados, que de una u otra manera permitieron construir este documento de tesis y ampliar el conocimiento. Se estimó el protocolo de revisión y se validó la confiabilidad de los análisis, con el asesor de este trabajo, mediante una lista de observación que contiene criterios de aporte, credibilidad, relevancia, novedad, viabilidad entre otros. En la revisión realizada se citó a los autores más relevantes y a los estudios de mayor jerarquía con su respectivo título del documento, técnica utilizada, año de publicación, base de datos, resolución, porcentaje de eficiencia con su técnica, etc. En la tabla 2.1 se presenta un resumen de la metodología de la investigación aplicada en este trabajo.

Tabla 2.1 Metodología de la investigación para el estado del arte

Aspecto	Explicación
Estrategia de Búsqueda	Área: Reconocimiento facial, Técnicas de reconocimiento facial, Reconocimiento facial con SVM, Bases de datos de rostros en 2D y 3D. Propósito de la búsqueda: Caracterización de técnicas y determinar los más eficientes
Fuentes de Información	Libros, Revistas indexadas, Tesis doctorales
Motores de Búsqueda	ACM Digital Library, IEEE, Science Direct
Criterios de Búsqueda	Recognition of faces Face recognition techniques Facial recognition with SVM Databases of faces in 2D Databases of faces in 3D
Criterios de selección	Documentos que contienen información sobre los temas mencionados
Criterios de Exclusión	Se excluyen los documentos publicados muchos años atrás, exceptuando los más importantes. Se excluyen los documentos que analizan otros tipos de reconocimiento que no sea de rostros como dactilares, iris, etc. Se excluyen bases de datos muy pequeños
Evaluación de los contenidos	Exactitud, objetividad, cobertura, eficiencia, Se investiga en la cadena de autores que han realizado contribuciones a los artículos y temas analizados.
Análisis de la información.	Se ofrece una visión general de las técnicas y bases de datos empleados en los procesos de reconocimiento de rostros en 2D y 3D. De los documentos analizados se establece los trabajos que han obtenido la mayor eficiencia en reconocimiento, así como las

	<p>técnicas empleadas, a partir de los cuales se inicia la solución al problema de la investigación. Se examinan algunas técnicas de clasificación y extracción como Máquina de Vectores Soporte (SVM), Árboles de Decisión, Análisis de Componentes Principales (PCA), Filtros de Wavelet de Gabor, Características de Gabor, etc. Y finalmente las bases de datos de rostros trabajados en los diversos laboratorios de investigación que se dedican al tratamiento de imágenes de rostros.</p>
--	---

2.1 Marco filosófico o epistemológico

El reconocimiento facial es uno de los pocos métodos con alta precisión y baja tendencia a la intrusión, es altamente eficiente sin ser intrusivo. (Valverde, Criollo, Plua, Quinche, & Quiroz, 2014). En los años setenta el reconocimiento facial ha sido identificado por los investigadores en las áreas de seguridad, procesamiento de imágenes, hasta una visualización por computadora. Debido al alto grado de inseguridad, se presenta un análisis exhaustivo sobre las técnicas más eficientes para reconocimiento facial en el campo de visión por computador y posteriormente el desarrollo respectivo de un aplicativo para un reconocimiento facial en 2D y 3D. El presente trabajo de investigación considera como una herramienta importante al reconocimiento facial para aportar a la seguridad de una persona, un problema actual y fundamental que al momento es muy difícil superarla. Tomando como base este criterio es necesario hacer un análisis a la seguridad ciudadana desde el punto de vista filosófico o epistemológico.

La Filosofía se la considera como el conocimiento y entendimiento como disciplina, en los orígenes del planteamiento filosófico al empezar el estudio y lograr su finalidad y justificación, es decir las cosas esenciales. En ese sentido, la seguridad, esta orientada y dedicada hacia una justificación, asimismo toda actividad que tiene relación con la certeza, esta vinculada a la informática segura, la higiene y seguridad industrial, la protección a bienes, edificaciones y valores, las alarmas inteligentes, redes de visión remota, blindajes, pasivos infrarrojos, detectores de temperatura, etc., la finalidad de todas estas tecnologías de seguridad tienen su razón de existencia y necesita los siguientes elementos, tales como:

Técnicos: Como el armamento, los vehículos, sistemas informáticos, equipamiento específico para contrarrestar las distintas modalidades delictivas.

Administrativos: Como las leyes y reglamentos adecuados que permitan saber cómo actuar y utilizar a los elementos técnicos de la mejor forma.

Humanos: Que comprende el personal policial y de guardias privado, capacitado y actualizado en las distintas ciencias y técnicas que requieren los hechos que promueven la acción policial, así como el personal de guardia

Cabe mencionar que la seguridad también se le debe entender como política pública, es así que la seguridad ciudadana es parte del sistema de protección estatal a través de las diversas fuerzas del orden, el estado toma un importante papel en la seguridad interna del país ya sea en sus gobiernos locales como en los gobiernos regionales o la política de seguridad pública como un engranaje de todos los actores de la seguridad de un país, es decir como los habitantes de una determinada población encuentran en sus autoridades la suficiente tranquilidad y respaldo en cuanto a su seguridad y de sus bienes. Cada país es independiente en sus estrategias de seguridad pública y destinan diversos presupuestos para llevar a cabo su planeación estratégica.

Las diversas políticas de seguridad poblacional deben llevar la estrategia de apuntar el cumplimiento y garantía de los diversos marcos normativos que permitirán la pacífica convivencia entre la comunidad, la garantía del orden público es una de las responsabilidades del estado hacia su población. El tema del reconocimiento facial, es parte de la interacción del hombre con la computadora, esta a su vez se ha convertido en un disciplina (Valverde et al., 2014), denominada Interacción Humana y Computador (HCI), El mismo que examina y cubre todos los aspectos relacionados con el diseño e implementación de interfaces entre humanos y computadoras.

Determinado por la naturaleza u objetivos, el HCI en su forma natural engloba diversas disciplinas relacionadas con la informática, entre las que se encuentran el procesamiento de imágenes, el lenguaje de programación, la visión por computadora u otras, y las ciencias humanas como: factores humanos, ergonomía, psicología cognitiva u otras similares.

A futuro, según (Valverde et al., 2014) esta técnica de reconocimiento facial se puede ampliar para identificar a la persona que abre la caja registradora durante un intento de robo en un supermercado o pequeño establecimiento; o en un caso más extremo, se puede utilizar en cajeros automáticos donde se puede utilizar para validar mediante reconocimiento facial en lugar del código PIN actual.

2.2 Antecedentes de investigación

En las civilizaciones anteriores las personas vivían en ciudades pequeñas, donde se reconocían sin dificultad por su número limitado de habitantes; sin embargo, debido al rápido aumento poblacional y la movilidad humana, la identificación se volvió un proceso complicado, de tal manera que las sociedades innovadoras consideraron necesario implementar sofisticadas técnicas de registro de identificación. Considerando a la identificación como un conjunto de informaciones relacionadas a una persona, tales como: nombres, apellidos, lugar y fecha de nacimiento, etc. (Escobar, 2019)

En el año 1882, el policía Bertillon Alphonse presentó un algoritmo, el que años más tarde se constituiría en el primer sistema biométrico para la identificación de personas, fundamentado en rasgos físicos, al que llamó antropometría (Serratosa, 2013). Este sistema se lo considera como un sistema biométrico científico, mediante el cual la policía podría registrar a todos los criminales. Bertillon Alphonse se encargó de clasificar a los culpables por la altura y el rostro.

El reconocimiento facial tiene más de 50 años. Un equipo de investigación dirigido por Woodrow W Bledsoe (Ballantyne, Boyer, & Hines, 1996) realizó experimentos entre 1964 y 1966 para ver si las computadoras de programación podían reconocer rostros humanos. El equipo usó un escáner rudimentario para mapear la ubicación del nacimiento del cabello, los ojos y la nariz de la persona. La tarea de la computadora era encontrar coincidencias. No tuvo éxito. Bledsoe dijo: "El problema del reconocimiento facial se dificulta por la gran variabilidad en la rotación y la inclinación de la cabeza, la intensidad y el ángulo de iluminación, la expresión facial,

el envejecimiento, etc.". En aquella época, a las computadoras les resultaba más difícil reconocer rostros que vencer a los grandes maestros en el ajedrez. Han pasado muchos años, el tema de reconocimiento facial sigue en avanzada, sin embargo aún no se superan completamente estos problemas.

2.3 Reconocimiento facial

Un Sistema de reconocimiento facial (SRF), es una aplicación dirigida por un dispositivo electrónico (computador), el mismo que identifica automáticamente a una persona a través de una imagen digital. En la actualidad se manejan algunos conceptos respecto del reconocimiento facial, tales como: Ana Belén Moreno Díaz (Belén et al., 2004), considera que un SRF es un proceso que dada una o varias imágenes de una cara desconocida, selecciona entre las caras registradas en su base de datos, aquella con un mayor grado de similitud o parecido, devolviéndose la identidad de ésta. Así mismo Luis Blázquez Pérez (Pérez, 2013), considera que en el reconocimiento facial se realiza un proceso de extracción de rasgos, el mismo que puede ser tratado como: locales, globales y mixtos. El reconocimiento facial posee una variedad de ventajas sobre otros métodos biométricos tales como reconocimiento de huella digital y de iris; entre estas que es natural y no intrusiva además del hecho que el reconocimiento facial se podrá realizar a una distancia y de manera prudencial, (Cutipa, Cesar, Huanca, Posgrado, & Universitaria, 2017).

En relación a la seguridad, el reconocimiento facial es un método biométrico que comprende un extenso campo de aplicación en el área tecnológica. Así, se podría utilizar en menor escala en sistemas de acceso para las empresas, universidades, reconocimiento de amigos en las redes sociales, identificación en un celular, computadora o tablet, acceso a cajeros automáticos, etc. Y a gran escala, podría ser instrumentado por las autoridades policiales para la localización de personas que hayan cometido grave daño a la sociedad, también en el control de pasaportes, seguridad en calles, en estadios de fútbol, en aeropuertos, etc.

Según Cabello (Cabello Pardos, 2003), considera que una de las virtudes de un sistema de reconocimiento facial basado en visión artificial es su carácter no intrusivo, es decir que la persona no se siente invadido su intimidad, no tiene que realizar ninguna acción

para identificarse o someterse a ningún tipo de análisis. Otra ventaja es que permiten eliminar la memorización de códigos y además se evitaría llevar una identificación como: pasaporte, cédula de ciudadanía, etc.

En la actualidad los investigadores trabajan en sistemas que eviten las restricciones de condiciones controladas para adquirir robustez ante cambios de iluminación, edad, rotación, traslación, profundidad, expresiones faciales, oclusiones, cabellos, lentes, maquillaje, etc. A continuación, se considera que las etapas siguientes típicamente integran un sistema de visión artificial, las mismas que son:

- Adquisición de las imágenes
- Detección de la cara en la imagen
- Extracción de características y
- Reconocimiento

Finalmente hay que indicar que en la actualidad se cuenta con varias técnicas que permiten el tratamiento del reconocimiento, los mismos que serán tratados más adelante.

2.4 Trabajos relacionados

2.4.1 Reconocimiento facial utilizando características geométricas en 3D: PCA y SVM

En este trabajo, Moreno (Moreno & Sanchez, 2005) presenta un sistema de modelado 3D de la cara basado en un algoritmo de segmentación HK, que consiste en separar la cara en zonas bajo características establecidas.

Seis zonas y dos líneas se adquirieron de forma automática desde cada malla 3D, además se utilizan para obtener el principal rasgo facial que corresponde al coeficiente de Fisher (Correa, Salazar, & Ortiz, 2013), para encontrar las zonas del rostro. El modelo planteado ha sido comprobado en la implementación de dos sistemas de reconocimiento facial basado en PCA (Moreno & Sanchez, 2005), técnica que permite reducir la dimensionalidad de las imágenes y SVM (Support Machines Vectors) como clasificadores de patrones, determinando la forma en como se empareja esquemas bajo

control y entornos no controlados. Como resultado experimental se observa que las tasas de reconocimiento correctas son suficientes para implementar aplicaciones de reconocimiento de rostro real y que el modelo propuesto es firme. El uso de SVM en un medio ambiente controlado determina el 90,16% de aciertos y en un ambiente que no es controlado produce el 77,9%. Y con respecto al PCA identifica el 82% en ambientes controlados mientras que el 76,2% en ambientes no controlados, en esta investigación según (Moreno & Sanchez, 2004) se utiliza la base de datos GAVAB que contiene 420 imágenes faciales en 3D de 60 personas diferentes.

2.4.2 Máquina vector de soporte para reconocimiento facial

Este trabajo trata sobre el reconocimiento facial multi clase (Guo et al., 2001), indica que es posible utilizar un método de red de aprendizaje para reconocimiento de patrones bipartita, y se incorpora a SVM una estrategia de reconocimiento de árbol binario para manejar el problema de reconocimiento facial multi clase. En relación al rendimiento del SVM se identifica que se basa en la comparación con el enfoque eigenface estándar, y su algoritmo actual expone una línea característica más cercana NFL(Guo et al., 2001), (B. Pradhan, 2013), (Z. Qi, Y. Tian, 2013), (X. Peng, 2010) perteneciente a un método eficiente pero simple para el reconocimiento de modelos. Según (Guo et al., 2001), establece un árbol binario estratégico para el SVM utilizado para resolver el problema de reconocimiento multi clase como se muestra en la figura 2.1.




Figura 2.1 Estructura de un árbol binario para 8 clases para un reconocimiento (Guo et al., 2001)

Se propone construir un árbol binario para la clasificación, allí se tiene 8 clases, los números del 1 al 8 son los que codifican las clases, cabe señalar que estos números para la codificación pueden estar en forma arbitraria. Entonces se elige un número ganador que sale de la comparación entre cada par de clases, las clases acertadas o elegidas llegarán al nivel superior para realizar una nueva ronda de pruebas. Guo utiliza tres métodos de clasificación: Line nearest features (NFL) (Líneas características más cercanas) (Guo et al., 2001), Nearest Center (NC) (centro más cercano) y el SVM. Se realizaron dos experimentos que arrojaron los errores cometidos en cuanto al reconocimiento, el primero trabajó solo con una base de datos ORL (ORL, 1994), con un total de 40 personas participantes distintas con 10 poses cada una, obteniendo un error del 3% para el SVM, que fue el mínimo comparado con el 3,83% del CNN (Lawrence et al., 1997), y 3,125% del NFL (Li S. & Lu L., 1999), e igual forma se realiza un segundo experimento con 1079 imágenes de 137 personas correspondiente a una base de datos compuesta principalmente por cinco bases de datos como pueden ser: ORL, BERN, YALE u otras, por lo que se finiquita que el SVM tiene el menor error en reconocimiento con un valor del 8,79 %, seguido de NFL con un 9,72% y el NC con el 15,14 %.

2.4.3 Un enfoque de reconocimiento facial mejorado basado en vector discriminante común y SVM

En este trabajo (Wen, 2012), se propone un método mejorado de vectores comunes discriminantes, Improved Discriminative Common Vectors (IDCV) que utiliza SVM, y para demostrar su eficiencia realizan una comparación de otros siete métodos de reconocimiento facial, dos de los cuales incluyen SVM. En la realización de los experimentos se utilizan sistemas de base de datos compuestas por imágenes de rostros denominadas The ORL Base de datos de rostros y The AR base de datos de rostros. Al trabajar con ORL, utiliza 400 imágenes de 40 personas, cada imagen tiene un tamaño de 112 por 92, cada persona tiene 10 poses diferentes. AR utiliza 1300 imágenes, 50 femeninas y 50 masculinos, 13 poses por cada persona.

En el presente trabajo se demuestra que la técnica propuesta IDCV con SVM presenta un alto porcentaje de reconocimiento comparado con los otros siete métodos, con cada sistema de base de datos utilizadas. Los vectores comunes se generan en el caso de que

el número de individuos sea menor o igual a la dimensionalidad del espacio de individuos. El algoritmo Vectores Comunes Discriminantes por sus siglas en inglés (DCV) es una variación del algoritmo Análisis Discriminante Lineal (LDA), en el que se observa que DCV consigue mejores resultados de reconocimiento facial que LDA. Sin embargo, no resuelve el problema de multiclase del algoritmo LDA. Se propone el método Mejorado vectores comunes discriminantes (IDCV), ajustando el criterio Fisher de LDA en DCV, para evaluar internamente las matrices de dispersión entre clases.

En este estudio se utiliza máquinas de soporte vectorial para la clasificación de los datos de entrenamiento y prueba, con la función kernel Gaussiana. En la tabla 2.2 se muestra los resultados obtenidos en el experimento, en el cual la técnica IDCV con SVM demuestra un alto nivel de desempeño. A continuación, en la tabla número 2.2, se muestra una síntesis de los resultados obtenidos bajo estas las técnicas aplicadas.

Tabla 2.2 Resumen de los resultados obtenidos para siete entrenamientos con 8 técnicas (Wen, 2012)

TECNICAS	EFICIENCIA	KERNEL
EIGENFACE	93,87%	Gaussian
LDA	93,8%	
PCA-SVM	95,56%	
DCV-NN	96,67%	
KDCV-NN	97,75%	
DCV-RBF	97,77%	
KDCV-RBF	97,65%	
IDCV-SVM	98,92%	

2.4.4 Un nuevo método de reconocimiento facial basado en una máquina rápida de mínimos cuadrados vectoriales

Este trabajo (Kong & Zhang, 2011), propone un nuevo método para el reconocimiento facial mediante la combinación de Análisis de Componentes Independientes por sus siglas en inglés (ICA)(Bartlett, 1998) y SVM. Como primer punto se separa las características del rostro utilizando el algoritmo Informax, después se procede a implementar el reconocimiento de rostros aplicando el algoritmo rápido de mínimos cuadrados (FLS-SVM). ICA es una tecnología de procesamiento de señal estadística desde 1990, la misma que puede extraer características de imágenes de rostros

estadísticamente independientes de una mezcla de señales. La idea de ICA es constituir un conjunto de variables aleatorias aplicando funciones básicas, en donde los componentes son estadísticamente independientes. Así, cada imagen de la cara es linealmente consistente de imágenes bases y factores. Cada imagen x es representada por el producto de los vectores $u * A$, en donde $u = (u_1, \dots, u_n)$ que son factores independientes estimados unos de otros, y $A = (a_1, \dots, a_n)$ son imágenes bases calculados.

En el experimento se autentifica el algoritmo de reconocimiento facial utilizando la database de cara ORL. Esta base de datos contiene imágenes de rostros de 40 personas de tamaño 28 por 28, todas tienen diez imágenes faciales determinando la expresión o si usa gafas o no. Finalmente se elige al azar cinco imágenes como conjunto de entrenamiento, y otras como un conjunto de prueba, todas las imágenes se recortan al tamaño 28 por 28 y son modificadas según la posición de los ojos situándolos manualmente. Los resultados obtenidos en el experimento, se presenta a continuación en la tabla 2.3

Tabla 2.3 Resultados obtenidos en el reconocimiento (Kong & Zhang, 2011)

Method of extracting features	classifier		The number of principal component	Correct recognition ratio(%)
PCA	FLS-SVM	PK (d = 2)	80	94.50
		PK (d = 3)	80	95.50
		GK ($\alpha = 0.7$)	80	96.00
ICA	FLS-SVM	PK (d = 2)	60	96.00
		PK (d = 3)	60	96.50
		GK ($\alpha = 0.7$)	60	97.50

De acuerdo a los resultados obtenidos se visualiza que ICA con el clasificador FLS-SVM resultó el más efectivo, con un reconocimiento máximo del 97.5%.

2.4.5 Reconocimiento facial R-KDA con SVM no lineal para bases de datos de múltiples vistas

En la presente investigación realizada por (Devi, Laishram, & Thounaojam, 2015), intenta desarrollar una aplicación de reconocimiento combinando que involucra el R-KDA con SVM no lineal, y al mismo tiempo los resultados obtenidos se comparan con los resultados de R-KDA y K-nn vecinos respectivamente, obteniendo mejores resultado. Este trabajo (Devi et al., 2015) propone un sistema de reconocimiento con dos fases: La fase de extracción de características y la de reconocimiento de caras, para la primera utiliza R-KDA y SVM no lineal para la segunda. Se plantea una serie de pasos involucrados en la extracción de características usando R-KDA (Para el entrenamiento), los mismos que tienen una entrada y salida.

Entrada: Conjunto de formación de imágenes, el número de muestras de entrenamientos por clase y el parámetro de kerne RBF.

Salida: Subespacio de R-KDA, y se considera los siguientes puntos:

Cálculo de la matriz usando el nucleo RBF para el conjunto de entrenamiento.

- Se realiza una matriz $m \times n$.
- Se calcula la matriz de nucleo usando RBF de la prueba.
- Se determina la proyección usando subespacio R-KDA con la matriz núcleo.

A continuación, presenta los pasos para la extracción de características usando R-KDA (para conjunto de pruebas), en la que se proyecta las muestras de prueba al subespacio del núcleo discriminante, este se obtiene a partir del conjunto de entrenamiento.

Entrada: Prueba de datos, ejemplos de entrenamiento, el espacio del núcleo discriminante, la varianza de Gauss para el kernel RBF.

Salida: Subespacio R-KDA de conjunto de pruebas.

- Calcula el tamaño del conjunto de prueba (m) y el tamaño del conjunto de aprendizaje (n).
- Se crea una matriz de tamaño $m \times n$.

- Se calcula la matriz de núcleo usando núcleo RBF de la prueba.
- Se determina la proyección usando subespacio R-KDA con la matriz del núcleo.

Se plantea una secuencia de pasos para el reconocimiento de rostros, el mismo que plantea utilizar un clasificador SVM, este encuentra un hiperplano óptimo que la fracción más grande posible de los puntos de la misma clase en el mismo lado, maximiza la distancia de cualquiera de las clases al hiperplano. La determinación del hiperplano óptimo es un problema de optimización exclusiva y se puede solucionar utilizando técnicas de programación cuadrática.

La base de datos UMIST que se utiliza, esta compuesta de 564 imágenes de 20 personas. Cada uno compuesta por una serie de poses de perfil, los sujetos cubren diferentes aspectos como es la raza, genero, apariencia. Hay que tener en cuenta que los archivos están en formato pgm, aproximadamente 220×220 píxeles de 256 tonos de gris. Para el propósito experimental se toman 18 sujetos, 10 poses diferentes.

Finalmente, a partir del resultado del análisis, se observa que la combinación de R-KDA con SVM no lineal supera a la combinación R-KDA con k-nn. La tasa de reconocimiento correcta obtenida con el algoritmo propuesto es de aproximadamente el 30% y la función kernel utilizada es la función base radial (RBF), tomando en cuenta que se trata de un conjunto de caras de multiples vistas.

2.4.6 Modificaciones al método de Eigenphases para el reconocimiento facial basado en SVM

Según (Olivares-Mercado, Toscano-Medina, Sánchez-Pérez, Nakano-Miyatake, & Pérez-Meana, 2016) establecen las modificaciones para el método de eigenphases, con el fin de aumentar su precisión. La primera modificación se denomina Eigenfaces de dominio espacial local (LSDE), en el cual la imagen del rostro está segmentada por primera vez en bloques de $N \times N$ píxeles, en las que las magnitudes se normalizan. La segunda modificación se la identifica como local frequency domain eigenphase (LFDE), en la cual después de la segmentación las magnitudes de los píxeles se normalizan y se calcula el espectro de fase en forma independiente, luego se concatenan todos los bloques y se aplica PCA (Benitez-Garcia, Olivares-Mercado,

Aguilar-Torres, Sanchez-Perez, & Perez-Meana, 2012) para disminuir la dimensionalidad del problema.

Se utiliza la base de datos AR (Martínez, 2014) compuesta por 9360 rostros, trabaja con 120 personas (65 hombres y 55 mujeres). Efectúa dos entrenamientos distintos con 1200 imágenes cada una, igualmente para poner en práctica el SVM se utiliza la biblioteca LIBSVM (Chang & Lin, 2013), y la función utilizada para la tarea de entrenamiento y reconocimiento es el Kernel polinomial. En cuanto a la identificación usando SVM, utiliza algoritmos como: gabor, wavelet, LSDE3, LSDE6, LFDE3, LFDE6 distribuido en dos grupos o conjuntos. De los cuales el principal LFDE3 es el que mayor probabilidad tiene, además con el primer conjunto de datos tiene un acierto del 85,92% y en con el segundo conjunto un 97,92% de acierto.

2.4.7 Detección de expresión facial basada en la característica de fusión de PCA y LBP con SVM

Este trabajo trata sobre el Análisis de componentes principales (PCA), el mismo que es un método de extracción basado en características estadísticas de grises globales de toda la imagen. Los autores (Luo, Wu, & Zhang, 2013), implementan el método híbrido de análisis de componentes principales y un patrón binario local (LBP). LBP elimina las características de escala de grises locales de la zona de la boca, que contribuyen en mayor medida a reconocimiento de expresiones faciales, para ayudar a las características globales de la escala de grises en el reconocimiento de expresiones faciales.

El reconocimiento se diseña tomando en cuenta el ambiente de VC6.0, y el dispositivo de entrada es una cámara PHILIPS. En este experimento, el conjunto de muestras de entrenamiento contiene siete expresiones faciales diferentes y la suma de ellas es de 50. La mitad de ellas tiene mejor iluminación y las otras no tienen un buen nivel de iluminación y cada imagen del conjunto de entrenamiento se normaliza en tamaño pequeño de 24×24 . Se realiza una comparación entre PCA+SVM y PCA+LBP+SVM. De entre ellos se obtuvo un reconocimiento promedio de: para el PCA+SVM el más alto fue de 93,75% correspondiente a la expresión neutral y para la combinación PCA+LBP+SVM un reconocimiento del 96,25% tanto para la expresión neutral y

alegre, en ambos casos utilizando un kernel RBF. Cabe anotar que este reconocimiento de imágenes lo aplica desde el punto de vista de las emociones.

2.4.8 Reconocimiento facial mediante la clasificación de modelos vectoriales para la autenticación de usuarios

Este trabajo de investigación según (Lin, Wang, & Tsai, 2016), desarrolló un sistema de reconocimiento facial en línea mediante la formación de un clasificador SVM basado en los rasgos faciales del usuario asociado a la transformada y un patrón binario local espacialmente mejorado. Este sistema de validación cruzada y SVM asociado utilizó la base de datos Olivetti Research Laboratory de rasgos faciales para la solución de problemas de precisión de clasificación. Los resultados experimentales mostraron que el error de clasificación disminuyó con un aumento en el tamaño de las muestras de entrenamiento. De allí que la precisión global del reconocimiento de la cara es más del 97%, para un tamaño de datos de 168 y 341 imágenes de baja y alta resolución respectivamente. En cuanto a la transformada, se manifiesta que esta debe permitir cambios sólo en la extensión de tiempo, pero no en la forma, sobre la base de funciones de base adecuadas. Los rasgos faciales más comunes aparecen como parte de la información de baja resolución, mientras que la parte de alta resolución contiene la mayor parte de los rasgos faciales, tales como las variaciones locales de la iluminación, la expresión y el vestido. A la inversa, la transformación wavelet inversa combina las dos partes de la imagen de la cara en la imagen original a través de un proceso de reconstrucción de información.

Esta investigación utiliza 3 funciones kernels: El lineal, Polinomial y el RBF (Función de base radial), de los cuales el que dio mejores resultados fue el Lineal, tanto en el entrenamiento como en las pruebas. En comparación con los sistemas existentes, el sistema tiene una serie de ventajas importantes, tales como:

- 1) Proporciona el beneficio de completa protección de la privacidad a través de almacenamiento distribuido, en el que la tarjeta inteligente almacena imágenes de diferentes expresiones faciales y una base de datos contiene registros de imágenes de la cara.

2) El modelo utiliza varios diagramas analíticos de capas para la conversión de ondas y un patrón dual de un espectro de un histograma espacialmente mejorado con una función LBP, y mejora la precisión de reconocimiento facial.

2.4.9 Extracción de características basado en SVM para reconocimiento facial

Según los autores (Kim, Park, Toh, & Lee, 2010), el objetivo es encontrar un subespacio eficaz para la discriminación de identidad que servirá para la extracción de características del rostro. Este se ha extendido para hipersuperficie no lineal, sin embargo, sigue habiendo limitaciones para el LDA no lineal para hacer frente a las aplicaciones físicas en virtud de factores ambientales complejos. Las limitaciones incluyen el uso de una función de covarianza común entre cada clase, y la dimensionalidad limitada inherente a la definición de la dispersión entre la clase. Dado que estos problemas son inherentemente causados por la propia definición de criterio de Fisher, que no pueden solventarse en el marco LDA (Zhao, Fu, Ji, Tang, & Zhou, 2011) convencional, utiliza el kernel no lineal, en este caso un polinomial.

Esta situación establece incorporar una dispersión basada en el margen entre la clase y un proceso de regularización para resolver un problema, para esto rediseña una matriz de dispersión entre la base de los márgenes de SVM para facilitar la extracción de características de una manera eficaz y fiable. A continuación se realiza una regularización de la matriz de dispersión dentro de la clase, en este proceso se realizan algunos experimentos empíricos que se llevan a cabo para comparar el método propuesto con varias otras variantes del método LDA (Zhao et al., 2011) mediante las bases de datos FERET(P.J. Phillips, H. Moon, S. Rizvi, 2000), (Sadhya & Kumar, 2019), (Benini, Khan, Leonardi, Mauro, & Migliorati, 2019), AR(Robert, 2014) y CMU-PIE(Sim, Baker, & Bsat, 2003). Con esta base de datos se realiza tres experimentos respectivamente. Con FERET hay 1702 imágenes que corresponden a 256 personas, con AR hay 1680 imágenes que corresponden a 120 personas y finalmente con CMU-PIE existen 1840 imágenes que corresponden a 68 personas. Todas estas imágenes corresponden al tamaño 56 x 46 píxeles. El porcentaje de error del Análisis discriminante basado en SVM resulta ser el mínimo en relación a las técnicas KFD, el Análisis discriminante generalizado GDA, y el Análisis discriminante directo KDDA. Los mejores resultados obtenidos fueron que con la base

de datos (FERET, ARE, CMU, PIES). El método SVM-DA obtuvo los errores más mínimos como; 8,5%, 8,6% y 9,5% respectivamente.

2.4.10 Evaluation of facial recognition techniques using SVM, wavelets and PCA

Aquí se plantea una evaluación de la utilización de diferentes métodos para el reconocimiento de rostros (Gumus, Kilic, Sertbas, & Ucan, 2010). Utiliza técnicas de extracción de características como la descomposición wavelet y el método Eigenfaces que está basado en el Análisis de Componentes Principales (PCA). Después de generar vectores característicos, clasificadores de distancia, utiliza máquinas de vectores soporte (SVMs) para la etapa de clasificación. Examina la exactitud de la clasificación de acuerdo al aumento de la dimensión del conjunto de entrenamiento, así como utiliza una función del núcleo elegido para el clasificador SVM. Como prueba utiliza la base de datos de rostros ORL(ORL, 1994) que se conoce como una base de datos de cara estándar para las aplicaciones de reconocimiento facial que incluyen 400 imágenes de 40 personas. Al final de la tarea global de separación, se obtuvo la precisión de la clasificación del 98,1% con enfoque Wavelet-SVM para el entrenamiento de 240 imágenes, teniendo en cuenta medios ponderados de reconocimiento en el basado Wavelet que dieron mejores resultados que el enfoque basado en PCA. Además, se compararon las tasas de reconocimiento de acuerdo con el género y notando que los individuos de sexo masculino tienen una mayor tasa de reconocimiento (89,38%) que las mujeres (81,41%).

2.4.11 Diseño uniforme de lentes múltiples como herramienta de selección de modelo SVM para reconocimiento facial

De acuerdo a los autores (W. Li, Liu, & Gong, 2011), plantean que la principal dificultad de la selección del modelo de la máquina de vector de soporte (SVM) es un coste computacional elevado. El autor propone primero un método de búsqueda de diseño uniforme multiobjetivo (MOUD) como una herramienta de selección de modelo SVM, y luego aplica este clasificador SVM optimizado para el reconocimiento de rostros. Debido a que se reemplaza el criterio objetivo único por criterios multiobjetivos y se adopta un diseño uniforme para buscar puntos experimentales que

se dispersan uniformemente en todo el dominio experimental, el MOUD puede reducir el coste computacional y mejorar la capacidad de clasificación simultáneamente.

Los experimentos se ejecutan en el benchmark UCI, y utiliza las bases de datos de cara de Yale (Deng, 2008) y CAS-PEAL-RI (Gao, W., Cao, B., Shan, S., Chen, X., Zhou, D., Zhan, 2008). Los resultados experimentales muestran que el método propuesto supera significativamente otros métodos de búsqueda de modelos, especialmente para el reconocimiento facial. Además de las bases de datos utilizados, también se hizo uso de la función del núcleo polinomial. De acuerdo a los resultados, con las dos bases de datos utilizados, YALE con 165 imágenes y CAS-PEAL-RI con 100 imágenes, muestran a MOUD como una herramienta de selección de modelo SVM que puede efectivamente aliviar el coste computacional de la selección del modelo SVM, y al mismo tiempo puede aumentar la capacidad del reconocimiento facial, en este caso se alcanzó el mayor resultado de clasificación del 96,67%.

2.4.12 Método de selección de muestra de carcasa convexa de subclase principal para SVM en reconocimiento facial

Según los autores (Zhou, Jiang, Tian, & Shi, 2010), el SVM tiene un defecto vital, es que necesita un gran cálculo para tareas de aprendizaje a gran escala, para lo cual propone una selección de muestras para superar este problema.

Con el fin de reducir las muestras de entrenamiento sin sacrificar la precisión del reconocimiento, este trabajo presenta un nuevo método de selección de muestras denominado Kernel Subclass Convex Hull (KSCH), que trata de seleccionar muestras límite de cada casco convexo de clase. Este método de selección de la muestra es más adecuado para el SVM no lineal, el mismo que trabaja con tres kernels: El lineal, el Quad y el RBF, por lo que las muestras seleccionadas por este método pueden representar eficientemente el conjunto de entrenamiento original y apoyar la clasificación SVM. Para los resultados finales experimentales se utilizó las bases de datos faciales MIT-CBCL (Weyrauch, Heisele, & Blanz, 2004) y el UMIST (Graham & Mallinson, 1998) se verificó que el método de selección de muestras KSCH puede seleccionar menos muestras de alta calidad para mantener la precisión de reconocimiento de SVM. Finalmente, con ese método KSCH, se logra reducir el

tamaño de conjunto de entrenamiento en el menor tiempo de ejecución con una alta precisión de clasificación. En este sentido se aplica el entrenamiento con 180 imágenes para los tres kernels de un total de 1032 imágenes, con una precisión de clasificación del 100%.

2.4.13 Un nuevo modelo de clasificación SVM + NDA con una aplicación de reconocimiento facial

En este trabajo de investigación (Khan, Ksantini, Ahmad, & Boufama, 2012), los autores coinciden en que SVM es una metodología de clasificación potente. Este trabajo introduce un nuevo modelo SVM + NDA (Análisis discriminario no paramétrico) que puede ser visto como una extensión a la SVM mediante la incorporación de alguna información parcialmente global, especialmente, la información discriminatoria en la dirección normal a la decisión frontera. Esto también puede considerarse como extensión de la NDA donde los vectores de soporte mejoran la elección de k-vecinos más cercanos en el límite de decisión incorporando información local.

La extensión SVM es considerada NDA, puede trabajar con datos heteroscedasticos y no normales, también evita el problema del tamaño de la muestra, se puede reducir al modelo SVM clásico, para que de esa manera utilice los softwares existentes. Se plantea el uso de un modelo de kernel llamado KSVM + KNDA para conocer problemas no lineales con la base de datos reales. En general se puede indicar que la técnica SVM+NDA presenta mejores resultados que los demás en cuanto al grado de precisión, sobrepasando el 98% en la base de datos. Es así que se trabajó con la base de datos ORL (Yu & Yang, 2001), un total de 400 imágenes frontales de 40 personas, variando en pose, iluminación, expresión y detalles específicos, además utiliza la base de datos YALE de 165 imágenes, y la base de datos ESSEX con 153 personas que contiene 20 imágenes por cada una y finalmente la base de datos JAFFE con 123 imágenes.

2.4.14 Un enfoque de reconocimiento facial en 3D eficiente basado en la fusión de características novedosas locales de bajo nivel

Según Lei (Lei, Bennamoun, & El-Sallam, 2013), en su trabajo manifiesta que en las últimas dos décadas, el reconocimiento de caras 2D ha sido un tema de gran interés en la mayoría de las personas dedicadas a la investigación, sin embargo debido a la presencia de varios factores como: pose, iluminación, edad, estado de ánimo, etc., han sido factores dominantes que han obstaculizado la eficiencia de muchas aplicaciones de reconocimiento en 2D. Para poder superar estas limitaciones y retrocesos inherentes, muchos de los investigadores se han inclinado por el área del reconocimiento facial en 3D, con el objetivo de tener el potencial adecuado para lograr una mayor precisión de reconocimiento. Igualmente indica que los algoritmos de reconocimiento facial 3D se pueden clasificar en diferentes categorías, de acuerdo con la modalidad utilizada, por ejemplo: Multimodal (RGBD) y Profundidad 3D (Lei et al., 2013).

En este trabajo de investigación según los autores (Lei et al., 2013) señalan un enfoque de reconocimiento facial en 3D basado en características geométricas de bajo nivel que se recogen en diferentes regiones como; ojos, frente y nariz, como se ilustra en la figura 2.2. Estas zonas son relativamente influenciadas en menor cantidad por las deformaciones que son causadas por las expresiones faciales, estas características extraídas revelan ser eficientes y robustas en presencia de las expresiones faciales. Un descriptor de histograma basado en una región calculada a partir de estas características se aplica para representar de manera única un rostro en 3D.




Figura 2.2 Región basada en representación facial 3D (Lei et al., 2013)

En este trabajo, el autor utiliza la Máquina de Vector de Soporte (SVM) entrenada como un clasificador basado en los descriptores de histograma propuestos para reconocer cualquier cara de prueba. El enfoque propuesto ha sido probado en bases de datos FRGC v2.0 y BU-3DFE a través de una serie de experimentos y ha logrado un alto rendimiento de reconocimiento, del cual se deduce que RBF- SVM que utiliza es el que obtiene un rango más alto con el 94,5%.

2.4.15 Extracción de funciones 3D multiescala y combinación con una aplicación de reconocimiento facial 3D

Los autores (Fadaifard, Wolberg, & Haralick, 2013) establece una representación superficial multi esalar para las formas 3D que se basa en la teoría del espacio-escala. La representación, Curvature Scale-Space 3D (CS3), es adecuada para medir la similitud entre superficies (parciales) que tienen una posición, una orientación y una escala desconocida. La representación CS3 se obtiene mediante la evolución de las curvaturas superficiales de acuerdo con la ecuación de calor. Este proceso de evolución produce una pila de curvaturas superficiales cada vez más suavizadas que son útiles para la extracción de puntos clave y cálculos de descriptor. Demuestra que este enfoque de cálculo de clave y descriptor supera a muchos de los principales métodos.

Las principales ventajas de esta representación es la eficiencia computacional, menores requerimientos de memoria y facilidad de implementación.

2.4.16 Múltiples estrategias para mejorar el reconocimiento automático de expresiones faciales en 3D

El presente trabajo (X. Li, Ruan, An, Jin, & Zhao, 2015), considera que la investigación sobre el reconocimiento de la expresión facial 3D ha atraído un gran número de interés debido a su superioridad a los trabajos en 2D y ha sido muy promovido en los últimos años, su funcionamiento necesita mejorar y la estructura de la base de datos debe ser anlaizada para que de esa manera mantenga su automatización, debido a que la estructura de la malla de modelos de la cara 3D no se puede aplicar directamente a las operaciones algebraicas. Plantea una estructura similar a una imagen para representar los modelos, de manera que las operaciones algebraicas se pueden aplicar directamente para analizar datos 3D. Basándose en esta estructura de imagen, se debe emplear las estrategias de esquemas de división irregulares y los bloques de entropía para mejorar la precisión de reconocimiento.

El autor propone tres estrategias para el reconocimiento facial, siendo las siguientes:

1. Una imagen como estructura para modelos de normalización de imágenes 3D
2. Esquemas irregulares de división para mantener la integridad de la estructura local
3. Bloques de entropía para enfatizar la contribución de las diferentes regiones.

El primera instancia se utiliza para procesar y normalizar los modelos faciales en 3D, de modo que los modelos se adapten a las características, mientras que en la segunda y tercera, las estrategias pueden aplicarse por separado o conjuntamente para reforzar las características de clasificación. Se considera que la extracción de características es el paso clave para un sistema de reconocimiento, pero no se puede aplicarse directamente a los modelos 3D ya que son ruidosos y complejos. Aunque algunos investigadores consideran usar los puntos de referencia para representar datos faciales en 3D para la extracción de características, dan ciertos problemas, es así que la ubicación automática de referencia en el modelo 3D sigue siendo un problema abierto

que afecta en gran medida la calidad de las características (X. Li, Ruan, An, et al., 2015).

En la primera estrategia se plantean algunas fases, como:

- a) La fase de procesamiento, que a su vez contempla cuatro pasos que lo resumimos como:
 1. Extracción de la máscara $-(1 / 2)^a$ y $(1 / 2)^a$ de la parte central de los modelos 3D y ajuste del punto con el valor de profundidad más alto como la punta de la nariz;
 2. Dejar que todos los puntos sustraigan los elementos de la punta de la nariz, de modo que la punta de la nariz se mantenga como el origen de las coordenadas;
 3. Consultar la resolución del modelo triangular original y construir una nueva coordenada para la estructura de la imagen cuya resolución estará determinada por la resolución original del modelo triangular dividido por un espacio uniforme;
 4. Volver a muestrear los valores de profundidad en el modelo triangular para analizar cada nodo en la estructura de la imagen usando el algoritmo Qhull. Las mismas operaciones se realiza para la información del color.

- b) Luego viene la fase de normalización, que considera que se debe normalizar con todos los modelos en imagen como estructura (profundidad, color), del mismo tamaño para que puedan analizarse en lotes. Sin embargo, el área de las caras 3D normalizadas es siempre determinados por puntos de referencia que son difíciles de detectar directamente modelos 3D, pero son manejados con madurez utilizando imágenes 2D. Por lo tanto, esta normalización se logra principalmente sobre la base del efecto interactivo entre el valor de profundidad y la información de color, como se ilustra en la figura 2.3.




Figura 2.3 Face de Normalización (X. Li et al., 2015)

En la segunda estrategia sobre los esquemas irregulares de división para mantener la integridad de la estructura local, se propone hacer divisiones en el rostro, como se observa en la figura 2.4, donde se tiene la figura original (a), luego una división regular (6 x 5) (b), otra división regular 8 x 8 (c), división irregular 6 x 5 (d), división irregular 8 x 5 (e), y finalmente, división irregular 8 x 7 (f)




Figura 2.4 Esquemas de división descritos en base a una imagen de textura neutral (X. Li et al., 2015)

Como proceso final se plantea la tercera estrategia, que consiste en crear bloques de entropía para enfatizar la contribución de las diferentes regiones, donde finalmente, se extrae las características faciales locales de cada bloque, y posteriormente se concatenan en un vector de características para representar la característica facial. Sin embargo, las contribuciones de las diferentes regiones en las imágenes de la cara son diferentes, como se ilustra en la figura 2.5.




Figura 2.5 Pesos de diferentes bloques de una imagen. El bloque más brillante tiene un mayor peso; viceversa (X. Li et al., 2015)

Por ejemplo, el bloqueo de la nariz que es menos afectado por las expresiones faciales, puede contribuir menos que la región de la boca. Por lo tanto, los diferentes bloques deben ser dados pesos diferentes para enfatizar sus contribuciones antes de generar el vector de características. Para resolver este problema, este trabajo propone la estrategia de entropía ponderada. Como se ha analizado anteriormente, la contribución de cada bloque debe agregarse antes de alcanzar el vector de rasgos faciales. La contribución de una región se puede medir por la cantidad de información que contiene, que puede calificarse por su entropía de acuerdo con la definición de la teoría de Shannon.

En este trabajo (X. Li, Ruan, An, et al., 2015) se concluye que la estrategia I es eficaz para el reconocimiento de la expresión facial 3D. Todas las características extraídas

de los datos faciales normalizados (incluyendo los valores de profundidad, las imágenes de textura y su fusión) proporcionan resultados sorprendentes, lo que implica que los datos faciales 3D normalizados por la estrategia I se mantienen discriminativos. Al momento de realizar el experimento para evaluar las estrategias propuestas, se lo trabajó sobre la base de datos BU-3DFE. Esta base de datos estática está especialmente diseñada para el análisis de expresión facial 3D y fue capturada de 100 sujetos: 56 mujeres y 44 hombres de diferentes ascendencias étnicas y edades. Cada sujeto realizó seis expresiones faciales típicas, a saber, enojo, disgusto, felicidad, miedo, tristeza y sorpresa en cuatro niveles, y una cara neutral se conserva, por lo que hay totalmente 2500 modelos de cara en esta base de datos. Igualmente se toma como clasificador la máquina vectorial de soporte (SVM), basada en la Minimización del Riesgo Estructural (SRM). Además, se utiliza el núcleo función gaussiana.

2.4.17 Un método de reconocimiento facial 3D-2D basado en la onda extendida de Gabor que combina la detección de bordes y curvaturas

De acuerdo al trabajo realizado por (Torkhani, G., et al), una principal limitación en los sistemas de reconocimiento facial en 3D (FR) es su susceptibilidad a las dificultades de escaneo y ambientes no controlados como pose, iluminación y variedad de expresión. Este trabajo propone un nuevo marco de reconocimiento facial basado en la deformación de malla (3D a 2D) y combinado de la curvatura de Gabor y mapas de borde. Los vectores características extraídos se clasifican utilizando la excepcional robustez de SVM (Torkhani et al., 2017). A pesar de las mejoras significativas en el reconocimiento de rostros en 3D, aún no se ha logrado un cierto criterio de precisión que satisfaga los propósitos industriales y comerciales (Torkhani et al., 2017).

Este trabajo, propuesto comienza por preprocesamiento de Imágenes 3D (reduce el ruido, orificio de llenado, suavizado de malla), usando un bloque de operaciones de mejora de malla. Luego aplica la conversión de espacio de 3D a 2D para reducir la cantidad de vértices de malla. Esencialmente, esta reducción de datos permite preservar solo los vértices y la alta prominencia de puntos. Después, se procede a extraer las características usando mapas de curvatura y los mapas de los bordes extendida de Gabor, para completar la extracción de características. Las características

(vectores) resultantes se clasifican utilizando SVM. El método propuesto se ilustra en la figura 2.6




Figura 2.6 Diagrama de bloques de sistema 3D FR propuesto (Torkhani et al., 2017)

El autor recomienda trabajar con datos de malla, porque es adecuado para el modelado de superficies 3D. Las imágenes pueden tener ruidos gaussianos sintéticos, artefactos y agujeros. En la etapa de mejora de la malla, los ruidos y los artefactos agudos se tratan usando el filtrado laplaciano. En el siguiente paso, agujeros y brechas que ocurren durante el escaneo, el proceso se corrige usando el algoritmo de restauración. Finalmente, se aplica una curva laplaciana más suave para homogeneizar la superficie de la malla y restringir los bordes filosos.

El objetivo propuesto por el modelo de malla deformada 3D es realizar conversión de espacio 3D a 2D preservando y proyectando vértices con características de alta saliencia. Una malla triangular 3D está formada por un conjunto triangular de facetas, cada faceta es una superficie construida con tres vértices y conectado por tres bordes. El ajuste de mínimos cuadrados es la técnica más eficiente y comúnmente utilizada en el modelado de malla 3D que permite encontrar la mejor función de adaptación hasta que se alcanza la convergencia. El último paso es lograr subdivisiones de malla para mantener la estabilidad y el control de la superficie (Torkhani et al., 2017).

Respecto de la Curvatura de Gabor extendida y mapas de los bordes, este trabajo aprovecha las ventajas del impacto sobresaliente de las ondas de Gabor en la simulación de la forma de la cara, explotando propiedades visuales pertinentes, localizando frecuencias de características especiales y el control de la selectividad de orientación. En la teoría de la wavelet Gabor convencional, cada filtro es una onda sinusoidal modulada por una envolvente gaussiana diseñada utilizando una orientación y una escala espacial o una frecuencia. (Torkhani et al., 2017) El algoritmo planteado se implementa en el entorno MATLAB R2016 utilizando un PC con una CPU de 2.7 Ghz y una memoria RAM de 8G. Algunas de las dificultades en el desempeño de aplicaciones inteligentes en las imágenes de caras en 3D son la falta de disponibilidad de Bases de datos 3D públicas. Los presentes experimentos se llevan a cabo en dos diferentes bases de datos: CASIA (Academia China de Ciencias, Instituto of Automation) (Casia, 2011) y GAVAB (Group of ArtificialVision, Biometría Artificial)(Gavab, n.d.)

La base de datos CASIA (Casia, 2010) Contiene 123 sujetos escaneados utilizando una cámara USB Logitech 3D bajo condiciones no controladas como oclusiones y variedad de pose. Las imágenes son también efectivas en expresiones faciales como la risa, la sonrisa, el disgusto, felicidad y tristeza La presencia de accesorios y oclusiones lo hace un buen candidato para probar el rendimiento de este enfoque 3D FR.

La base de datos GAVAB(Gavab, n.d.), se emplea porque posee abundantes expresiones acentuadas, varias iluminaciones para cada muestra de los 61 sujetos. Esta diversidad facial impone flexibilidad y solidez al programa propuesto para manejar los numerosos problemas de FR causados en cada caso. Este trabajo además indica que los modelos 3D pueden presentar ruidos de escaneo como ruidos gaussianos, ruidos gaussianos blancos, frecuencia picos e impulsos.

2.4.18 Un algoritmo P-KCCA eficiente para el reconocimiento facial 2D-3D usando SVM

Este trabajo (Kamencay, Hudec, Benco, Sykora, & Radil, 2015), presenta sistema de reconocimiento de rostros basado en una combinación de análisis de componentes principales (PCA) y Kernel Canonical Correlation Analysis (P-KCCA) usando la

Máquina de Vector de Soporte (SVM). Primero, el método P-KCCA se utiliza para detectar y extraer las características importantes de las imágenes de entrada. Este método permite hacer coincidir la imagen de cara con datos 2D con los datos de cara 3D registrados. Las características resultantes se clasifican utilizando el método SVM. El propuesto método fue probado en la bdd TEXAS con 200 sujetos. Los experimentos en la bdd TEXAS indican resultados interesantes desde el punto de vista del éxito, la velocidad y la robustez del reconocimiento del algoritmo de reconocimiento de rostros. Comparamos el rendimiento de nuestro método de reconocimiento facial propuesto a otros métodos comúnmente utilizados. Los resultados experimentales muestran que la combinación del método P-KCCA el uso de SVM logra un mayor rendimiento en comparación a los algoritmos PCA, CCA y KCCA solos.

El autor presenta su trabajo basado en este esquema general, como se ilustra en la figura 2.7

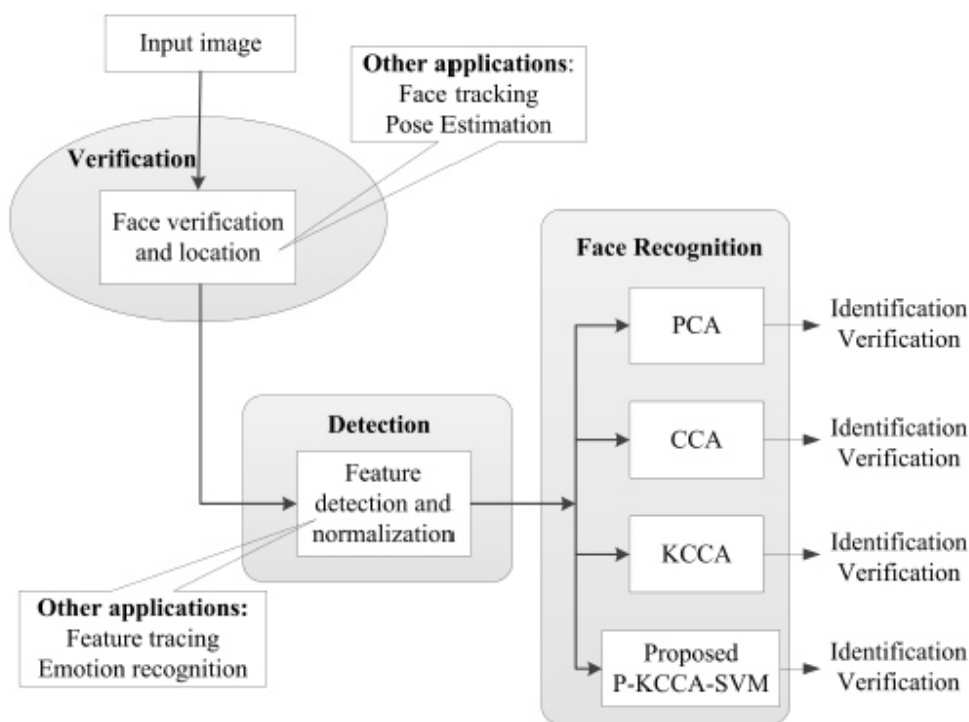


Figura 2.7 Configuración del sistema de reconocimiento facial (Kamencay et al., 2015)

El método propone dos enfoques de reconocimiento facial, a saber, PCA con algoritmo KCCA y SVM. PCA lo ocupa para disminuir la dimensión del espacio de la función de la cara. Mientras que KCCA es utilizado para identificar y cuantificar la asociación entre dos conjuntos de variables, es una variante no lineal de CCA. El SVM se utiliza como clasificador para verificar la cara candidata. El objetivo del método propuesto es reconocer un objeto 2D que contiene un rostro humano.

- Las técnicas simples que utiliza para el reproceso es eliminar el ruido y el llenado de orificio.
- Se usó el filtro mediano para la eliminación de ruido y se aplicó interpolación bidimensional para el llenado de orificios.

Los experimentos se han realizado en la base de datos TEXAS, que se desarrolló en el Laboratorio para Ingeniería de Imagen y Video de la Universidad de Texas en Austin. La base de datos de cara de TEXAS contiene pares de imágenes faciales en 2D y datos faciales en 3D de 200 caras. Las imágenes son de tamaño 751x 501 píxeles. Cada valor en z-dimensión se representa en formato de 8 bits con el valor más alto de 255 asignado a la punta de la nariz y un valor de 0 asignado al fondo. (Kamencay et al., 2015). El conjunto de entrenamiento contiene pares 3D de 50 sujetos, mientras que la fase de prueba, contiene 200 imágenes de rostro elegidas al azar de la base de datos de caras TEXAS3DFRD con variaciones en expresiones faciales. Después de calcular las caras propias usando PCA, los vectores de proyección se calculan para el conjunto de entrenamiento y luego se almacenan con la función KCCA en la base de datos. El vector de característica se asigna a la imagen usando KCCA, esta arquitectura se llama P-KCCA. La Clasificación se realiza comparando los vectores de proyección de las imágenes de la cara de entrenamiento con el vector de proyección de la imagen de la cara de entrada. Esta comparación se basa en el SVM. La fase de entrenamiento y la fase de prueba del método propuesto se muestran en la figura 2.8

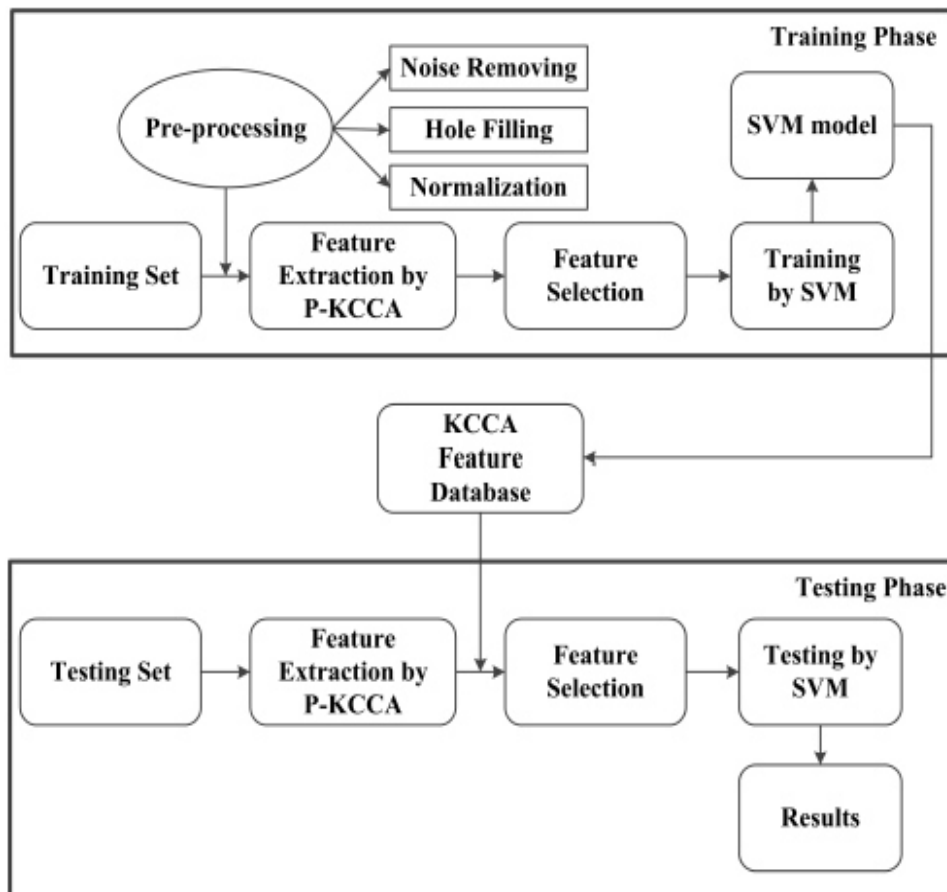


Figura 2.8 Algoritmo P-KCCA de diagrama de bloque propuesto (Kamencay et al., 2015)

El esquema principal de este experimento se ilustra en la figura 2.9.

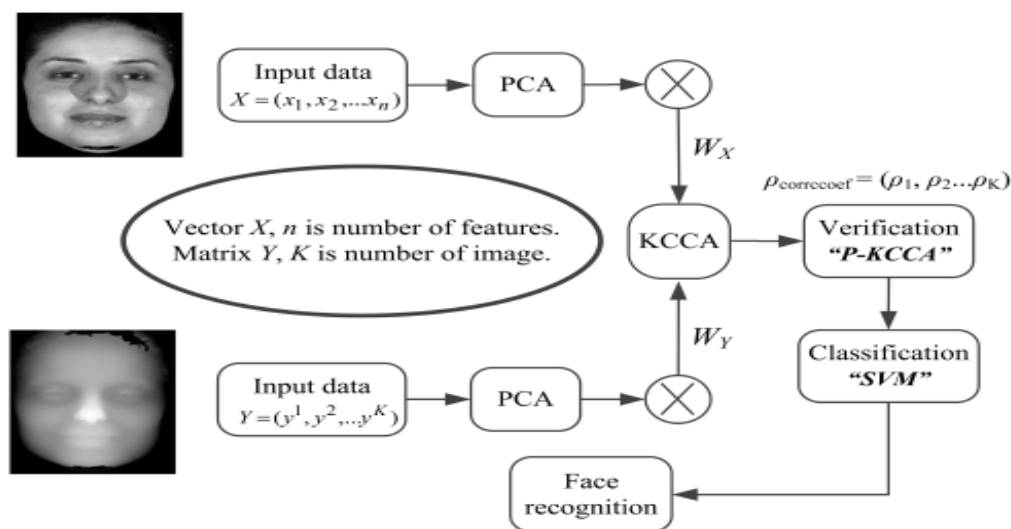


Figura 2.9 Algoritmo P-KCCA usando SVM (Kamencay et al., 2015)

El mejor resultado de reconocimiento facial se obtuvo con este algoritmo P-KCCA, alcanzando un máximo del 93% con 50 sujetos y un mínimo de 88% con 200 sujetos. En general se observa una mayor precisión en todos algoritmos cuando el número de sujetos es menor.

2.4.19 Reconocimiento de expresiones faciales 3D estáticas y dinámicas: una investigación exhaustiva

En este trabajo realizado por Sandbach, et al. (Sandbach, Zafeiriou, Pantic, & Yin, 2012), se examina los avances recientes en reconocimiento de expresiones faciales 3D y 4D. Se habla sobre desarrollos en adquisición y seguimiento de datos faciales en 3D, y presenta bases de datos 3D / 4D disponibles actualmente para el análisis de expresiones faciales 3D. La técnica de adquisición utilizada para capturar datos 3D es especialmente importante al recopilar expresiones faciales, ya que el equipo ha utilizarse puede afectar el nivel de imposición sobre el sujeto (Sandbach et al., 2012), cambiando así su comportamiento significativamente. Existe una variedad de dispositivos y técnicas que han sido empleado previamente para adquisición de datos de expresión facial en 3D, incluyendo el uso de la reconstrucción de una sola imagen, las tecnologías de luz estructurada y dos métodos diferentes para algoritmos de reconstrucción estéreo: fotométrico estéreo y multivista estéreo.

Ante la gran dificultad de la presencia mínima de bases de datos de caras en 3D, este trabajo (Sandbach et al., 2012), presenta un resumen de algunas de ellas, las mismas que podrán ser de gran utilidad para investigaciones futuras sobre reconocimiento facial en 3D, como se ilustra en la tabla 2.4.

Tabla 2.4 Bases de datos de rostros en 3D (Sandbach et al., 2012)

Nombre bdd	Tamaño	Contenido
Chang et al. (Y. Chang, M. Vieira, M. Turk, 2005)	6 adultos	6 expresiones básicas
BU-3DFE (L. Yin, X. Wei, Y. Sun, J. Wang, 2006)	100 adultos	6 expresiones básicas en 4 niveles de intensidad
BU-4DFE (L. Yin, X. Chen, Y. Sun, T. Worm, 2008)	101 adultos	6 expresiones básicas

Bosphorus (A. Savran, N. Alyuz, H. Dibeklioglu, O. Celiktutan, B. Gokberk, B. Sankur, 2008)	105 adultos inc. 27 actores	24 Aus, neutral, 6 expres. Básicas, oclusiones
ICT-3DFRE (G. Stratou, A. Ghosh, P. Debevec, 2011)	23 adultos	15 expresiones: 6 básicas, 2 neutrales, 2 cejas, 1 cara arrugada, 4 miradas
Tsalakanidou et al. (F. Tsalakanidou, 2010)	52 adultos	11 Aus a 6 expresiones básicas
Benedikt et al. (L. Benedikt, D. Cosker, P. Rosin, 2010)	94 adultos	Sonrisas y expresión verbal
D3DFACS (D. Cosker, E. Krumhuber, 2011)	10 adultos inc. 4 FACS expertos	Hasta 38 AU por sujeto
Blanz Vetter (V. Blanz, 1999), (“3D morphable models UR,” 2011)	200 adultos	Rostros neutrales
ND-2006 (T. Faltemier, K. Bowyer, 2008)	888 adultos	Neutral y 5 exps: H, D, Sa, Su, al azar
CASIA (Casia, 2011)	123 adultos	Neutral y 5 exps: sonrío, río, A, Su, ojos cerrados
Gavbd (A. Moreno, 2004)	61 adultos	3 expresiones: abierto / cerrado, sonriente y al azar
York 3D (Y. Bdd, 2011)	350 adultos	Neutral y 4 exps: H, A, ojos cerrados, cejas levantadas
Texas (T. Bdd, 2010)	105 adultos	Neutral y sonriente, o hablando con los ojos abiertos / cerrados

2.4.20 Reconocimiento facial 3D-2D con normalización de pose e iluminación

De acuerdo a (Kakadiaris et al., 2017) se propone un marco 3D-2D para el reconocimiento facial que es más práctico que 3D-3D, más preciso que 2D-2D. Para el reconocimiento de caras 3D-2D, los datos se componen de datos de forma 3D y textura 2D y las sondas son imágenes bidimensionales arbitrarias. Se presenta un sistema 3D-2D (UR2D) que se basa en un modelo de cara deformable en 3D que permite el registro de datos en 3D y 2D, la alineación de la cara, la normalización de la postura y la iluminación. Durante la inscripción, los modelos 3D específicos del tema se construyen usando datos 3D + 2D. Para el reconocimiento, las imágenes 2D se representan en un espacio de imagen normalizado utilizando los modelos 3D de galería y la estimación de proyección 3D-2D basada en hitos. Los autores (Kakadiaris et al., 2017), trabajan en la base de datos UHDB11 3D-2D con imágenes 2D bajo gran

iluminación y variaciones de postura y la bases de datos FRGC v2.0 3D-2D con imágenes faciales frontales.

El trabajo realizado propone (Kakadiaris et al., 2017) conjuntamente con las bases de datos mencionadas, un sistema de reconocimiento de rostros asociado (UR2D), basado en la ecualización de las condiciones de postura e iluminación entre un par de galería sonda a igualar. Para ello, se adapta un modelo de cara deformable a los datos tridimensionales para registrar las texturas faciales de galería y sonda, obtenidas con el mismo modelo, en un sistema de coordenadas bidimensional común. El proceso proporciona una representación de rostros basada en la apariencia en el espacio de la imagen geométrica y una alineación de las áreas faciales visibles bajo una pose estimada.

Las condiciones de luz de la sonda se transfieren localmente a la textura de la galería a través de un esquema de reactivación bidireccional basado en un modelo explícito de reflectancia de la piel. Las evaluaciones cuantitativas en una base de datos diseñada para pruebas de reconocimiento facial 3D-2D, bajo grandes variaciones en las condiciones de postura e iluminación, demostraron que el rendimiento de reconocimiento facial 3D-2D supera al 2D-2D, y puede aproximarse a 3D-3D. El marco propuesto puede ser potencialmente adaptado para el reconocimiento facial 2D asistido por 3D en bases de datos desafiantes de imágenes faciales (por ejemplo, mediante el uso de un conjunto externo de modelos 3D ajustados), finalmente este trabajo presenta una comparación de reconocimiento facial a través de varios tipos y métodos, de los cuales se observa que el tipo 3D-2D es el que mejor resultado se obtiene con un porcentaje del 90.8% de acierto, como se ilustra en la tabla 2.5 (Kakadiaris et al., 2017).

Tabla 2.5 Reconocimiento facial en UHDB11 utilizando sistemas 3D-3D, 2D-2D y 3D-2D (Kakadiaris et al., 2017)

Method	Type	Verification				RR1(%)
		VR@10 ⁻³	VR@10 ⁻²	EER	AUC	
PP5 (Pittsburgh Pattern Recognition, 2011)	2D-2D	0.242	0.431	0.211	0.826	68.2
L1 (L1 Identity Solutions)	2D-2D	0.519	0.588	0.230	0.845	62.6
GOS(Z)	2D-2D	0.046	0.191	0.279	0.778	32.9
GOS(E)	2D-2D	0.064	0.186	0.305	0.764	29.1
UR2D(Z)	3D-2D	0.544	0.763	0.072	0.975	77.0
UR2D-R(Z)	3D-2D	0.695	0.851	0.056	0.986	85.6
UR2D(E)	3D-2D	0.793	0.915	0.043	0.988	89.9
UR2D-R(E)	3D-2D	0.817	0.939	0.037	0.991	90.8
UR3D (Kakadiaris et al., 2007)	3D-3D	0.890	0.894	0.108	0.905	90.2
UR3D-C (Ocegeda et al., 2011a)	3D-3D	0.892	0.895	0.101	0.906	90.1

2.5 Técnicas tratadas en el reconocimiento facial en dos dimensiones (2D) y en tres dimensiones (3D)

Dentro de las técnicas que contribuyen al proceso de reconocimiento, podemos citar varias, tales como:

- Análisis Principales Componentes (PCA) (Moreno & Sanchez, 2005), (Stan, L., & Jain, 2011), (Samaria, F., & Harter, 1994)
- K vecinos más cercanos (K_NN) (Manso, 2017)
- Redes neuronales artificiales (RNA) (Nacelle, 2009), (Laura et al., 2015)
- Máquinas de vectores soporte (SVM)(Vapnik, 1998), (Cabello Pardos, 2003), (Betancour, 2005), (G. Pajares, 2008), (Romero, 2011), (Zhan & Shen, 2005), (Montoya, 2015), (Acosta, Pablo, & Gonz, 2014), (Blanco Oliver, Pino Mejías, & Lara Rubio, 2014).
- Análisis Discriminante Lineal (LDA) (Devi et al., 2015)
- Análisis de componentes independientes (ICA) (Bartlett, 1999)

A continuación, una breve descripción de estas técnicas aplicables en un proceso de reconocimiento facial 2D y 3D.

2.5.1 Análisis de Componentes Principales (PCA)

Esta técnica, también es conocida como método de eigenfaces. El análisis de componentes principales (PCA) según (Moreno & Sanchez, 2005), se utilizó para

monitorear imágenes de rostros, como base de una técnica de reconocimiento de rostros. De esta modalidad se derivan otras como el método Fisherfaces (Análisis Discriminante Lineal de Fisher). Ambas técnicas: eigenfaces y fisherfaces se han experimentado en bases de datos de un gran número de imágenes proporcionando resultados óptimos cuando las imágenes han sido captadas bajo condiciones de adquisición uniformes. Según Stan y Jain (Stan, L., & Jain, 2011), este modelo de Análisis de Componentes Principales (PCA) es una técnica que consiste en reducir la dimensionalidad basado en la separación del número deseado de componentes principales de los datos multidimensionales.

El estudio de los principales componentes fue inicialmente visto en el campo de la estadística y su desarrollo más tarde fue insertado en el campo de redes neuronales. El modelo está vinculado con la Transformada de Karhunen-Loève (KLT). Esta técnica asume que un conjunto dado de N imágenes de muestra $\{x_1, x_2, \dots, x_N\} \in \mathbb{R}^n$. Cada imagen pertenece a una de las m clases $\{C_1, C_2, \dots, C_m\}$. Se define la matriz de dispersión total S_T como.

$$S_T = \sum_{k=1}^N (x_k - \mu)(x_k - \mu)^T \quad (1)$$

Donde μ es la media de los datos. El Análisis de Componentes Principales determina la proyección ortogonal φ como.

$$y_k = \varphi^T x_k \quad \text{donde } k = 1, \dots, N \quad (2)$$

Esto maximiza el determinante del total de la matriz de dispersión de la muestra proyectada y_1, \dots, y_N :

$$\varphi_{opt} = \arg \max_{\varphi} |\varphi^T S_T \varphi| \quad (3)$$

Las propiedades principales del PCA son resumidas por las siguientes ecuaciones:

$$x \approx \varphi_k y \quad (4)$$

$$\varphi_k^T \varphi_k = I \quad (5)$$

$$E\{y_i y_j\}_{i \neq j} = 0 \quad (6)$$

Reconstrucción aproximada, orto normalidad de la base φ_k , y principales componentes correlacionados $y_i = \varphi_k^T x$ respectivamente (Samaria & Harter, 1994).

2.5.2 K vecinos más cercanos (K-*nn*)

De acuerdo a Manso (Manso, 2017), K-NN es un método sencillo y eficaz, que presenta sensibilidad a la presencia de atributos irrelevantes. Por ello, resulta muy importante para evaluar subconjuntos de atributos calculados con las técnicas de selección presentadas.

2.5.3 Redes neuronales artificiales (RNA)

De acuerdo a (Nacelle, 2009), una red neuronal artificial (RNA) es un esquema de sistemas informáticos distribuida inspirada en la estructura del sistema funcional de los seres vivos. La arquitectura de este tipo de red neuronal se forma conectando varios procesadores elementales, siendo éste un sistema adaptivo que posee un algoritmo para ajustar sus pesos (parámetros libres) para alcanzar los requerimientos de desempeño del problema basado en muestras representativas. Es fundamental determinar que la propiedad de más importancia de las redes neuronales artificiales es su capacidad de conocer partiendo de un sinfín de patrones de entrenamientos, en ese sentido, es idóneo de localizar un patrón que sea ajustable a los datos.

En el proceso de formación denominado entrenamiento de una red puede ser observado o no observado. La observación consiste en ejercitar la red a partir de una agrupación de datos o patrones entrada y salida. La finalidad del algoritmo de instrucción es ajustar los pesos de la red para que la salida producida por la red neuronal para una entrada determinada sea lo más cercana posible a la salida real. Es decir, la red neuronal intenta encontrar un modelo para el proceso desconocido que generó la salida. Opuestamente, el no observado presenta sólo un conjunto de patrones de entrada a la red neuronal, y la finalidad de este algoritmo de aprendizaje es ajustar los pesos de la red de manera que la red encuentre alguna estructura o configuración presente en los datos. Según (Laura et al., 2015), considera que las redes neuronales son muy importantes, por su capacidad para generalizar la información y por su tolerancia al ruido. Una de las áreas informáticas que más las utiliza es la de reconocimiento de patrones, especialmente en Minería de Datos y Procesamiento de Señales Temporales.

Por último los autores (Kasar, Bhattacharyya, & Kim, 2016), señalan que una red neuronal es una herramienta de clasificación muy potente y robusta que se puede utilizar para pronosticar los datos renombrados y los desconocidos. Una red neuronal es utilizable en muchas áreas, como la interpretación de escenas visuales, reconocimiento de voz, reconocimiento facial, reconocimiento de huellas digitales, reconocimiento de iris, etc. Una red neuronal está compuesta por una red de neuronas artificiales también conocidas como nodos, los mismos que están conectados entre sí, se le asigna un valor basado en su fuerza: inhibición (el máximo es -1.0) o excitación (el máximo es +1.0). Si el valor de la conexión es elevado, la conexión es fuerte, de la misma manera en el interior de cada nodo se incorpora una función de transferencia. Existen tres tipos de neuronas en una red neuronal artificial que son; nodos de entrada, nodos ocultos y los nodos de salida como se muestra en la figura 2.10.

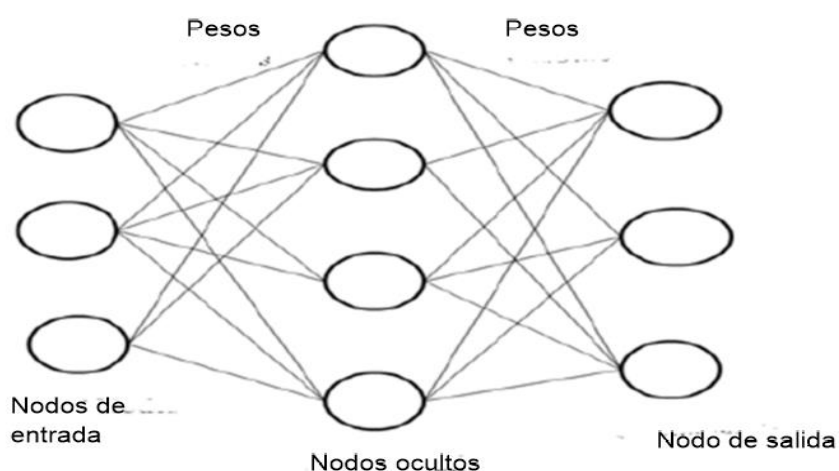


Figura 2. 10 Red neuronal artificial (ANN)

Este trabajo de investigación (Kasar et al., 2016), realiza una comparación entre algunas técnicas de redes neuronales para reconocimiento facial, de los mismos establece que la fusión entre la Red de propagación hacia atrás y Función de base radial (BNP y RBF) logra alcanzar un 97,56% de efectividad en reconocimiento facial.

2.5.4 Máquina de vectores soporte (SVM)

Según Cabello(Cabello Pardos, 2003) las SVM son técnicas consideradas como clasificadores, además se considera un algoritmo que define un modelo para cada clase, de manera que esta clase a la que pertenece cada elemento se calcule con los

valores de los datos del elemento, según (Betancour, 2005) considera que la teoría de las Support Vector Machines corresponde a una técnica eficiente. La diferenciación más importante de las máquinas de vectores de soporte frente a otros algoritmos de instrucción es la aplicación de un nuevo principio inductivo, que busca minimizar el riesgo estructural, además del uso de un kernel o función del kernel, lo que le confiere una gran capacidad de generalización, incluso cuando el conjunto de entrenamiento es pequeño.

Realizando un poco de historia, la teoría del SVM fue desarrollada por Vladimir Vapnik (Vapnik, 1998) por los años 90, aparece en trabajos sobre la teoría del aprendizaje estadístico. El SVM es una técnica considerada como un clasificador, aunque también se la utiliza en el campo de la regresión, agrupamiento, multclasificación, de allí que ha estado inmerso en algunos campos como la visión artificial, reconocimiento de caracteres, medicina. El SVM se considera un algoritmo que permite definir un modelo para cada clase y se calcule a partir de los valores de los datos que definen el elemento, como se muestra en la figura 2.11.




Figura 2.11 Esquema general del SVM

Las SVM son consideradas como máquinas de soporte vectorial, y en terminología inglesa se la considera como “support vector machines”, se la considera también como un clasificador de patrones. Al inicio se la utilizó para una clasificación biclase, que permitía proyectar datos en espacios de mayor dimensión que los originales para conseguir una mayor separabilidad (G. Pajares, 2008).

Esta técnica contempla 2 fases: Una primera de entrenamiento y otra de decisión. En esta primera fase, el principal objetivo es hallar una función de decisión apta de dividir las dos clases. En el caso de que las clases no sean divididas con facilidad, entonces los vectores de aprendizaje se proyectan hacia un espacio de mayor dimensión mediante funciones de transformación no lineal, que puede ser una función kernel, la

misma que permite adaptar la distribución de patrones para poder separar los mismos sin ninguna dificultad. En esta fase, se ingresa cualquier conjunto X con n muestras, y en la salida habrá un conjunto Y compuesto por los elementos 1 y -1. En conclusión, el conjunto de entrenamiento estará compuesto por pares (X, Y) , donde $i = 1, 2, 3, 4, \dots, n$, donde:

$$X_i \xrightarrow{R} Y_i \in \{1, -1\}$$

La función de decisión se define como:

$$f(x) = \sum_{i=1}^n a_i y_i H(x_i, x) - b \quad (7)$$

Esta función representa una combinación lineal de núcleos centrados en cada punto.

a_i : representa un parámetro donde $i = 1, 2, \dots, n$.

Los patrones x_i relacionadas con a_i diferentes de cero se denominan vectores soporte, gráficamente estos vectores soporte son aquellos que se encuentran más próximo al hiperplano encontrado.

Tenemos diferentes tipos de núcleos o funciones kernel, siendo las siguientes:

- Lineal:

$$H(x, y) = x' y \quad (8)$$

- Función de base radial

- Gaussiana:

$$H(x, y) = e^{\left\{ \frac{-\|x-y\|^2}{2\sigma^2} \right\}} \quad (9)$$

$$e = 2,7182\dots$$

- Exponencial:

$$H(x, y) = e^{\left\{ \frac{-\|x-y\|}{2\sigma^2} \right\}} \quad (10)$$

$$e = 2,7182\dots$$

- Polinomios:

$$H(x, y) = (1 + (x, y))^d \quad (11)$$

- Función sigmoide:

$$H(x, y) = \tanh(\rho(x, y) + \gamma) \quad (12)$$

Donde (x, y) se refiere al producto interno con ρ y γ parámetros de ajuste.

La técnica SVM se la ilustra en la figura 2.12, de la siguiente manera:




Figura 2.12 Esquema gráfico de una máquina de vectores de soporte

La segunda fase, que es la decisión consiste en ingresar ahora los nuevos x , y y se espera que la técnica determine la clase a la que corresponde conforme al signo de polaridad (+, -) de $f(x)$, una vez que se pasó la primera fase. Se considera a los vectores soporte a aquellos datos más representativos de todos los utilizados hasta el punto en que al utilizar los vectores soporte se llegaría a una misma solución que cuando se utilizarían el resto de patrones, es decir que los vectores de soporte contienen el mayor grado de información y no se necesitaría del resto de patrones, en tal sentido se ahorraría espacio en el almacenamiento de los resultados del aprendizaje obtenidos. La distancia mínima

desde el hiperplano que separa las clases al patrón más cercano se denomina **margen** τ . Un hiperplano resulta inmejorable si es el máximo margen.

La distancia que existe entre el hiperplano y un patrón z esta dada por:

$$d = y_k \frac{|f(x)|}{\|w\|} \quad (13)$$

A su vez:

$$w = \sum_{i=1}^n a_i y_i x_i \quad (14)$$

Esta expresión es equivalente a $\sum_{\text{vectores soporte}} a_i y_i x_i$

A la hora de calcular la función de decisión, la constante b se obtiene en base a:

$$a_i \{y_i |(w \cdot x_i) + b| - 1\} = 0 \quad (15)$$

Tomando en cuenta esta distancia τ , todas las muestras de entrenamiento cumplirán la siguiente desigualdad:

$$\frac{y_k f(x_k)}{\|w\|} \geq \tau \quad (16)$$

$$k = 1, 2, 3, \dots, n$$

$$y = \{+1, -1\}$$

El problema de encontrar el hiperplano óptimo se reduce a encontrar el valor de w que maximice el margen τ . Se da la posibilidad que exista un número alto de soluciones que difieren solo en el escalado de w . Para disminuir este número se fija la escala de acuerdo a la siguiente igualdad:

$$\tau \|w\| = 1 \quad (17)$$

Es decir maximizar el margen τ es lo mismo que minimizar la norma w .

En el espacio que separa dos clases podemos tener varios hiperplanos, pero existe un hiperplano óptimo, como se indican en las figuras: 2.13 y 2.14




Figura 2. 13 Un esquema de dos clases con varios hiperplanos




Figura 2. 14 Un esquema de dos clases con un hiperplano óptimo

Es decir, un hiperplano separador se dirá óptimo si y solo si equidista del ejemplo más cercano de cada clase (Leon, 2016). Figura 2.14

A continuación tenemos dos clases de ejemplos separables:

a) Separable linealmente




Figura 2. 15 Un esquema de un caso separable linealmente

b) No separable linealmente

En el gráfico 2.16 se indica un ejemplo, el cual no se puede separar por medio de una función lineal, es decir a través de un hiperplano separador, entonces se debe recurrir a una técnica consistente en la transformación del espacio original mediante una función no lineal hacia un espacio Hilbert dotado de un producto escalar denominado función kernel ó SVM kernelizada, como se indica en la figura 2.17 (Leon, 2016)




Figura 2. 16 Un esquema de un caso no separable linealmente




Figura 2. 17 Esquema de un ejemplo transformado a un caso separable linealmente

A pesar que el SVM originalmente fue pensado para resolver problemas de clasificación binaria, en la actualidad se utilizan para resolver otros tipos de problemas como: regresión, agrupamiento, multclasificación, igualmente son muy utilizadas en: visión artificial, reconocimiento de caracteres, categorización de texto, clasificación de proteínas, procesamiento de lenguaje natural, análisis de series temporales, etc. (Carmona, 2016)

Software para SVM

La mayor parte del software existente está escrito en C o C++, como la biblioteca libsvm, ganadora del premio, que proporciona una robusta y rápida implementación

de SVM y produce resultados muy competentes en la mayoría de problemas de regresión y clasificación. También destacan SVMlight, SVMtorch, Royal Holloway Support Vector Machines, mySVM y M-SVM. Otras bibliotecas proveen de interfaces para MATLAB como The MathWorks, SVM and Kernel Methods Matlab Toolbox o MATLAB Support Vector Machine Toolbox y la SVM toolbox for Matlab (Leon, 2016)

La fortaleza de un SVM considera las siguientes:

- El entrenamiento es relativamente fácil
- No hay óptimo local, como en las redes neuronales.
- Se escalan relativamente bien para datos en espacios dimensionales altos.
- El compromiso entre la complejidad del clasificador y el error puede ser controlado explícitamente.
- Datos no tradicionales como cadenas de caracteres y árboles pueden ser usados como entrada a la SVM, en vez de vectores de características.

La máquina de vectores de soporte tienen algunas particularidades que las han puesto en superioridad encima de otras técnicas populares de clasificación y / o regresión. alguna de estas características que se destacan es que son pertenecientes a las disciplinas del aprendizaje automático o aprendizaje estadístico. La estrategia sobre este modelo de aprendizaje nos permite que las máquinas aprendan con los ejemplos; las salidas correctas para algunas entradas. La diferencia más notable de las máquinas de vectores de soporte frente a otros algoritmos de aprendizaje es la aplicación de un nuevo principio inductivo, que busca minimizar el riesgo estructural.

Decimos que el proceso de aprendizaje automático no es dependiente necesariamente de la cantidad de atributos, lo que permite un comportamiento excelente en problemas de alta dimensionalidad. Uno de los problemas más comunes es lo que se conoce como “sobreentrenamiento”, que ocurre cuando los datos de entrenamiento se han aprendido muy bien, pero ejemplos nunca antes vistos (datos de verificación) no se puede clasificar bien, es decir, una mala generalización del modelo. Otro problema que puede surgir cuando la característica de los datos de entrenamiento no se ha aprendido muy bien, por lo que se realiza una clasificación errónea. El experimentador debe tener en

cuenta estas atenciones al ajustar el modelo porque la precisión y el éxito de la predicción dependen de ellas.

La SVM fue ideada originalmente para la resolver los problemas de clasificación binarios en los que las clases eran linealmente separables. Por esta razón se conocía también como hiperplano óptimo de decisión en justificación a la solución entregada como aquella en la que se clasifican precisamente toda la disponibilidad de muestras, ubicando el hiperplano de separación lo más alejado posible de todas las demas. Las muestras más contiguas al hiperplano de optimización en disgregar son reconocidas como muestras críticas o vectores soporte, que es lo que da nombre a la SVM.

Esta metodología se encuentra propiamente relacionada con dificultades de clasificación y regresión. Es así que un conjunto de ejemplos de entrenamiento (de muestras) podemos etiquetar las formas y entrenar una SVM para edificar un modelo que prediga la clase de otra muestra. Instintivamente, una SVM es un modelo que simboliza a los puntos de muestra en el espacio, desglosando las clases por un espacio lo más grande en su posibilidad. Cuando las nuevas muestras se ponen en relación con dicho modelo, en función de su acercamiento pueden ser clasificadas a una u otra clase. Más formalmente, una SVM construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta (o incluso infinita) que podría ser usada en problemas de clasificación o regresión. Una buena separación entre las clases permitirá una eficaz clasificación.

Según Romero (Romero, 2011), de acuerdo a los resultados obtenidos en su investigación aplicada a la medicina, tuvo que emplear la técnica de clasificación de imágenes basados en algunos clasificadores como SVM, KNN, funciones lineales discriminantes, árboles de decisión o redes neuronales, alcanzando el mejor resultado con SVM, con una precisión del 90,3%, trabajó con un clasificador SVM con un núcleo basado en función de base radial (RDF).

La máquina de vectores soporte tiene abundantes aplicaciones, como el reconocimiento de escritura, identificación de un interlocutor, categorización de textos, en ese sentido. Otra de las aplicaciones fundamentales de la SVM, que es en la que se concentra el presente análisis, está en el campo de la visión computarizada, más

en concreto en los sistemas de detección de rostros. Así como también el SVM ha sido también aplicada en la medicina de acuerdo a un artículo publicado por Zhan & Shen (Zhan & Shen, 2005), sobre tejidos de próstata, igualmente Montoya & otros (Montoya, 2015) aplican el MVS en la identificación de patrones sísmicos en ficheros 2D mediante máquinas de soporte vectorial, de igual forma hay un trabajo de Acosta & otros (Acosta et al., 2014) sobre diagnóstico y detección de fallas para la dinámica lateral de un vehículo utilizando Máquinas de Soporte Vectorial Multiclase. Así mismo tenemos un trabajo de Oliver & otros (Blanco Oliver et al., 2014) sobre un caso de estudio de un Modelado de auxilio financiero con el apoyo de Máquina de Vectores.

2.5.5 Análisis discriminante lineal (LDA)

De acuerdo a (Devi et al., 2015), el LDA es uno de los métodos para la reducción de dimensiones y una técnica de clasificación al maximizar la relación entre la varianza de clase y la varianza dentro de la clase en cualquier conjunto de datos en particular. El LDA fue desarrollado por R.A. Fisher en 1936, también conocido como “Discriminante lineal de Fisher”. También se la conoce como una técnica supervisada utilizada para clasificación de patrones en términos de reducción de dimensionalidad.

2.5.6 Análisis de componentes independientes (ICA)

De acuerdo a Alvarez & Giraldo (Alvarez & Giraldo, 2008), ICA es comprendido para el problema de separación ciega de fuentes (proceso que se fundamenta en la estadística independiente de las señales, que son generadas en procesos autosuficientes y consiste en la recuperación de las señales originarias a partir de las combinaciones observadas). Asimismo recibió gran atención en las redes neuronales y procesamiento de señales, en causa de la potencial de sus aplicaciones en estas áreas. También la forma se ha extendido a su aplicación en el área de procesamiento de imágenes observando el hecho de que ésta técnica pudiera aplicarse en algún dominio donde un arreglo de N entradas forma una mezcla lineal de un conjunto incognito de fuentes estadísticamente independientes. ICA puede ser usada en aplicaciones reales en imágenes, los aplicativos con frecuencia prefieren utilizar ICA sobre PCA debido a que ICA es capaz de producir bases no ortonormales y no está restringido a mediciones de covarianza como PCA. Sin embargo, plantean utilizar PCA para estimar una matriz

de cruces que pueda ser utilizada como inicialización para ICA. Asimismo con ICA se encuentran una representación fuerte de la imagen en la cual tanto las estadísticas de segundo como las de más alto orden se encuentran decorrelacionadas.

El análisis de componentes independientes (ICA) es una generalización de PCA que codifica las dependencias de orden superior en la entrada además de las correlaciones. Las representaciones para el reconocimiento facial se desarrollaron a partir de los componentes independientes de las imágenes faciales. Las representaciones de ICA fueron superiores a PCA por reconocer rostros en las sesiones y cambios en la expresión. (Bartlett, 1999)

2.6 Bases de datos de caras

En esta subsección se presentan algunas bases de datos importantes en 2D y 3D

2.6.1 Bases de datos de caras 2D

En la actualidad tenemos diferentes tipos de bases de datos con imágenes faciales. Se puede anotar que se diferencian por la forma en la que fueron adquiridos las imágenes, mediante qué tipo de dispositivos, así como el procesado al cual fueron sometidas quizá en algún laboratorio especializado. De allí que las características más importantes de una imagen podría ser su tamaño, formato, dimensión (2D, 3D), etc. A continuación, se describen algunas bases de datos muy utilizadas dentro del reconocimiento facial:

2.6.1.1 Base de datos de rostros Yale

La base de datos de rostros Yale fue construida en 1997, la cual está conformada por 165 imágenes en escala de grises de 15 individuos (11 imágenes por individuo), ésta contempla diversas expresiones de rostro, iluminación y uso de anteojos. En la figura 2.18, se indica la sesión de imágenes completa para un individuo de estudio de la base de datos Yale (Shao, Chen, Wang, Li, & Deng, 2014).



Figura 2. 18 Ejemplo de sesión completa para una persona de la base de datos de Yale (Shao et al., 2014).

2.6.1.2 Base de datos Yale extendida B

En el 2001, Georhiades, Belhumeur y Kriegman lograron ampliar el trabajo previo de la base de datos Yale. La base de datos de rostros Yale Extendida B, contiene 16.128 imágenes de 640 X 480 en escala de grises de 28 individuos bajo 9 poses y 64 condiciones de luminosidad (Chan & Tahir, 2013). En ese sentido, se incorporó en la base de datos un conjunto de imágenes recortadas con rostros de personas como se muestra en la figura 2.19



Figura 2.19 Ejemplo de una base de datos ampliada de rostros de Yale B. (Chan & Tahir, 2013)

2.6.1.3 Base de datos CAS-PEAL

En el año 2004, (Gao, Y., Ma, J., Zhao, M., 2017) fue construída esta base de datos de rostros que contiene 99.594 imágenes de 1040 individuos, de los cuales 595 son de sexo masculino y 445 son de sexo femenino, en donde se cogieron las imágenes con

diversas posturas, expresiones de rostro, iluminación y accesorios. Se instalaron nueve cámaras en semicírculo, con el fin de capturar simultáneamente en diversas posturas a cada individuo. Se tomaron 18 imágenes con el rostro hacia arriba y hacia abajo, también de consideraron 5 diferentes expresiones faciales, 6 accesorios (3 lentes y 3 gorras) y 15 orientaciones de iluminación. En la figura 2.20, se indican parte de la base de datos CAS-PEAL.




Figura 2.20 Ejemplo de imágenes tomadas en la base de datos de rostros CAS-PEAL.(Gao, Y., Ma, J., Zhao, M., 2017)

2.6.1.4 Base de datos FERET

Entre los años 1993 y 1996, (P.J. Phillips, H. Moon, S. Rizvi, 2000), fue cosntruída la base de datos FERET (Face Recognition Technology), la cual radica en 1196 personas y cuatro clases de conjunto de pruebas: fafb (imágenes con diferentes expresiones de rostro), fafc (imágenes con diferentes orientaciones de iluminación), dupI (imágenes tomadas en menos de 18 meses) y dupII (imágenes tomadas en los 18 meses siguientes). El programa (FERET) es dirigido por la Agencia (DARPA) (Defense Advanced Research Projects Agency) y (NIST) (National Institute of Standards and Technology).

En la figura 2.21, se muestran una parte de las imágenes capturadas en la base de datos FERET.




Figura 2.21 Imágenes de ejemplo de la base de datos de caras de FERET(Lu, J., Tan, Y.-P., & Wang, 2013), (Sadhya & Kumar, 2019), (Benini et al., 2019)

2.6.1.5 Base de datos ORL

En 1994, un grupo de trabajo de los laboratorios AT&T, construyeron la base de datos ORL la misma que está constituida por 10 imágenes diferentes de 40 individuos (Xu, Y., Fang, X., Li, X., Yang, J., You, J., Liu, H., & Teng, 2014). Las imágenes se captaron en diversas temporadas, ángulos de iluminación, expresiones de rostro y accesorios. Las dimensiones de las imágenes son 92 x 112 píxeles cada una, en escala de grises. En la figura 2.22 se indica un ejemplo de las imágenes captadas para una persona.




Figura 2.22 Imágenes de muestra de la base de datos facial ORL. (Xu, Y., Fang, X., Li, X., Yang, J., You, J., Liu, H., & Teng, 2014)

2.6.1.6 Base de datos MUCT

Esta base de datos MUCT, consta de 3755 imágenes de rostros humanos con 76 puntos de referencia manuales. Esta base de datos MUCT proporciona más diversidad de iluminación, edad y etnia en relación a otras bases de datos de marcas registradas 2D disponibles al público. A continuación, se ilustra un conjunto de rostros parte de esta base de datos en la siguiente figura 2.23.



Figura 2.23 Bases de datos MUCT
Fuente: (Milborrow, S., Morkel, J., & Nicolls, 2010)

Esta base de datos está disponible gratuitamente para uso académico en la siguiente dirección: <https://github.com/StephenMilborrow/muct>

2.6.2 Bases de datos de caras 3D

En esta subsección se presentan algunas bases de datos conocidas en 3D

2.6.2.1 Base de datos Texas3DFRD

En la actualidad se cuenta con una gran variedad de bases de datos en 2D, siendo una pequeña desventaja la poca presencia de bases de datos en 3D. Sin embargo a través

de algunos laboratorios se va obteniendo algunas bases de datos, tal es el caso de Texas3DFRD (Gupta, Castleman, Markey, & Bovik, 2010a), la misma que contiene 1149 pares de alta resolución, presentan imágenes de color y rango normalizadas, preprocesadas y perfectamente alineadas de 118 sujetos humanos adultos adquiridos usando una cámara estéreo. Las imágenes representan el género, la etnia y la expresión facial de los sujetos, como se ilustra en la figura 2.24




Figura 2. 24 Bases de datos Texas 3DFRD (Gupta et al., 2010a)

2.6.2.2 Base de datos de caras 3D de CASIA

Entre agosto y septiembre de 2004, se realiza la recopilación de la base de datos de caras 3D que consta de 4624 caras de 123 personas que utilizaron una cámara digitalizada 3D sin contacto, tipo Minolta Vivid 910. Durante la creación de la base de datos, se ha considerado no solo las variaciones únicas de poses, expresiones e iluminaciones, sino también las variaciones combinadas de expresiones bajo iluminación y poses bajo expresiones, como se muestra en la figura 2.25 el objetivo de CASIA fue construir una base de datos de caras 3D completa, que se verá impulsada a ser una plataforma pública para probar los algoritmos en reconocimiento de caras 3D u otros.




Figura 2.25 Bases de datos de caras de CASIA 3D (Casia, 2011)

2.6.2.3 Base de datos de rostros FRGC 3D

La base de datos de rostros FRGCv2 3D (Passalis, Kakadiaris, Theoharis, Toderici, & Murtuza, 2014) es un conjunto de datos de caras 3D, utilizado para promover el desarrollo y la evaluación de una variedad de algoritmos de reconocimiento facial, esta base de datos consiste en imágenes en 3D de alta resolución. Esta base de datos contiene un conjunto de datos v2 de FRGC, un total de 4007 imágenes 3D, adquiridas entre 2003 y 2004. El hardware utilizado para adquirir estos datos de rango fue un escáner de rango Minolta Vivid 900, con una resolución de 640x480. Estos datos provienen de 466 sujetos y contienen diversas expresiones faciales como, por ejemplo, felicidad, sorpresa. Los sujetos son 57% varones y 43% femenino, mientras que la distribución por edades es del 65% 18-22 años, 18% 23-27 y 17% 28 o más. En la figura 2.26, se muestra un ejemplo de esta base de datos.



Figura 2.26 Ejemplo de imágenes clasificadas como neutrales en la base de datos de FRGC v2 (Passalis et al., 2014)

2.6.2.4 Base de datos de rostros BU-3DFE

Esta base de datos BU-3DFE (L. Yin, X. Wei, Y. Sun, J. Wang, 2006), (Yin, et al, 2010), (Rosato, 2016), (Dou & Kakadiaris, 2017) contiene rostros de personas con diferentes expresiones (neutral, tristeza, alegría, enojo, sorpresa), ver figura 2.27. Esta base de datos corresponde al Dr. Lijun Yin del Department of Computer Science de State University of New York at Binghamton. La base de datos BU-3DFE se encuentra disponible para áreas de interés como la computación afectiva, visión por computadora, interacción con la computadora humana, seguridad, biomedicina, aplicación de la ley y la psicología. Esta base de datos actualmente contiene 100 sujetos, de los cuales el 56% corresponde a mujeres y 44% hombres, con edades entre 18 y 70 años, con una variedad de ancestros étnicos raciales, incluidos los blancos, negros, asiáticos del Medio Oriente, indios, e hispano latino. Sin lugar a duda esta base de datos constituye uno de los componentes más importantes en el campo del reconocimiento facial. En el presente trabajo, se optó por trabajar con esta data.




Figura 2.27 Base de datos BU-3DFE (Dou & Kakadiaris, 2017)

2.7 Análisis de las técnicas y bases de datos revisados

A partir de los trabajos revisados, muchas técnicas son las que permiten cumplir con el objetivo del reconocimiento de rostros, según lo revisado entre los que figuran son: Máquinas de vectores soporte, Análisis de principales componentes, K-nn vecinos,

Análisis de componentes independientes, Eigenface, también muchos han optado por trabajar con combinaciones como: PCA-SVM, DCV-NN, KDCV-NN, DCV-RBF, KDCV-RBF, IDCV-SVM, ICA-FLS_SVM, RKDA-SVM, GABOR-SVM.

La eficiencia de un clasificador de patrones SVM trabaja con funciones kernels como lineal, gaussiano, polynomial, entre otros. El kernel Gaussiano y Polynomial son los que mejores resultados han tenido, un elemento muy importante en este proceso son las bases de datos utilizados en efecto del reconocimiento que dependen de varios elementos como la eficiencia de entrenamiento, el modelo obtenido, el número de pruebas efectuadas, el tamaño de la base de datos. Cabe insistir que estos resultados alcanzados resultan muy buenos por las bases de datos utilizados, a diferencia con otras bases como FERET, MUCT según la literatura sus resultados son un tanto menor.

En lo que respecta a los trabajos de reconocimiento facial en 3D, es importante destacar el nivel de eficiencia es mucho mejor que en el 2D, esto se debe a que una imagen en 3D antes de ser reconocido, pasa por ciertos pre-procesamientos tales como, eliminación de ruidos, llenado de agujeros y normalizaciones. De allí que los resultados que se obtienen en los procesos de reconocimiento son bastante buenos, pero no todo es bueno, al momento existen ciertas desventajas en cuanto a sus bases de datos en 3D, al menos, su presencia en forma libre y gratuita para investigaciones es muy baja en relación a las bases de datos de rostros en 2D. Una de las pocas bases de datos de rostros en 3D que se ha encontrado para investigaciones es CASIA (Academia China de Ciencias, Instituto of Automation) (Casia, 2011), GAVAB (Group of Artificial Vision, Biometría Artificial) y TEXAS3DFRD (Gupta, Castleman, Markey, & Bovik, 2010b) y BU-3DFE (L. Yin, X. Wei, Y. Sun, J. Wang, 2006), (Yin, et al, 2010), (Rosato, 2016), (Dou & Kakadiaris, 2017)]. Por último es necesario indicar en base a trabajos anteriores los sistemas 3D-2D son los más indicados, por cuanto alcanzan un mejor porcentaje de aciertos, alcanzando un acierto del 90,8% como lo establece kakadiaris en su trabajo de investigación, (Kakadiaris et al., 2017).

2.8 Filtrado de Imágenes

El método del filtrado de imágenes consiste en una técnica aplicada en un preprocesamiento de imágenes, cuyo objetivo fundamental es obtener a partir de una imagen origen un resultado más adecuado para una aplicación específica, mejorando ciertas características de la misma que posibilite efectuar operaciones del procesado sobre ella.

El método trata de resaltar o suprimir, de forma selectiva, información argumentada en una imagen a diferentes escalas espaciales, para destacar algunos elementos de la imagen, igualmente para ocultar valores anómalos. El proceso de filtrado se fundamenta en la aplicación a cada uno de los pixels de la imagen de una matriz de filtrado de tamaño $N \times N$ (generalmente de 3×3 aunque puede ser mayor) compuesta por números enteros y que genera un nuevo valor mediante una función del valor primario y de los pixels circundantes, la representación de algoritmos se filtra de segmentación que permite mejorar la calidad (Piña & Silva, 2016) (Pérez Flores, 2015), la transformada de Fourier, etc. En la actualidad se cuenta con varios tipos de filtrados que la numeramos a continuación:

- Filtros de paso bajo
- Filtros de paso alto
- Filtros direccionales
- Filtros para la detección de bordes

De lo descrito anteriormente, es claro concluir que una de sus importantes aplicaciones sería ser parte de un proceso de reconocimiento facial de imágenes.

La figura 2.28 se indica un ejemplo de imagen filtrada, donde la primera corresponde a su versión original, mientras que la segunda a una imagen filtrada (suavisada).




Figura 2.28 Imagen original (izquierda) que ha sido filtrada (derecha)

2.8.1 Filtro de Gabor

Dentro de los filtros muy importantes empleados para procesar una imagen de entrada están los filtros de Gabor, los mismos que son victoriosamente utilizados en varias aplicaciones de imágenes como el estudio de textura, verificación facial, reconocimiento de caracteres y restablecimiento de imágenes por contenido, estos filtros funcionan como un detector de bordes en una base no ortogonal, por lo tanto cada característica extraída por un filtro se correlaciona con otra particularidad generada por otro, (Alejandra, 2016) (Belén et al., 2004) (Garrido & Alcaide, 2018).

La expresión matemática en la que se basa el filtro de Gabor (Alejandra, 2016), es el siguiente:

$$\psi(x, y, x_0, y_0, f_0, \sigma_x, \sigma_y, \theta, \phi) = \frac{f_0^2}{\pi\sigma_x\sigma_y} \exp\left[-f_0^2\left(\frac{x_2^2}{\sigma_x^2} + \frac{y_2^2}{\sigma_y^2}\right)\right] \cdot \exp(2\pi i \cdot f_0 x_r + i\phi) \quad (18)$$

Donde:

$$x_r = (x - x_0) \cos \theta + (y - y_0) \sin \theta$$

$$y_r = (x - x_0) \sin \theta + (y - y_0) \cos \theta$$

x_0 y y_0 indican la posición en el espacio de la wavelet

f_0 = frecuencia central de la onda plana

σ_x = det er min a el ancho del eje mayor de la envolvente Gaussiana

σ_y = det er min a el ancho del eje menor de la envolvente Gaussiana

θ = ángulo (contrario de las manecillas del reloj)

entre la dirección de propagación de la onda y el eje x

ϕ = desplazamiento de la fase de la onda

He aquí una representación de una imagen filtrada utilizando el filtro de Gabor, Figura 2.29




Figura 2.29 Dos filtros de Gabor, cada uno de ellos con distinta frecuencia central, escalado y orientación (García, Escaramilla, & Nariko, 2015).

En tal sentido el filtro de Gabor es un filtro lineal cuya replica de impulso esta en función sinusoidal multiplicada por una función gaussiana. Si le asignamos una específica frecuencia y direcciónamiento, se obtiene una rebaja del ruido a la vez de proteger una dirección de la imagen original.

Los filtros de Gabor pueden ajustar para operar a diferentes escalas y orientaciones, de modo que se pueda analizar la imagen en diferentes profundidades y ángulos. Este actúa como un filtro de paso de banda sintonizable. Gracias a la implementación de banco de filtros multicanal y sintonización a diferentes escalas y orientaciones, imita la respuesta del sistema visual humano (Karthika & Parameswaran, 2016).

Por último los filtros de Gabor están directamente en conexión con los wavelets de Gabor, dado que tienen funcionalidad en aproximación pasabanda y que pueden delinearse como un banco de filtros con diferentes dilataciones y rotaciones, al trabajar con filtros ortogonales (requisito de los wavelets) puede dar complicaciones, en este caso se requiere el uso de wavelets biortogonales.

2.9 Extracción de Características

La extracción de características de rostros radica en separar información asociada con la activación de los diversos músculos de la cara, esta acción puede realizarse en forma global u holística, también se analiza el rostro como un solo conjunto o localmente, en donde se eligen regiones de utilidad del rostro como ojos cejas y boca. Se tienen varias técnicas para este proceso de extracción de características, como PCA, ICA, GABOR, etc. (Castrillon, Alvarez, & López, 2008) (Belén et al., 2004) (Garrido & Alcaide, 2018). Los algoritmos de extracción de características se centran, entre otras cosas, en las imágenes analizadas para extraer atributos y regiones de interés, la división de objetos del fondo, la detección de bordes o formas. La extracción de características transforma las características originales para generar otras características que son más significativas (Khalil, 2014).

Según Aguirre (Aguirre Dobernack Nicolás, 2013) un proceso de extracción de características debe cumplir, entre otras, las siguientes condiciones:

- La extracción de información útil a partir de la imagen no debe suponer un coste excesivo al sistema en el cual está integrado, y el tiempo total dedicado a esta tarea debe ser lo menos posible.
- La localización de las características de la imagen debe ser muy precisa. Así mismo, el error cometido en la estimación de las mismas debe ser lo más pequeño posible.
- El método utilizado para la extracción de características debe ser robusto y estable, los datos extraídos deben contener la máxima información posible de la imagen.

Extraer características, dentro de el estudio de componentes principales PCA, es un modelo empleado para minimizar dimensiones de problemas del reconocimiento de

patrones, permitiendo imágenes significativas bajo un análisis, en forma minuciosa y compacta. Para conocer las ecuaciones fundamentales del PCA se ha de llevar las características de imágenes de caras, se considera el grupo de M imágenes en los niveles de grises, cada una $L = N_1 \times N_2$ en píxeles, las que se ordenan en una matriz de dimensión $L \times M$. Por consiguiente, con el objetivo de descubrir aquellos vectores que den mejor significado de la disposición de imágenes de caras bajo un análisis, cada figura de entrenamiento T_i , $i=1, 2, \dots, M$ se reduce la imagen, obteniendo un promedio de las M imágenes de entrenamiento, obteniendo de esta forma un conjunto de imágenes.

En otro campo de estudio, la extracción de características sirve para transformar señales cerebrales originales en una representación que facilita la clasificación. En otras palabras, el objetivo de la extracción de características es eliminar el ruido y otra información innecesaria de las señales de entrada, al mismo tiempo que retener información que es importante para discriminar diferentes clases de señales. (Vinicio & César, 2017). Finalmente la extracción de características se aplica en el campo del estudio de imágenes que se constituye en la primera etapa en la inteligencia de un circuito de visión artificial.

2.9.1 Extracción de características por wavelets de Gabor

En la actualidad la forma más común de estudiar las propiedades periódicas de las texturas la llevamos a cabo en procesos por un banco de filtros particulares denominados filtros de Gabor. Los descritos están a grandes rasgos filtros paso banda, que dan información de las frecuencias espaciales que contienen las figuras, así como de su patrón. Cada uno de los espectros del filtro de Gabor de acuerdo a lo mencionado referido en la extracción de características faciales como lo menciona García (García, Escaramilla, & Nariko, 2015)

Igualmente, (Sujitha, Venkatramaphanikumar, & V, 2019) considera que para la extracción de características, wavelets de Gabor es muy importante, considerando las propiedades de discriminación como la escala y la orientación. Este proceso consiste en que las características de Gabor se recopilan de las caras de entrada de escala de grises. El dominio espacial del filtro Gabor 2-D es una función de núcleo gaussiano

que fue modulada por una onda sinusoidal. Los filtros wavelet de Gabor se pueden practicar en numerosos problemas de detección para la extracción de características debido a sus propiedades de localización impecables en pares de dominio espacial y de frecuencia.

Las wavelets de Gabor son inventadas por Dennis Gabor, la propiedad importante de la wavelet es que minimiza el producto de sus desviaciones estándar en el dominio del tiempo y la frecuencia. Hay que tener en cuenta que los errores en la información transportada por esta wavelet se minimizan, pero tiene el inconveniente de no ser ortogonales, por lo que es difícil una descomposición eficiente en la base de datos. Se encuentran en distintas aplicaciones desde el procesamiento de imágenes hasta el análisis de neuronas en el sistema visual humano.

Los wavelets de Gabor se usan para detectar bordes, esquinas y manchas, la función regular de una wavelet de Gabor bidimensional descrita en el dominio de la frecuencia espacial (Sujitha et al., 2019) se da en base a la siguiente ecuación:

$$g(x, y) = \exp\left[-\frac{x^2 + y^2}{2\sigma_{xy}^2}\right] \cos(u_0x + v_0y) \quad (19)$$

Donde, σ_{xy} es la desviación estándar de la cobertura gaussiana que representa la extensión del dominio espacial y la capacidad de transmisión del filtro gaussiano. Los parámetros (u_0, v_0) caracterizan la frecuencia espacial de la curva sinusoidal, que se representa en coordenadas bidimensionales como frecuencia radial r_0 y orientación θ :

$$r_0^2 = u_0^2 + v_0^2 \quad (20)$$

$$\tan \theta = \frac{v_0}{u_0} \quad (21)$$

La densidad y las características discriminatorias angulares de las wavelets de Gabor son más precisas en su representación de rango de densidad que muestra la cantidad por la cual el filtro gaussiano cambia cada componente la densidad de imagen de entrada.

En la mayoría de las aplicaciones de reconocimiento facial, se utilizan wavelets Gabor con cinco escalas que son; $U = 5$ y ocho orientaciones: $V = 8$. La siguiente figura 2.30 muestra la magnitud a cinco escalas, y las partes reales con cinco escalas y ocho orientaciones.




Figura 2. 30 El conjunto de 40 wavelets Gabor. a) La magnitud a cinco escalas. b) Las partes reales a cinco escalas y ocho orientaciones (Shen & Bai, 2006)

Los wavelets de Gabor son elementos de una familia de funciones de Gabor mutuamente similares, se crean por dilatación y se desplazan desde una función de Gabor elemental (wavelet madre), que se halla representado por la siguiente ecuación

$$g_{\alpha,\xi,a,b}(x) = |a|^{-\frac{1}{2}} g_{\alpha,\xi}\left(\frac{x-b}{a}\right) \quad (22)$$

Para $a \in \mathbb{R}^+$ (escala) y $b \in \mathbb{R}$ (desplazamiento). Por convención, la wavelet madre tiene la energía localizada alrededor de $x = 0$ y todas las wavelets están normalizadas $\|g\| = 1$. Aunque las wavelets de Gabor no forman bases ortonormales, el conjunto discreto de ellas forma un marco. σ , representa la varianza y ξ es la frecuencia. (Barina, 2016)

Para un caso de una dimensión, se tiene que la función g está representado por:

$$g_{\alpha, \xi}(x) = \sqrt{\frac{\alpha}{\pi}} e^{-\alpha x^2} e^{-i\xi x} \quad (23)$$

Siendo $\alpha \in R^+$ y $\xi, x \in R$ donde $\alpha = (2\sigma^2)^{-1}$, σ^2 es una varianza y ξ es una frecuencia, i es la parte imaginaria.

Mientras que para un caso de dos dimensiones tendremos que:

$$g_{\alpha, \xi}(x) = g_{\alpha, \xi_0}(x_0) g_{\alpha, \xi_1}(x_1) \quad (24)$$

Siendo $\xi = (\xi_0, \xi_1)$ y $x = (x_0, x_1)$, con ello $\xi = (\xi_0^2 + \xi_1^2)^{\frac{1}{2}}$

Por convención, la wavelet madre tiene la energía localizada alrededor de $x = 0$ y todas las wavelets están normalizadas $\|g\| = 1$.

El reconocimiento facial es una de las aplicaciones más importantes de las ondas de Gabor. La imagen de la cara se convoluciona con un conjunto de ondas de Gabor y las imágenes resultantes se procesan adicionalmente con fines de reconocimiento. Las wavelets de Gabor generalmente se denominan filtros de Gabor en el ámbito de las aplicaciones de reconocimiento de imágenes. Recientemente ha habido una gran cantidad de investigaciones sobre el reconocimiento facial, y varios enfoques propuestos que podrían clasificarse aproximadamente en enfoques analíticos (local) y holísticos (global). (Chao, 2017)

Enfoques analíticos se refiere cuando se detectan algunos puntos característicos del rostro, especialmente los puntos de referencia faciales importantes como ojos, narices y bocas. Estos puntos detectados se denominan puntos fiduciales, y las características locales extraídas en estos puntos, la distancia y el ángulo entre estos puntos y algunas medidas cuantitativas del rostro se utilizan para el reconocimiento facial. La principal ventaja de los enfoques analíticos es que permiten una deformación flexible en los puntos de características clave para que la pose cambie y se puedan compensar diferentes ángulos de visión. (Chao, 2017)

Los enfoques holísticos en cambio extraen características de toda la imagen del rostro. La normalización del tamaño de la cara y la rotación es un preprocesamiento realmente importante para que el reconocimiento sea robusto. La cara propia basada en el análisis de componentes principales (PCA) y la cara del pescador basada en el análisis discriminante lineal (LDA) son dos de los enfoques holísticos más conocidos. (Chao, 2017)

Cuando se extraen características para el reconocimiento de patrones, la recuperación o la visión por computadora, los coeficientes transformados se utilizan para medida de distancia o representación comprimida pero no para reconstrucción, por lo que la restricción ortogonal podría omitirse.

2.10 Resumen de la revisión de literatura

2.10.1 Descripción de la metodología de la revisión de la literatura

Dentro de la metodología, es necesario anotar que la revisión de la literatura para el Estado del Arte, se revisaron varios artículos relacionados con el tema, dando prioridad a los últimos 5 años, excepto algunos trabajos de años inferiores que son necesarios en cuanto a las conceptualizaciones, así como en algunos casos su tecnología está vigente. De igual manera también se revisaron artículos de autores de tecnologías originales como el caso del SVM (Vapnik, 1998), (Cabello Pardos, 2003).

Se realizó la revisión literaria de varios artículos de bases de datos tanto Scopus, Web Of Science, etc., los cuales 45 corresponden a los 5 últimos años, y el resto a años menores a 2015, además se investigaron tesis doctorales relacionados con el tema de nuestro trabajo, para esta revisión se valió de algunas bases de datos indexadas muy importantes como: Scopus, Science Direct, Elsevier, IEEE, etc.

Esta revisión además se enfocó a las bases de datos de rostros, tales como: FERET, ORL, MUCT, CMU, YALE, TEXAS3DFRD, BU-3DFE, etc. La revisión estuvo enfocada en el siguiente término: “Reconocimiento de rostros”, ó “Face recognition”.

A continuación, se muestra un resumen de trabajos revisados, respecto a sus publicaciones en diferentes bases de datos, figura 2.31, y su año de publicación figura 2.32

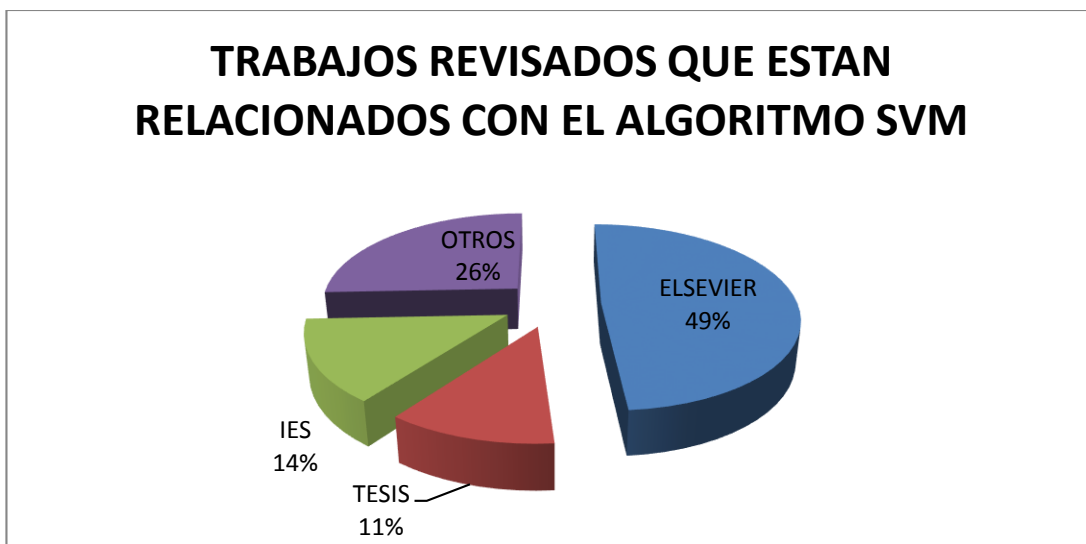


Figura 2. 31 Resumen de trabajos que involucran al algoritmo SVM según la base de datos registrada

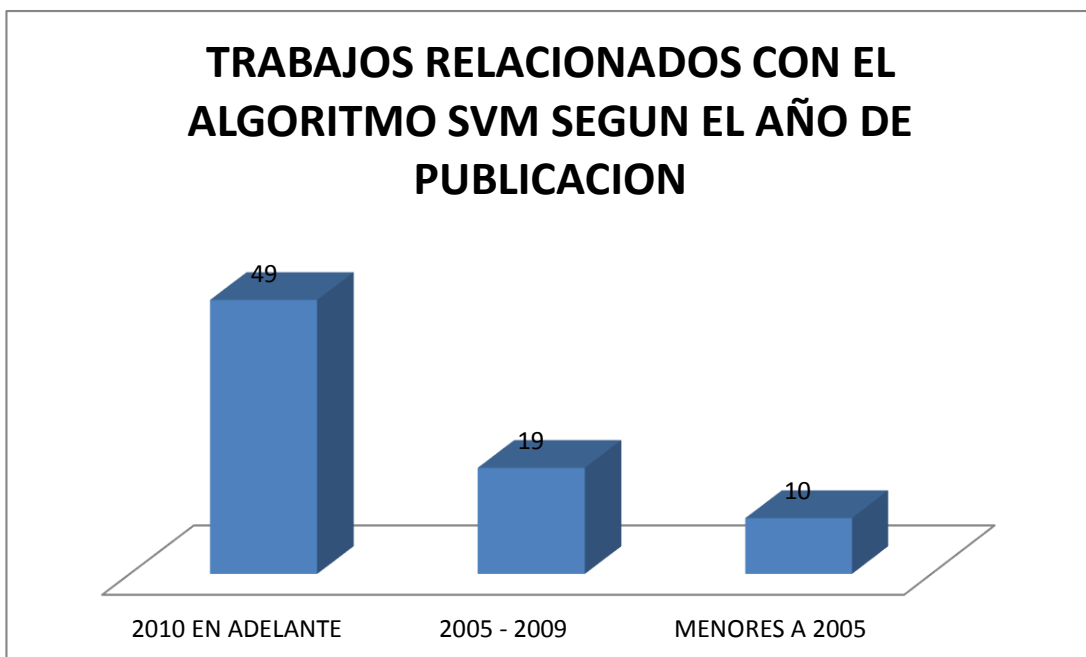


Figura 2. 32 Resumen de trabajos revisados que involucran al algoritmo SVM según el año de publicación.

2.10.2 Tipos de Investigación

Esta investigación se fundamenta en dos partes muy bien definidas, la primera es la investigación bibliográfica, mediante la cual se obtuvo una teoría sólida al realizar una revisión sistemática de varias fuentes tanto en revistas con factor de impacto indexadas en bases de datos Scopus, Web of Science, Scielo, etc., empresa editora de libros y artículos Elsevier, así como tesis doctorales que han sido de gran ayuda dentro del estado del arte.

De acuerdo al tema planteado y en base de las teorías de investigación se estima realizar un trabajo experimental, por cuanto esta permite manipular variables muy controladas, estudiando los efectos que se producen en casos concretos, a partir de este sistema nacen hipótesis que se pueden contrastar a través del método científico.

2.10.3 Comparación de técnicas de Reconocimiento Facial

En la tabla 2.6 se observa la composición de la obtención de resultados en los diferentes trabajos realizados, cabe destacar que el algoritmo SVM muestra un mayor porcentaje de reconocimiento de caras. A la vez se indica las bases de datos y el número de imágenes utilizados por cada base de datos.

Tabla 2. 6 Comparación de técnicas de Reconocimiento Facial

AUTORES	Técnicas Utilizadas	% acierto reconocimiento	Bases de datos	Número de imágenes	Tamaño (pixels)
Moreno et al., (2005)	PCA	77,9%	Gavab	420	---
	SVM	76,2%			
Guo et al, 2001	SVM	3,0% (el más mínimo error)	ORL	400	---
	CNN	3,83% (de error)			
	NFL	3,125% (de error)			
	SVM	8,79% (de error)	BDD COMPUESTA	1079	---
	CNN	9,72% (de error)			
	NFL	15,14% (de error)			
Wen (2012)	EIGENFACE	93,87%	ORL	400	112 x 96
	LDA	93,80%			
	PCA_SVM	95,56%			
	DCV_NN	96,67%			
	KDCV_NN	97,75%			
	DCV_RBF	97,77%			

	KDCV_RBF	97,65%			
	IDCV_SVM	98,92%			
Kong y Zhang (2011)	FLS_SVM (ICA)	97,50%	ORL	400	28 x 28
Devi et al., (2015)	R-KDA - SVM	30%	UMIST	564	220 x 220
Olivares et al., (2016)	LFDE - SVM	97,92%	AR	9360	---
Luo et al., (2013)	PCA+LBP+SVM	96,25%	PERSONAL	50	24 x 24
Lin et al., (2016)	SVM	97%	ORL	509	---
Kim et al., (2010)	SVM-DA	8,5% (error mínimo)	FERET	1702	56 x 46
		8,6% (error mínimo)	AR	1680	56 x 46
		9,5% (error mínimo)	CMU-PIE	1840	56 x 46
Gumus et al., (2010)	Wavelet-SVM	89,38%	ORL	400	---
Li et al., (2011)	MOUD-SVM	96,67%	YALE	165	---
			CAS-PEAL-RI	100	
Zhou et al., (2010)	KSCH	100%	MIT-CBCL	180	---
			UMIST		
Khan et al., (2012)	SVM-NDA	>98%	ORL	400	---
			YALE	165	
			ESSEX	153	
			JAFFE	213	
Kasar et al., (2016)	BNP + RBF	98,88%	-----	-----	-----

2.11 Validación cruzada

La validación cruzada es una técnica que se usa para evaluar los resultados de un análisis realizado. Esta técnica radica en dividir el conglomerado de datos de entrenamiento en k subconjuntos, y entrenar $k-1$ de esos subconjuntos de comprobación luego con el último subconjunto que no se ha entrenado (Ruiz, 2018), obteniendo un error de validación por cada proceso, el resultado final será el promedio de todos los errores, que representa el error promedio de validación. Finalmente este promedio se resta de la unidad y se multiplicaría por 100, obteniendo el porcentaje de eficiencia del modelo. Este proceso se indica en la tabla 2.7

Tabla 2. 7 Proceso de Validación Cruzada

CONJUNTO DE DATOS ENTRENADOS							
PROCESO_1	PROCESO_2	PROCESO_3	PROCESO_4	PROCESO_5	PROCESO_...	PROCESO_...	PROCESO_N
PRUEBA_1	DATOS	DATOS	DATOS	DATOS	DATOS	DATOS	DATOS
DATOS	PRUEBA_2	DATOS	DATOS	DATOS	DATOS	DATOS	DATOS
DATOS	DATOS	PRUEBA_3	DATOS	DATOS	DATOS	DATOS	DATOS
DATOS	DATOS	DATOS	PRUEBA_4	DATOS	DATOS	DATOS	DATOS
DATOS	DATOS	DATOS	DATOS	PRUEBA_5	DATOS	DATOS	DATOS
DATOS	DATOS	DATOS	DATOS	DATOS	DATOS	DATOS
DATOS	DATOS	DATOS	DATOS	DATOS	DATOS	DATOS
DATOS	DATOS	DATOS	DATOS	DATOS	DATOS	DATOS	PRUEBA_N

El tema de validación cruzada según (Kerbaa, Mezache, & Oudira, 2019), es un método estadístico para evaluar la capacidad de un modelo para aprender en modo automático. Esta técnica es usada generalmente en el aprendizaje aplicado automáticamente para hacer comparativas y elegir un modelo. Esta validación cruzada divide los datos de entrenamiento en varias partes no contiguas del mismo tamaño.

De acuerdo a (Curso & Lorena, 2009), la validación cruzada consiste en: dado un número n se divide los datos en n partes y, por cada parte, se construye el clasificador con las $n-1$ partes restantes y se prueba con esa. Este proceso se lo realiza para cada una de las “ n ” particiones.

La validación cruzada tiene muchas aplicaciones, como validación de métodos en laboratorios (Mano, 2018), en modelos de mediciones de velocidad (J. Li, Perrine, Wu, & Walton, 2019), en validar modelos de estrategias de control (Yang et al., 2019), etc.

CAPITULO III: METODOLOGIA DE LA INVESTIGACION

3.1 Tipo y diseño de la investigación

Para el presente trabajo se realizó una investigación cuantitativa y experimental. De acuerdo a Hernández (Hernández, 2010), la investigación cuantitativa consiste en la recolección de datos para probar hipótesis, con base en la medición numérica y el análisis estadístico, para establecer patrones de comportamiento y probar teorías.

De acuerdo a esta definición, esta investigación nos permite trabajar con los resultados obtenidos para posteriormente, en base a la estadística, poder validar la eficiencia del entrenamiento como de la prueba del proceso de reconocimiento facial. La investigación experimental es la alteración de una variable experimental o varias al mismo tiempo, en un ambiente estrictamente vigilado por la persona que realiza el experimento.

Finalmente, de acuerdo a Palella, (Palella, 2012) en cuanto al diseño experimental, considera que es el momento en el cual el investigador manipula una variable experimental no comprobada, bajo condiciones estrictamente controladas. Su objetivo es describir de qué modo y por qué causa se produce o puede producirse un fenómeno. Por medio de este diseño experimental se plantea desarrollar un software adecuado que apruebe realizar reconocimiento de rostros, comprendiendo todas las fases de entrenamiento y prueba respectivamente. Esto se logrará por medio de la manipulación de bases de datos, el uso del algoritmo de extracción de características, clasificación de patrones, etc.

Ya dentro de la solución general se plantea un esquema, en el que se incluye las fases de entrenamiento y pruebas de las bases de datos en las cuales se trabajaron con reconocimiento facial, cabe mencionar que a partir de las bases de datos de rostros se obtienen los vectores característicos, para luego ser utilizados por la técnica de clasificación como es el SVM, que es nuestra técnica de estudio para el reconocimiento de rostros. En el aporte de esta investigación se priorizan experimentos para

reconocimiento facial en 2D y 3D, mismos que serán explicados en los capítulos IV y V.

3.2 Unidad de análisis

Esta investigación va a manejar imágenes faciales en 2D y en 3D. Las imágenes faciales poseen características únicas que las diferencian la una de la otra. Una imagen de un rostro humano, en la actualidad, se establece en dos dimensiones (plano x-y), es así que podemos tener imágenes de caras con características como: gestos (alegre, triste, enojado, etc.), pose, género, edad, etnia, etc. Sin embargo, en la actualidad ya se habla de imágenes en tres dimensiones (plano x-y-z).

3.3 Población de estudio

Corresponden las bases de datos de figuras de rostros en 2D y 3D encontrados en la literatura. Es así que para la primera parte se trabaja con la siguiente data: La primera es la dataset FERET y la segunda la dataset MUCT. Para la segunda parte de la investigación se trabaja igual con dos datasets en 3D siendo TEXAS3DFRD (Gupta et al., 2010b) y la dataset BU-3DFE (X. Li, Ruan, Jin, An, & Zhao, 2015).

Cabe notar la selección de estas bases de datos por la calidad de imágenes, han sido utilizadas por investigaciones de alta calidad, son de libre acceso, no tienen costo si son utilizadas para temas de investigación, a diferencia de otras que requieren un pago.

Las bases de datos en 3D son muy pocas, y complicados de adquirir libremente, la mayoría es pagada. Sin embargo las seleccionadas son de muy alta calidad y se me fue entregado sin ningún costo, siempre y cuando sea con fines de investigación.

3.4 Tamaño de la muestra

De acuerdo a la literatura, según (Hernández, 2010) considerando que se trata de una investigación experimental, el tamaño de la muestra sería la misma que el de la población. Esto debido a que la mayor parte de las veces, las investigaciones experimentales utilizan muestras dirigidas para la validación de su hipótesis (p. 190,

191). Para la presente investigación se propone dos aportes importantes, la primera: un sistema de reconocimiento facial en 2D y la segunda en 3D.

Es así que para la primera parte de la investigación como se mencionó anteriormente, se trabaja con dos datos: La primera es la base de datos FERET y la segunda base de datos MUCT (Sadhya & Kumar, 2019), como se indican una parte de la misma en las figuras 3.1 y 3.2 respectivamente.

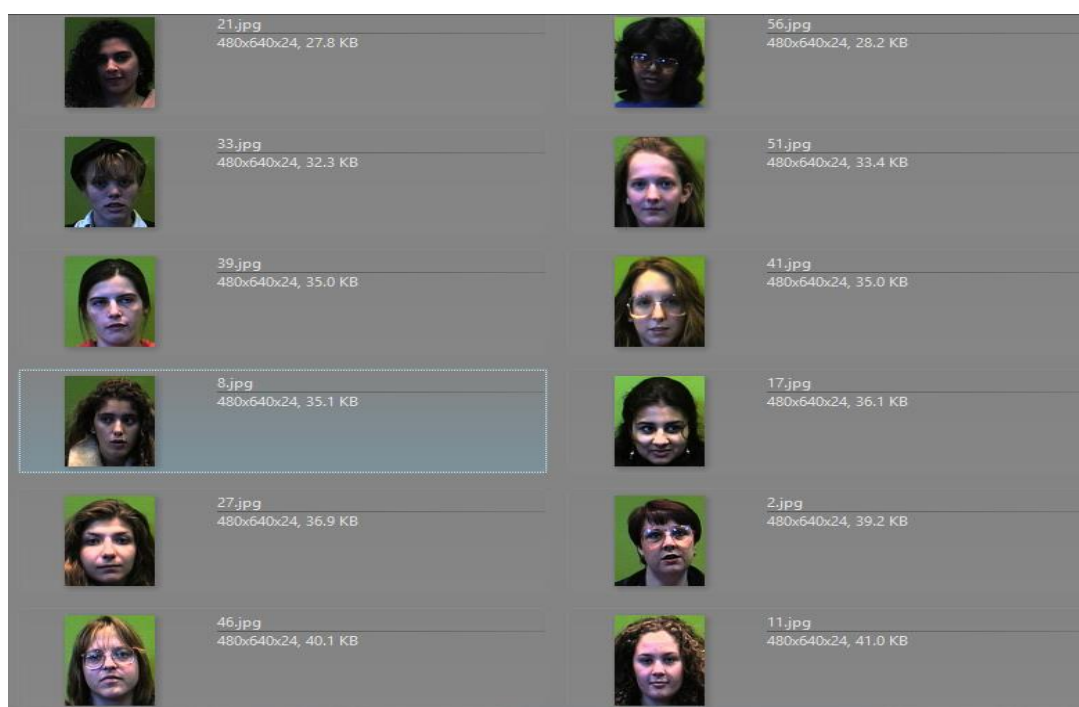


Figura 3. 1 Bdd FERET

Fuente: Extraído de (Sadhya & Kumar, 2019), (Benini et al., 2019)



Figura 3. 2 Bdd MUCT

Fuente: Extraído de (Sadhya & Kumar, 2019), (Milborrow, S., Morkel, J., & Nicolls, 2010)

Para la segunda parte de la investigación se trabaja igual con dos datasets en 3D siendo TEXAS3DFRD (Gupta et al., 2010b) con 183 rostros reprocesados en 3D correspondientes a 50 personas, y la base de datos BU-3DFE (X. Li, Ruan, Jin, et al., 2015), quien cuenta con 500 modelos de imágenes, que corresponden a 50 personas, las cuales se muestran en las figuras 3.3 y 3.4 respectivamente.




Figura 3. 3 Base de dattos TEXAS3DFRD

Fuente: Extraído de (Gupta et al., 2010b)



Figura 3. 4 Base de datos BU-3DFE

Fuente: Extraído de (X. Li, Ruan, Jin, et al., 2015)

3.5 Técnicas de recolección de datos

La data de figuras de rostros 2D y 3D se obtienen por los centros de investigación de las universidades e instituciones de investigación privadas a través de proyectos. Estas instituciones capturan imágenes de rostros, que posteriormente serán usados para sus investigaciones.

Sin embargo, es importante mencionar que no es fácil construir una de estas bases de datos, esto debido a que se debe tener en cuenta las herramientas e infraestructura, las personas y el pre procesamiento de las imágenes, lo que implica gasto de tiempo y recursos económicos.

Como se indicó en la Sección 2.6, existen una gran cantidad de estas bases de datos, lo que facilita este tipo de investigaciones.

Para la investigación se propone dos aportes importantes, la primera: un sistema de reconocimiento facial en 2D y la segunda en 3D. La data FERET se fundamenta en imágenes de rostros recolectados entre diciembre de 1993 y agosto de 1996. En 2003 se realizó una publicación en versión de muy alta resolución, 24 bits de color, de estas figuras, que incluimos 2413 figuras de rostros, enfocando a 856 personas. Las figuras

a color estan realizadas en formato ppm, con una resolución de 256×384 pixeles. Esta base de datos es de libre acceso.

3.6 Técnicas de análisis de datos

Como parte de la investigación experimental que se utiliza en este trabajo de investigación, para el análisis y proceso de datos obtenidos se utilizan algoritmos para extracción de características de imágenes y algoritmos para el reconocimiento de las mismas dentro de los procesos de reconocimiento en 2D y 3D que se detallada en el capítulo IV, dentro de las técnicas seleccionadas para el mismo.

En forma generalizada se destaca dentro del proceso de la primera parte del reconocimiento en 2D, la utilización de algoritmos de vital importancia, tales como el filtrado y extracción de características de Wavelets de Gabor y un clasificador de patrones SVM a través de sus kernels: Lineal, Cúbico y Gaussiano para el reconocimiento con data de caras humanas FERET y MUCT.

Para la segunda parte de la investigación sobre reconocimiento facial en 3D se cuenta con las bases de datos mencionadas anteriormente, como TEXAS3DFRD (Gupta et al., 2010b) y BU-3DFE (X. Li, Ruan, Jin, et al., 2015). Los algoritmos utilizados como el filtro de Gabor y el SVM son los mismos. La única diferencia es que, previamente, se realiza un proceso sobre la base de datos BU-3DFE, como es la proyección de los modelos de caras sobre los planos establecidos: (x vs z), (y vs z), y (z vs y), como se ilustra en la figura 3.5.




Figura 3. 5 Proyección de un modelo sobre los planos respectivos

3.7 Validación del modelo para reconocimiento facial en 2D y 3D

La validación del modelo obtenido sea para 2D y 3D, se realiza aplicando la técnica de la validación cruzada, su definición y proceso fue explicado en el capítulo II de la investigación, el comando CROSSVAL corresponde a la validación cruzada en Matlab, se trabajó con una partición del conjunto de datos de entrenamiento por defecto en 10 subconjuntos. Cada subconjunto se va probando con cada uno de los subconjuntos restantes (en este caso nueve subconjuntos), este proceso se repite por 10 veces en este caso. Cada subconjunto representa imágenes seleccionadas para el entrenamiento. Parte de este proceso se indica en la figura 3.6

		Subconjunto_1	PARTICION CONJUNTO DE DATOS DE ENTRENAMIENTO EN 10 SUBCONJUNTOS	
		Subconjunto_2		
		Subconjunto_3		
		Subconjunto_4		
		Subconjunto_5		
		Subconjunto_6		
		Subconjunto_7		
		Subconjunto_8		
		Subconjunto_9		
		Subconjunto_10		
	VALIDACION_2_1	VALIDACION_3_1	VALIDACION_4_1	VALIDACION_5_1
VALIDACION_1_2		VALIDACION_3_2	VALIDACION_4_2	VALIDACION_5_2
VALIDACION_1_3	VALIDACION_2_3		VALIDACION_4_3	VALIDACION_5_3
VALIDACION_1_4	VALIDACION_2_4	VALIDACION_3_4		VALIDACION_5_4
VALIDACION_1_5	VALIDACION_2_5	VALIDACION_3_5	VALIDACION_4_5	
VALIDACION_1_6	VALIDACION_2_6	VALIDACION_3_6	VALIDACION_4_6	VALIDACION_5_6
VALIDACION_1_7	VALIDACION_2_7	VALIDACION_3_7	VALIDACION_4_7	VALIDACION_5_7
VALIDACION_1_8	VALIDACION_2_8	VALIDACION_3_8	VALIDACION_4_8	VALIDACION_5_8
VALIDACION_1_9	VALIDACION_2_9	VALIDACION_3_9	VALIDACION_4_9	VALIDACION_5_9
VALIDACION_1_10	VALIDACION_2_10	VALIDACION_3_10	VALIDACION_4_10	VALIDACION_5_10
VALIDACION_6_1	VALIDACION_7_1	VALIDACION_8_1	VALIDACION_9_1	VALIDACION_10_1
VALIDACION_6_2	VALIDACION_7_2	VALIDACION_8_2	VALIDACION_9_2	VALIDACION_10_2
VALIDACION_6_3	VALIDACION_7_3	VALIDACION_8_3	VALIDACION_9_3	VALIDACION_10_3
VALIDACION_6_4	VALIDACION_7_4	VALIDACION_8_4	VALIDACION_9_4	VALIDACION_10_4
VALIDACION_6_5	VALIDACION_7_5	VALIDACION_8_5	VALIDACION_9_5	VALIDACION_10_5
	VALIDACION_7_6	VALIDACION_8_6	VALIDACION_9_6	VALIDACION_10_6
VALIDACION_6_7		VALIDACION_8_7	VALIDACION_9_7	VALIDACION_10_7
VALIDACION_6_8	VALIDACION_7_8		VALIDACION_9_8	VALIDACION_10_8
VALIDACION_6_9	VALIDACION_7_9	VALIDACION_8_9		VALIDACION_10_9
VALIDACION_6_10	VALIDACION_7_10	VALIDACION_8_10	VALIDACION_9_10	

Figura 3. 6 Esquema Validación cruzada del modelo obtenido aplicado al conjunto de datos de entrenamiento

CAPITULO IV: TECNICA EFICIENTE PARA RECONOCIMIENTO FACIAL GLOBAL EN 2D

En el presente capitulo, se procederá a detallar la técnica eficiente a utilizarse, para el reconocimiento facial en 2D; para lo cual, se toma en cuenta la base datos FERET y MUCT

4.1 Selección y justificación de las tecnologías utilizadas

4.1.1 Bases de datos 2D seleccionados

Para la primera parte de la investigación se selecciona las bases de datos FERET (Sadhya & Kumar, 2019) y MUCT (Sadhya & Kumar, 2019), (Milborrow, S., Morkel, J., & Nicolls, 2010), en función de su disponibilidad y adecuación al estudio. La base de datos FERET utilizada, consta de 200 imágenes correspondientes a 20 personas, es decir 10 rostros por persona, con una resolución de 480 x 640 pixeles. Esta base de datos está conformada por rostros caracterizados por: pose, expresión y género, un ejemplo de estos se observa en la figura 4.1. Mientras que la data MUCT contiene 1515 figuras y con resolución de 480 x 640 pixeles, correspondientes a 101 personas, es decir 15 imágenes por persona. Esta base de datos está conformada por rostros caracterizados por iluminación, pose, estado de ánimo y género, un ejemplo de estos se muestra en la figura 4.2




Figura 4. 1 Base de datos utilizado FERET
Fuente: Extraído de (Sucar, 2009)




Figura 4. 2 Base de datos utilizado MUCT
Fuente: Extraído de (Milborrow, S., Morkel, J., & Nicolls, 2010)

4.1.2. Algoritmo de extracción de características seleccionado

Revisada la literatura sobre el proceso de reconocimiento facial, interviene la fase de extracción de características, como se manifiesta en 2.9 del capítulo II, los algoritmos de extracción de los caracteres que consisten en sacar información asociada con la activación de los diversos músculos de la cara, esta actividad puede hacerse de manera global o local en donde se examina la cara como un conjunto unico, respectivamente; es así que, se escogen regiones de interés de la cara como ojos, cejas y boca (Leiva José, 2007). Por lo que de los algoritmos revisados, se ha seleccionado el filtro y extractor de características de Gabor; por cuanto es muy utilizado por los buenos resultados obtenidos (Mariñas Guillermo, 2009).

No obstante es de mencionarse que, entre las particularidades del rostro a extraer podemos diferenciar dos tipos: las transitorias que comparten diversos tipos de arrugas y abultamientos y se crean debido a las expresiones del rostro y las no transitorias, que

normalmente se presentan en la cara, entre estas se encontramos los ojos, las cejas y la boca, y a disparidad de las primeras siempre están ahí en las expresiones del rostro humano. Es así que la modificación de Gabor se la aplica en forma localizada, usando la función ventana gaussiana, con la que obtenemos un cambio muy parecido a la transformada wavelet; sin embargo, para el caso de las figuras se utiliza una función base que es una exponencial compleja y una función ventana gaussiana en 2D multiplicadas, para lograr un conjunto de funciones en base a la transformada y podemos variar las frecuencias centrales de la exponencial compleja, se podrían variar el ancho de la ventana con la desviación estándar de la gaussiana y se puede transformar la orientación de la función final. (Castrillon et al., 2008)

Por lo que, este filtro trabaja exclusivamente con tres parámetros importantes como la frecuencia central, el escalado y la orientación, los mismos que se definen en 2.8.1 y 2.9.1 del capítulo II.

4.1.3 Algoritmo de clasificación

En la actualidad se cuenta con varios algoritmos de clasificación, sin embargo, en base a la revisión de varios trabajos sobre reconocimiento facial, se pudo establecer que el algoritmo Máquina de Vectores Soporte (SVM) resulta el mejor en base a los resultados obtenidos; por lo cual, es de aclararse que, las SVMs fueron desarrolladas por Vapnik y son entrenadas por algoritmos de optimización convexa; es decir que existe una única solución; por lo cual, son construidas a partir de una estructura que depende de un subconjunto de vectores soporte, que ayudan a la interpretación del modelo. Durante la tarea de clasificación existen dos fases: la fase de aprendizaje automático y la fase de reconocimiento. (Gonzales; et al, 2017)

Es así que, como se indica en la tabla 2.6 del capítulo II; se ha seleccionado este clasificador SVM para la realización del estudio.

4.2 Modelo desarrollado para reconocimiento facial global en 2D

En la figura 4.3 se muestra el modelo propuesto para reconocimiento facial en 2D, en el mismo que se plantea la aplicación de Gabor para el filtrado y separar las características de un rostro, así como la máquina de vector de soporte (SVM) para la

clasificación (reconocimiento facial), a través de su kernels: Lineal, Cúbico y Gaussiano.

En base a las teorías revisadas y analizadas, se plantea el siguiente modelo, que se presenta en la figura 4.3

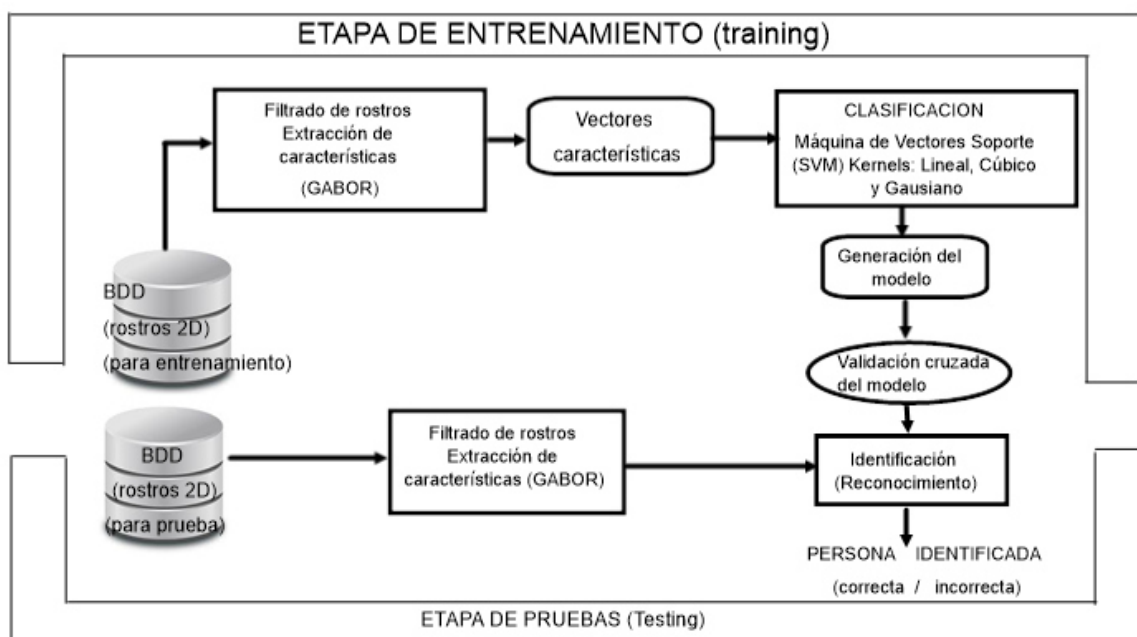


Figura 4.3 Modelo del proceso de reconocimiento facial en 2D

4.2.1. Componentes del modelo de reconocimiento facial global en 2D

Las dos etapas inician con la selección de una base de datos, para finalmente concluir en la etapa de validación o reconocimiento; por lo que, el modelo planteado consta de los siguientes componentes:

- 1) Base de datos de rostros.- Se cuenta con la data FERET y MUCT, las mismas que contienen un conjunto de imágenes 2D, FERET es un estándar dataset usado para la evaluación del sistema de reconocimiento facial. El programa Face Recognition Technology (FERET) es manejado por Defense Advanced Research Projects Agency (DARPA) y el Instituto Nacional de Estándares y Tecnología (NIST). La base de datos MUCT se creó para proporcionar una mayor diversidad de iluminación, edad y etnia que las bases de datos de caras 2D marcadas actualmente disponibles

- 2) Filtrado y extracción de características de imágenes.- consiste en un conjunto de métodos que permiten asignar entidades de entrada a nuevas entidades de salida. Esta técnica permite apartar características como: coordenadas, objetos, colores, texturas, propiedades de los elementos faciales, así como: objetos y formas de las escenas.
- 3) Vector de características.- Consiste en almacenar todas las características extraídas en un vector de m columnas.
- 4) Clasificación.- Es un proceso que trata de asignar las diferentes partes del vector de características a grupos o clases, basándose en las características extraídas anteriormente, para ello se utiliza el clasificador SVM.
- 5) Generación del modelo.- Una vez realizada la clasificación se obtiene un modelo de clasificación realizada con todas las clases o imágenes de entrenamiento
- 6) Validación cruzada.- El modelo generado en el proceso anterior es sometido a un proceso de validación cruzada, obteniendo un valor cuantitativo en cuanto a su eficiencia de reconocimiento.
- 7) Identificación o reconocimiento. - Es la fase final, en donde se somete las imágenes de prueba para ser procesadas con el modelo generado y probar la eficacia de su identificación o reconocimiento, es decir verificar si se corresponden o no a la clase correcta.

La descripción de cada uno de estos componentes se indica en el apartado 4.3 correspondiente a la implementación del modelo.

4.3 Implementación del modelo

Para la implementación del modelo para reconocimiento facial se diseñó un software en Matlab R2015a para 64 bits, este software bajo licencia es una aplicación sólida en el tratamiento de imágenes, toda vez que transforma una imagen en una tabla matricial de valores y finalmente resulta manejable para aplicar diferentes filtros y kernels que vienen incorporados en el mismo.

En el modelo desarrollado que se observa en la figura 4.3, consta de dos etapas importantes: Una etapa de entrenamiento y otra de prueba. Las dos etapas inician con la selección de una base de datos, para finalmente concluir en la etapa de identificación (reconocimiento). A continuación se describe cada uno de los componentes del modelo que se va a implementar:

1. Base de datos de rostros. - Las BDD utilizados son dos: FERET (Sadhya & Kumar, 2019) y MUCT (Sadhya & Kumar, 2019), (Milborrow, S., Morkel, J., & Nicolls, 2010), la primera consta de 200 imágenes de tamaño 480 x 640 pixeles correspondientes a 20 individuos. Esta dataset está conformada por imágenes que presentan diferentes edades, género, etnias, poses y expresiones. Una parte de esta dataset se indica en la figura 4.4




Figura 4. 4 Dataset Feret utilizada
Fuente: Extraído de (Rosales & Gualle, 2006)

La segunda dataset utilizada llamada MUCT está compuesta por 1515 rostros correspondientes a 101 personas y un tamaño de 480x640 píxeles. Esta dataset está conformada por imágenes que presentan diferentes edades, género, etnias, poses, expresiones e iluminación. Una parte de esta dataset se indica en la figura 4.5



Figura 4. 5 Dataset MUCT utilizada
Fuente: Extraído de (Milborrow, S., Morkel, J., & Nicolls, 2010)

2. Filtrado y extracción de características de imágenes. - El proceso indicado se lo realiza a través de Wavelets de Gabor, que contempla el filtrado y extracción de características de un conjunto de rostros de las bases de datos mencionados anteriormente.

3. Vector de características. - Todas las características principales extraídas en el proceso anterior son almacenadas en vectores, de allí su nombre de vectores características.
4. Clasificación. - Proceso que trata de asignar las diversas partes del vector de caracteres a grupos o clases, que se basan en las características sacadas anteriormente, el proceso se realiza para las imágenes de entrenamiento (aprender).
5. Finalmente viene la etapa de Identificación (reconocimiento), que consiste en identificar la imagen de prueba ingresada a que clase corresponde, donde se valida si la identificación es acertada o desacertada.

De acuerdo al modelo establecido, su implementación se inicia con:

- a) La lectura de las bases de datos indicado anteriormente: FERET y MUCT.
- b) A continuación, se genera los filtros de Gabor. Parte del resultado obtenido se indica en la figura 4.6, una parte aplicada a una imagen de la dataset MUCT.

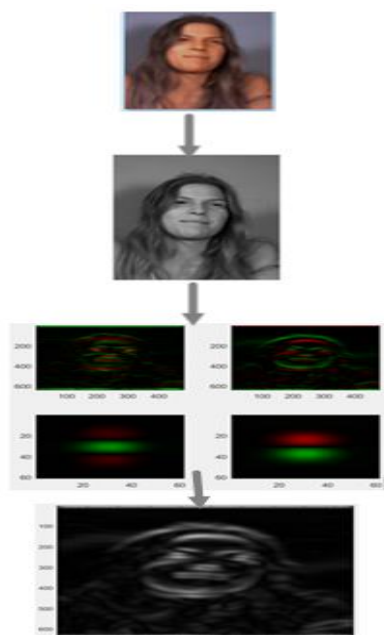


Figura 4. 6 Resultado del filtrado de una imagen por Gabor

- c) Seguidamente se realiza la extracción de características para obtener los vectores característicos y almacenar en un banco de características. El proceso de filtrado y extracción se realiza tanto con imágenes de entrenamiento como de prueba.
- d) Las características obtenidas se los guarda en una tabla denominada vector de características, de allí su nombre de vectores característicos. Una parte de vectores característicos correspondiente a la base de datos FERET se indica en la figura 4.7, el proceso es el mismo para base de datos MUCT.

	1	2	3	4	5	6	7	8	9	10	11	12	13
5	0.7489	1.9145	-0.6735	-0.6601	-0.6487	-0.6810	2.1832	0.0292	-0.5172	-0.5018	-0.5715	-0.6220	2.2321
6	0.7580	1.9095	-0.6823	-0.6590	-0.6566	-0.6696	2.1662	0.1072	-0.6025	-0.5653	-0.5182	-0.5873	2.2290
7	0.7600	1.9084	-0.6741	-0.6503	-0.6685	-0.6755	2.1564	0.1437	-0.6072	-0.5056	-0.5813	-0.6060	2.2351
8	0.7672	1.9044	-0.6700	-0.6600	-0.6660	-0.6757	2.1171	0.2812	-0.6014	-0.5791	-0.5927	-0.6250	2.2141
9	0.7442	1.9170	-0.6754	-0.6406	-0.6674	-0.6778	2.1760	0.0680	-0.5876	-0.5431	-0.5427	-0.5707	2.2354
10	0.7237	1.9282	-0.6691	-0.6556	-0.6643	-0.6629	2.1659	0.1101	-0.5752	-0.5362	-0.5714	-0.5932	2.2311
11	0.7412	1.9187	-0.6730	-0.6502	-0.6662	-0.6705	2.1645	0.1168	-0.5736	-0.5632	-0.5819	-0.5627	2.2361
12	0.8295	1.8683	-0.6746	-0.6440	-0.7048	-0.6744	2.1967	-0.0415	-0.4610	-0.5623	-0.6068	-0.5252	2.1831
13	1.3467	1.4796	-0.7021	-0.7009	-0.7166	-0.7066	2.2285	-0.2762	-0.4968	-0.4358	-0.4906	-0.5292	2.2351
14	1.3162	1.5078	-0.7039	-0.6974	-0.7181	-0.7047	2.2176	-0.1764	-0.5413	-0.4275	-0.5487	-0.5238	2.2351
15	1.2973	1.5248	-0.7209	-0.6986	-0.7175	-0.6851	2.2323	-0.3290	-0.4691	-0.4416	-0.5152	-0.4774	2.2348
16	1.7812	0.9678	-0.6670	-0.7083	-0.6737	-0.7001	2.2211	-0.1987	-0.4467	-0.5235	-0.5250	-0.5272	2.2351

Figura 4. 7 Banco de vectores característicos de bdd FERET

- e) A continuación, se procede con la clasificación de las características extraídas anteriormente, el proceso se realiza tanto para las imágenes de entrenamiento (aprender), como de prueba. Para nuestro caso se trabajó con el clasificador Máquina de vectores soporte (SVM), a través de sus kernels o funciones: Lineal, cúbico y gaussiano.
- f) Una vez realizado la clasificación de patrones con SVM, se aplica la validación cruzada para validar el modelo de entrenamiento obtenido, los resultados se indican en el apartado 4.4.

Una parte del código del modelo implementado, se encuentra en el Anexo 2.

4.4 Validación del Modelo

En cuanto a la validación del modelo, y con la finalidad de verificar el grado de confianza que tiene este modelo, se procede por validación cruzada como ya se lo mencionó con anterioridad, para una mejor visualización, parte de los resultados adquiridos con las dos datas y sus respectivos kernels se indican en las figuras que van desde la 4.8 hasta la 4.13. Es así que al finalizar la validación, se pudieron obtener los resultados que son expuestos en la tabla 4.1 del presente documento.

Validación

Validar Modelo

	Prediccion	True	Acerto?	probabilidad
12	persona11	persona11	ok	0.9997
13	persona11	persona11	ok	0.9923
14	persona11	persona11	ok	0.9807
15	persona11	persona11	ok	0.9919
16	persona12	persona12	ok	1
17	persona12	persona12	ok	1
18	persona12	persona12	ok	1
19	persona12	persona12	ok	1
20	persona12	persona12	ok	1
21	persona13	persona13	ok	0.9995
22	persona13	persona13	ok	1.0000
23	persona13	persona13	ok	0.9811
24	persona13	persona13	ok	0.9970
25	persona13	persona13	ok	0.9166
26	persona14	persona14	ok	1

Aciertos: 100 / 100 Eficacia:
1.000000

Figura 4. 8 Validación modelo, bdd Feret kernel lineal

En cuanto a la validación del modelo bdd Feret Kernel lineal se pudo obtener como resultado el 100%, a su vez se puede observar que de todas las pruebas 6 fueron de 1.0 de probabilidad, mientras que la mínima de probabilidad fue la de 0,9166 y el resto de aciertos fue de 0,98 en adelante lo cual determina un 100% de eficacia para todas las pruebas realizadas.

Validación

Validar Modelo

	Prediccion	True	Acerto?	probabilidad
1	persona1	persona1	ok	1
2	persona1	persona1	ok	1
3	persona1	persona1	ok	1
4	persona1	persona1	ok	1
5	persona1	persona1	ok	1
6	persona10	persona10	ok	0.9956
7	persona10	persona10	ok	0.9956
8	persona10	persona10	ok	0.9956
9	persona10	persona10	ok	0.9956
10	persona10	persona10	ok	0.9956
11	persona11	persona11	ok	0.9943
12	persona11	persona11	ok	0.9943
13	persona11	persona11	ok	0.9943
14	persona11	persona11	ok	0.9943
15	persona11	persona11	ok	0.9943

Aciertos: 100 / 100 Eficacia:
1.000000

Figura 4. 9 Validación modelo, bdd Feret kernel cúbico

En relación a la visualización de esta gráfica se puede observar claramente que todas las pruebas que se realizaron tuvieron el 100% de eficacia no obstante de las pruebas realizadas 5 tuvieron 1,0 de probabilidad. Mientras que el resto de pruebas fueron aproximadas al inmediato superior, teniendo como resultado que el que tuvo menor probabilidad fue el de 0,9943 y las demás pruebas dieron un resultado superior al que ya se mencionó, por lo cual, se comprueba que todas las pruebas fueron óptimas con aciertos de 100/100 y una eficacia de 1.000000.

Validación

Validar Modelo

	Prediccion	True	Acerto?	probabilidad
12	persona11	persona11	ok	1.0000
13	persona11	persona11	ok	0.9979
14	persona11	persona11	ok	0.9930
15	persona11	persona11	ok	0.9977
16	persona12	persona12	ok	1
17	persona12	persona12	ok	1
18	persona12	persona12	ok	1
19	persona12	persona12	ok	1
20	persona12	persona12	ok	1
21	persona13	persona13	ok	0.9998
22	persona13	persona13	ok	1.0000
23	persona13	persona13	ok	0.9866
24	persona13	persona13	ok	0.9981
25	persona13	persona13	ok	0.9220
26	persona14	persona14	ok	1

**Aciertos: 100 / 100 Eficacia:
1.000000**

Figura 4. 10 Validación modelo, bdd Feret kernel Gaussiano

Cómo se observa en la gráfica, los aciertos que se dieron en este caso fueron de 100/100, es decir que todos llegaron o se aproximaron al 100% de eficacia, no obstante 7 de las pruebas tuvieron una probabilidad excelentes sin errores mientras que la prueba que tuvo menos probabilidad fue la de 0,9220; seguida de pruebas de más de 0,99; por lo cual estas pruebas se elevaron al inmediato Superior y tenemos que todas las pruebas tuvieron una probabilidad excelente el 100% y una eficacia de 1.000000




Figura 4. 11 Validación modelo, bdd Muct kernel Lineal

Cómo se observa en la figura 4.11, para la validación del modelo bdd Muct Kernel Lineal, se obtuvo aciertos de 1350/1515 es decir que no fue totalmente acertado, por lo que obtuvo una eficacia de 0,891089; debido a que existieron pruebas inferiores y no cumplieron con las expectativas, es así que la que obtuvo menos probabilidad fue la de predicción p09 con una probabilidad de 0,0272 seguida de la predicción p04 con una probabilidad de 0,5065 sin embargo las siguientes pruebas tuvieron un valor superior a 0, 8139 con lo cual justifica el resultado que se obtuvo de aciertos y eficacia.

Validación

Validar Modelo

	Prediccion	True	Acerto?	probabilidad
1	p0	p0	ok	1.0000
2	p9	p0	no	0.8641
3	p0	p0	ok	1.0000
4	p0	p0	ok	1.0000
5	p0	p0	ok	1.0000
6	p0	p0	ok	1.0000
7	p0	p0	ok	0.9971
8	p0	p0	ok	1.0000
9	p0	p0	ok	1.0000
10	p0	p0	ok	1.0000
11	p0	p0	ok	1.0000
12	p0	p0	ok	1.0000
13	p0	p0	ok	1.0000
14	p0	p0	ok	1.0000
15	p0	p0	ok	1.0000

Aciertos: 1353 / 1515
Eficacia: 0.893069

Figura 4. 12 Validación modelo, bdd Muct kernel Cúbico

En cuanto a la realización de este modelo según la figura 4.12, podemos observar que de los aciertos según esta imagen fueron de 1353/1515 con una eficacia de 0,893069; lo cual se justifica debido a que no todas las pruebas tuvieron el puntaje máximo en probabilidad. Por lo cual la menos puntuada para probabilidad fue la p92 con un valor de 0,8641 seguida de p07 con valor de 0,9971; sin embargo el resto de aciertos, se obtuvieron 1,0000; lo cual justifica el valor final de la eficacia que como ya se expuso fue de 0,893069.




Figura 4. 13 Validación modelo, bdd Muct kernel Gaussiano

Finalmente en esta última figura 4.13, podemos observar que se obtuvieron aciertos de 1347/1515 con una eficacia de 0,88 9109; debido a que sólo dos de las pruebas tuvieron un puntaje máximo que es de 1,0000; seguido de valores inferiores como el que se obtuvo en p09 con un valor de 0,0316 que fue la prueba con menos puntuada para la probabilidad seguida de la prueba P04 con un valor de 0,5685; por lo que es de mencionarse que el resto de pruebas tuvieron valores superiores a 0,8460 pero inferiores a 1,0000; lo cual justifica que se haya obtenido una eficacia de 0,889109

Los resultados obtenidos de la validación del modelo se resumen en la tabla 4.1

Tabla 4. 1 Resumen de validación cruzada a los modelos de aprendizaje generados

BASES DE DATOS	KERNEL LINEAL (%)	KERNEL CUBICO (%)	KERNEL GAUSSIANO (%)
FERET	100	100	100
MUCT	89,1	89,3	88,9

En base al resumen de validación cruzada realizada en la etapa de entrenamiento, se establece que los tres kernels (lineal, cúbico y gaussiano) alcanzan un máximo del

100%, con la base de datos FERET, superando totalmente al trabajo realizado con MUCT, posiblemente se deba a la mejor resolución de las figuras de la primera data.

4.5 Descripción de los experimentos y sus resultados

En la realización del entrenamiento y pruebas, se utilizaron un total de 200 rostros correspondientes a 20 personas, parte de la base FERET y 1515 correspondientes a 101 personas de la base MUCT. Respecto a la dataset FERET, se separó 5 imágenes para la etapa de entrenamiento y 5 imágenes para pruebas por cada persona, mientras que de la base MUCT se seleccionó 12 imágenes para entrenamiento y 3 para pruebas por cada persona.

A continuación, se presenta en la tabla 4.2, un resumen de los resultados que obtenemos en la fase de identificación (prueba) de la clase al que pertenece cada uno de los caras humanas de la data FERET seleccionados para la prueba a través de los kernels Lineal, Cúbico y Gaussiano, en total se realizaron 300 pruebas con los kernels mencionados.

Tabla 4.2 Resumen de resultados con Bdd FERET

KERNELS	25 imágenes	50 imágenes	75 imágenes	100 imágenes
	# de aciertos	# de aciertos	# de aciertos	# de aciertos
Kernel_Lineal	25	50	72	95
Kernel_Cúbico	23	46	68	92
Kernel_Gaussiano	25	50	72	96

La tabla 4.2 presenta los resultados obtenidos sobre la identificación de la clase a la que pertenece, como se visualiza, se realizó un total de 100 pruebas por cada kernel con un total de 300 pruebas con rostros correspondientes a la base de datos FERET. Obteniendo un mayor número de aciertos con el kernel Gaussiano con 96 aciertos y un mínimo de 92 aciertos con el kernel cúbico de un total de 100. Cabe anotar que las pruebas se realizaron en una forma aleatoria con respecto al número de la clase, para ello se utilizó la función aleatoria de Microsoft Excel (ver anexos 4, 5 y 6).

Finalmente, los resultados presentados están divididos en 4 rangos o intervalos, tales como: (1-25, 26-50, 51-75, 76-100) imágenes con el fin de ir visualizando como va variando el número de aciertos. Estos resultados obtenidos en la tabla 4.2 se lo presenta en modo porcentual en la tabla 4.3, el mismo que se lo puede visualizar gráficamente en la figura 4.13 para su respectivo análisis.

Tabla 4.3 Porcentaje de reconocimiento de clases con Bdd FERET

KERNELS	25 imágenes	50 imágenes	75 imágenes	100 imágenes
Kernel_Lineal (%)	100,0	100,0	96,0	95,0
Kernel_Cúbico (%)	92,0	92,0	90,7	92,0
Kernel_Gaussiano (%)	100,0	100,0	96,0	96,0

La tabla 4.3 muestra los resultados anteriores de reconocimiento en una forma porcentual, la misma que figura el kernel Gaussiano con un 96,0% que corresponde al mayor acierto obtenido en las pruebas y un mínimo del 92% con el kernel cúbico.

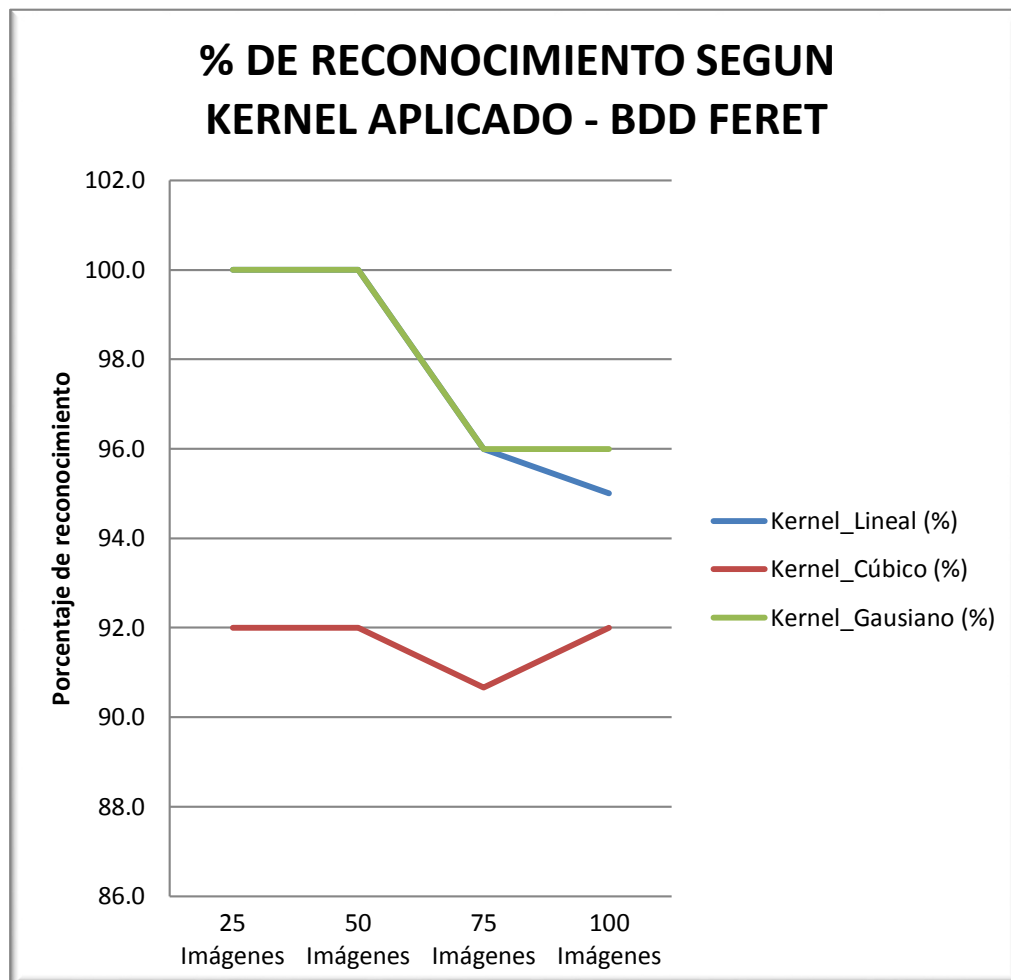


Figura 4.14 Porcentaje de reconocimiento de clases con Bdd FERET

En la figura 4.14 nos permite visualizar la tendencia de la trayectoria de las curvas, sea variable o constante en función del porcentaje de acierto. De acuerdo a los resultados, en el intervalo de 50-75 los tres kernels: Lineal, cúbico y gaussiano sufren una baja en cuanto a los aciertos, a partir de la prueba 76 el kernel gaussiano mantiene una trayectoria constante por el orden del 96% hasta el final, mientras el lineal mantiene una tendencia de bajada, mientras el kernel cúbico a partir de la prueba 76 tiene una tendencia de subida hasta el final.

De idéntica manera se presenta en la tabla 4.4, un resumen de los resultados obtenidos en la validación de fase de identificación (pruebas) de la clase al que pertenece cada uno de los rostros de las bases de datos MUCT seleccionados para la prueba a través de los kernels Lineal, Cúbico y Gaussiano.

Tabla 4.4 Resumen de resultados con Bdd MUCT
RECONOCIMIENTO DE CLASES SEGUN KERNEL APLICADO - BDD
MUCT

KERNELS	50	100	150	200	250	303
	imágenes	imágenes	imágenes	imágenes	imágenes	imágenes
	# de	# de	# de	# de	# de	# de
	aciertos	aciertos	aciertos	aciertos	aciertos	aciertos
Kernel_Lineal	50	98	140	182	226	271
Kernel_Cúbico	50	95	141	188	233	284
Kernel_Gaussiano	50	99	141	185	229	274

La tabla 4.4, presenta los resultados obtenidos sobre la identificación de la clase a la que pertenece, se realizó un total de 303 pruebas por cada kernel con un total de 909 pruebas con rostros correspondientes a la base de datos MUCT. Obteniendo un mayor número de aciertos con el kernel Cúbico con 284 aciertos y un mínimo de 271 aciertos con el kernel lineal de un total de 303. Cabe anotar que las pruebas se realizaron en una forma aleatoria con respecto al número de la clase, para ello se utilizó la función aleatoria de Microsoft Excel (ver anexos 7, 8 y 9). Finalmente, los resultados presentados están divididos en 6 rangos o intervalos, tales como: (1-50, 51-100, 101-150, 151-200, 201-250 y 251-303) imágenes con el fin de ir visualizando como va variando el número de aciertos. Estos resultados obtenidos se lo presenta en modo porcentual en la tabla 4.5 al mismo tiempo que se lo puede visualizar gráficamente en la figura 4.15 para su respectivo análisis.

Tabla 4.5 Porcentaje de reconocimiento de clases con Bdd MUCT
% DE RECONOCIMIENTO DE CLASES SEGUN KERNEL APLICADO
BDD MUCT

KERNELS	50 imágenes	100 imágenes	150 imágenes	200 imágenes	250 imágenes	303 imágenes
Kernel_Lineal (%)	100,0	98,0	93,3	91,0	90,4	89,4
Kernel_Cúbico (%)	100,0	95,0	94,0	94,0	93,2	93,7
Kernel_Gaussiano (%)	100,0	99,0	94,0	92,5	91,6	90,4

La tabla 4.5 muestra los resultados anteriores de reconocimiento en una forma porcentual, la misma que figura el kernel Cúbico con un 93,7% que corresponde al mayor acierto obtenido en las pruebas y un mínimo del 89,4% con el kernel lineal.




Figura 4.15 Porcentaje de reconocimiento de clases con Bdd MUCT

En la figura 4.15 nos permite visualizar la tendencia de la trayectoria de las curvas, sea variable o constante en función del porcentaje de acierto. De acuerdo a los resultados, los kernels: Lineal y gaussiano mantienen una trayectoria con tendencia a la baja durante todo el proceso de las pruebas, mientras el kernel cúbico presenta una trayectoria con tendencia a seguir subiendo con respecto de los aciertos a partir de la prueba No. 250.

4.6 Discusión de los resultados

De acuerdo al modelo presentado en la figura 4.3 se procede con los experimentos para la fase de entrenamiento y pruebas. Para el mismo se utilizan las bases de datos FERET y MUCT. En las tablas 4.2 y 4.4 se muestran los resultados realizados para cada una de las bases de datos por cada kernel utilizado dentro del SVM. Es decir que para el presente estudio, se procedió a realizar experimentos con los modelos propuestos para el desarrollo del estudio; con lo que al finalizar la fase de pruebas, se pudo obtener buenos resultados; pues como se muestra en la tabla 4.1, se obtuvo un puntaje de 100% con la base de datos de Ferret, en sus validaciones de Kernel Lineal, Kernel Cúbico y Kernel Gaussiano; lo que no ocurrió con la base de datos de MUCT, puesto que aquí se obtuvieron ciertas diferencias como 89,1% para Kernel Lineal; 89,3% para Kernel Cúbico, y 88,9 para Kernel Gaussiano.

No obstante y como ya se referenció, de acuerdo a la obtención de resultados, se contempla que con la base de datos FERET, se obtiene un mayor acierto de reconocimiento (96%) con el kernel Gaussiano, teniendo en cuenta que, la prueba se realizó con 100 imágenes correspondientes a 20 personas, con un total de 300 pruebas con los 3 kernels; que por lo contrario ocurrió con Kernel Cúbico, pues este fue el de menor puntaje con 100 imágenes, ya que obtuvo un porcentaje del 92% como resultados de la pruebas; sin embargo, es de resultados similares para menor cantidad de imágenes, pues en todas las pruebas según número de imágenes, la de menor porcentaje, resultó ser la de kernel cúbico, como se ilustra en la tabla 4.2

Por otro lado, lo contrario ocurrió con la base de datos MUCT, pues se obtiene un mayor acierto de reconocimiento con un 93,7% para el kernel cúbico, en donde, la

prueba se realizó con 303 imágenes correspondientes a 101 personas, con total de 909 pruebas con los 3 kernels; por lo cual, es claro que para esta ocasión, se utilizó una mayor cantidad de imágenes; con lo que se pudo determinar que obtuvo mejor porcentaje fue la de kernels cúbico con 303 imágenes; mientras que la menor puntuada en las mismas características fue la de Kernel Lineal, por lo que, al analizar los resultados se puede determinar que mientras mayor cantidad de imágenes se integraban en la prueba, mejores resultados obtenía el kernel cúbico; y mientras menos imágenes se integran, fue el Kernel Gaussiano que tenía mejor puntuación con 99 para 100 imágenes, seguido por kernel lineal con 98 en las mismas características con 100 imágenes; por lo que los resultados varían según el número de imágenes como se indica en la tabla 4.4.

Finalmente, se realiza una comparación con otros experimentos que funcionan con métodos de [21]: cuantificación de fase local (LPQ), muestreo descendente (DS), los patrones binarios locales (LBP) y Gabor, todos combinados con SVM. Un resumen de esta comparación se indica en la tabla 4.6

Tabla 4. 6 Resumen de comparación con otros trabajos relacionados

Métodos	Base de datos	Porcentaje de reconocimiento
LBP+SVM (Sun, Zhao, & Jin, 2018)	RAFD-FRONT	86,50%
Gabor+SVM (Sun et al., 2018)	RAFD-FRONT	83,10%
LPQ+SVM (Sun et al., 2018)	RAFD-FRONT	84,80%
DS+SVM (Sun et al., 2018)	RAFD-FRONT	79,00%
La presente investigación	FERET	96,00%
La presente investigación	MUCT	93,70%

En las comparaciones realizadas, es visible que nuestro método que consiste en trabajar con la base de datos FERET y MUCT, luego de filtrar y extraer características para finalmente realizar la clasificación ha resultado ser muy sólido con respecto a los trabajos revisados anteriormente.

CAPITULO V: TECNICA EFICIENTE PARA RECONOCIMIENTO FACIAL GLOBAL EN 3D

En el presente capítulo, se procede a detallar la técnica eficiente a utilizarse, para el reconocimiento facial en 3D; para lo cual, se toma en cuenta la base de datos de TEXAS3DFRD y BU-3DFE

5.1 Selección y justificación de las tecnologías para reconocimiento facial 3D

5.1.1 Bases de datos 3D seleccionados

Existen dos tipos de datos para procesamiento de imágenes faciales en 3D:

- a) Imágenes faciales 3D con puntos de referencia.

Uno de los métodos utilizados para tratar imágenes de 3D, son los puntos de referencia, conocidos como puntos fiduciaros. Se indica en la Fig. 5.1




Figura 5. 1 Puntos fiduciales antropométricos (a) en una imagen en color, y (b) en una imagen de rango

Fuente: Extraído de (Castleman, Markey, & Bovik, 2010)

Estos puntos fiduciaros fueron ubicados manualmente en las imágenes de color facial utilizando una interfaz gráfica de usuario basada en computadora para motivos de estudio por otros investigadores. (Castleman et al., 2010)

b) Imágenes faciales 3D con máscaras

Para la segunda parte de este capítulo, se considera modelos de caras en 3D, estos modelos que representan rostros humanos fueron proyectados a los tres planos ($x-z$), ($y-z$) y ($z-x$), una parte del código en Matlab 2015 de la función creada para obtener estas perspectivas se indica en el Anexo 15; en el mismo que se puede visualizar como la aplicación hace un llamado de la imagen la convierte en 2D y la almacena temporalmente en un directorio; lo mismo lo hace con cada plano; para finalmente volver a tomar todos estos planos y obtener una figura en 3D

Los modelos faciales 3D se han utilizado ampliamente para el reconocimiento facial 3D y la animación facial 3D, no obstante, se desconoce la utilidad de dichos datos para el reconocimiento de expresiones faciales 3D; sin embargo, con la finalidad de fomentar la investigación en este campo, se creó una base de datos de expresión facial en 3D (llamada base de datos BU-3DFE), que incluye 100 sujetos con 2500 modelos de expresión facial; la misma que está disponible para la comunidad investigadora, por lo que, las áreas de interés provienen de áreas tan diversas como la informática afectiva, la visión por computadora, la interacción con la computadora humana, la seguridad, la biomedicina, la aplicación de la ley y la psicología. (Yin, et al, 2010)

Teniendo en cuenta que, a pesar de que, los humanos usan las expresiones faciales con éxito para transmitir sus estados emocionales; replicar tal éxito en el dominio de interacción humano-computadora es un problema de investigación activa. (Oyedotun, Demisse, El, & Shabayek, 2017)

Hay que tomar en cuenta que, al referirse a la extensión WRL; es indispensable mencionar que es el formato estándar para gráficos vectoriales 3D interactivos; por lo cual, los archivos WRL tienen un contenido de la descripción de la

realidad virtual, la cual incluye investigación como el punto de partida de la vista 3D, coordenadas, objetos, colores, texturas, propiedades de los elementos de la escena, así como objetos y los modos de las escenas; en otras palabras nos permite una correcta forma de identificarlos (Filextensions, 2020).

El objetivo de este proceso es obtener proyecciones en 2D para posteriormente aplicar el mismo modelo del primer aporte en el proceso de reconocimiento de rostros. El resultado obtenido se muestra en la figura 5.2




Figura 5. 2 Proyección de un modelo 3D a los planos (x-z), (y-z) y (z-y)

A continuación, las bases de datos seleccionadas son:

En lo que respecta a la selección de las bases de datos 3D, se trabaja con dos muy importantes como TEXAS3DFRD (Gupta et al., 2010b) y BU-3DFE (X. Li, Ruan, Jin, et al., 2015), (L. Yin, X. Wei, Y. Sun, J. Wang, 2006), (Yin, et al, 2010).

La primera TEXAS3DFRD (Gupta et al., 2010b), contiene personas adultas tomando en cuenta su expresión, género y claridad de la imagen, con una resolución de 751 x 501 x 3 píxeles, la misma que contiene 1149 imágenes reprocesadas de alta resolución, presentan imágenes de color y rango normalizadas, preprocesadas y perfectamente alineadas de 118 sujetos humanos adultos adquiridos usando una cámara estéreo. Las imágenes representan el género, la etnia y la expresión facial de los sujetos, de los cuales por casos de estudio utilizamos imágenes correspondientes a 50 personas, dando un total de 908 imágenes entre portada y rango para el entrenamiento y 183 para las pruebas, con cada uno de los tres kernels indicados anteriormente. Un fragmento de la base de datos se muestra en la Figura 5.3




Figura 5. 3 Imágenes preprocesadas (a) de color y (b) de rango de la Base de datos Texas 3DFRD
Fuente: Extraído de (Castleman et al., 2010)

La segunda base de datos es BU-3DFE (Yin, et al, 2010), se da debido a que, las mismas contienen una amplia variedad de datos con características propias de diversas etnias, lo cual es imprescindible, ya que con ello asegura una mejor probabilidad de aciertos, a lo cual los creadores de estas base de datos mencionan que la misma contiene actualmente 100 sujetos, de los cuales por razones de estudio se optó en trabajar con 50 personas, correspondiendo 25 modelos de caras por cada persona en formato *.wrl con un total de 1250 modelos con características de expresión y género. Una parte de estas bases se indica en las Figuras 5.4 y 5.5 respectivamente.



Figura 5. 4 Base de datos TEXAS3DFRD
Fuente: Extraído de (Castleman et al., 2010)



Figura 5. 5 Base de datos BU-3DFE

Fuente: Extraído de (Oyedotun et al., 2017), (Yin,et al, 2010)

5.1.2. Algoritmos de extracción de características y de clasificación 3D

La técnica de extracción de características en imágenes se fundamenta en separar información asociada con la activación de los diversos músculos de la cara, esta tarea puede hacerse de manera global en donde se analice la cara humana como un conjunto único, para el caso de esta investigación. (Castrillon et al., 2008).

De los algoritmos revisados, se ha seleccionado wavelet de Gabor para filtrar y extraer características de la base de datos TEXAS3DFRD y de las perspectivas obtenidas de los modelos 3D de BU-3DFE, por cuanto es muy utilizado por los buenos resultados obtenidos según la literatura revisada. (Barina, 2016).

No obstante, de acuerdo a los fundamentos de la transformación de Wavelet de Gabor; la transformación ha sido la herramienta más utilizada para analizar la frecuencia de propiedades de una señal dada, mientras que después de la transformación, la información sobre el tiempo, es difícil saber dónde ocurre una determinada frecuencia; por lo que con la finalidad de solucionar el problema, se usan distintos tipos de técnicas de análisis de frecuencia de tiempo, ya que es bien sabido que cuando la duración del tiempo aumenta (Chao, 2017).

Las propiedades de resolución múltiple y orientación múltiple de Gabor; así como la transformación wavelet lo convierte en un método popular para la extracción de características incluso si existe la no ortogonalidad intrínseca; debido a que, entre todas las obras basadas en Galet wavelet se muestran que el reconocimiento y la representación de texturas son las aplicaciones más notables, mientras que al utilizar las wavelets de Gabor principalmente para la extracción de características; teniendo a Matlab por sus características permite la representación de características, no obstante las aplicaciones siguen siendo espacios para futuras investigaciones. (Chao, 2017).

En cuanto, a las funciones seleccionadas con el código respectivo para el filtrado y extracción de características de Gabor, se utilizó aquellos que vienen incorporadas en la aplicación Matlab versión R2015a para 64 bits, lo que, que permitió realizar todo el proceso de entrenamiento y pruebas en 3D con las dos bases de datos ya mencionados.

La clasificación de patrones consiste en asignar las diversas partes del vector de caracteres a grupos o clases, basándose en las formas separadas. Esta parte corresponde a lo que se conoce como aprendizaje automático, cuya razón es desarrollar diversas técnicas que permitan aprender a las computadoras.

Para la presente investigación, se trabaja con el clasificador de patrones, Máquina de vectores de soporte (SVM) con sus kernels: cúbico, lineal y gaussiano.

Finalmente, es de explicarse que, Matlab es una aplicación muy sólida en el tratamiento de imágenes, por lo cual es indispensable utilizarla como herramienta necesaria para estos estudios; puesto que las mismas que son convertidas a tablas matriciales de valores, finalmente resulta manejable para aplicar los diferentes filtros y kernels que vienen incorporados en el mismo. Con respecto al hardware, la aplicación se lo ha ejecutado en una máquina laptop hp, procesador Intel Core i5, 2.4 Ghz.

5.2 Modelo propuesto para reconocimiento en imágenes 3D

5.2.1 Modelo de imágenes facial 3D-2D con puntos de referencia

En la figura 5.6 se muestra un modelo propuesto para reconocimiento facial en 3D, en el mismo que se plantea la utilización de la base de datos TEXAS3DFRD (Gupta et al., 2010b), (Dow, Shishir, & Loannis, 2017) que trabaja con rostros en 3D reprocesadas y mas robustas para aplicar el proceso de filtrado, extracción de características y clasificación.

Para la realización de este proceso de reonocimiento, se plantea un modelo que contempla dos etapas principales: entrenamiento y pruebas, el mencionado modelo se lo indica en la figura 5.6.

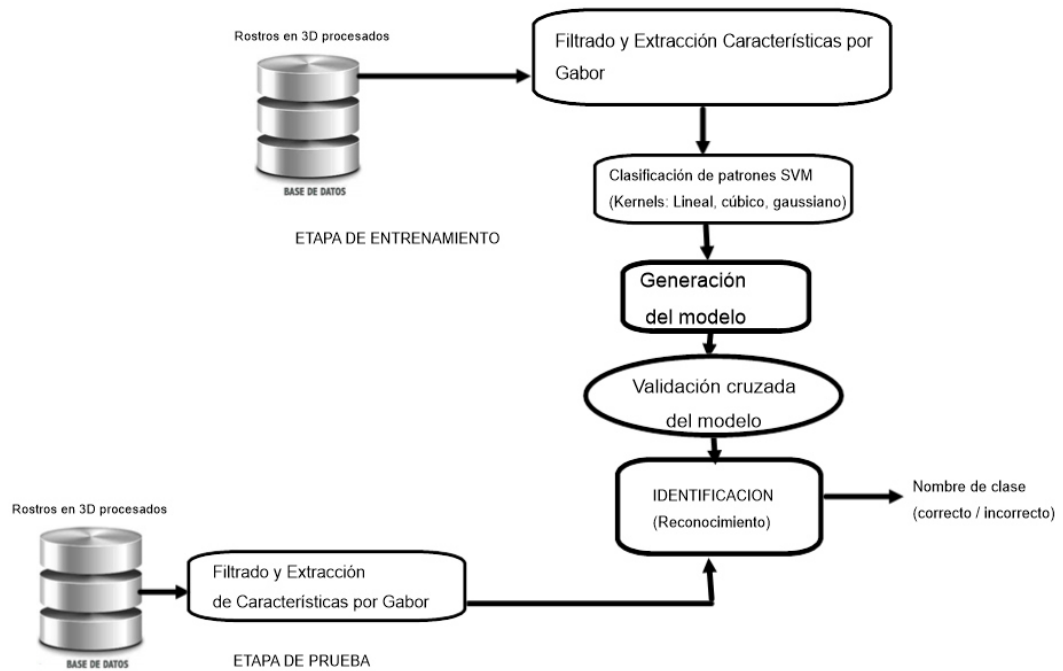


Figura 5. 6 Modelo de reconocimiento facial 3D TEXAS3DFRD

Componentes del modelo de reconocimiento facial por etapas en 3D

- **Etapa de entrenamiento**

En la etapa de entrenamiento incluyen varios componentes entre los cuales se encuentran: Filtrado de extracción de características por Gabor, en el cual como ya se había explicado anteriormente se da una extracción de las características que contiene la base de datos y se asemejan a las características de la prueba, seguido de una clasificación de patrones SVM, en la cual se produce primero una ordenación de las características según su importancia para la clasificación mediante el algoritmo luego clasifica cada imagen muestra usando todas las características en el orden obtenido anteriormente mediante el método, finalmente se obtiene la tasa correcta de clasificación para cada caso; y a continuación se integran los componentes de generación del modelo validación cruzada y una identificación que es el reconocimiento.

- **Etapa de prueba**

La etapa de prueba al igual que la de entrenamiento contiene como componentes el filtrado y extracción de características de Gabor, clasificación de características obtenidas y la identificación de la clase para obtener el nombre de misma y finalmente poder validar si fue correcto o incorrecto la identificación.

Al igual que en el primer aporte de este trabajo, se presenta un modelo de reconocimiento facial en 3D (ver figura 5.6) el mismo que hace referencia a una serie de procesos que se agrupa en 2 etapas principales que son la de entrenamiento y pruebas, en las dos etapas se cumplen los mismos procesos, pero con diferentes imágenes de una misma base de datos. Este modelo tiene los siguientes componentes y procesos importantes que se la describe a continuación:

Base de datos.- Se cuenta con la base de rostros TEXAS3DFRD (Gupta et al., 2010b), (Dow, Shishir, & Loannis, 2017), la misma que contiene un conjunto de imágenes reprocesadas. El reprocesado de imágenes consiste en preparar una imagen en 3D, para convertirlo en una forma útil para el reconocimiento facial, eliminando pequeñas regiones extrañas que no están unidas a la región de la cara, por ejemplo, puede ser unos collares, para ello se procede a normalizar y detectar la región frontal como la más grande, seguidamente se elimina las pequeñas cantidades de ruido de impulso presentes en el rango de imágenes.

Filtrado y extracción de características. - es un conjunto de métodos que asignan entidades de entrada a nuevas entidades de salida. Lo cual permite apartar características como objetos, colores, texturas, coordenadas, propiedades de los elementos faciales.

Vector de características.- Todas las características principales extraídas en el proceso anterior son almacenadas en vectores, de allí su nombre de vectores características; es decir que se reconocen características especiales como dimensiones y formas de nariz, ojos, boca, pómulos, entre otros.

Clasificación.- Proceso que trata de asignar las diversas partes del vector de características a grupos o clases, basándose en las propiedades extraídas anteriormente.

En esta etapa se tiene como objetivo desarrollar técnicas que permitan a las computadoras aprender. Para nuestro caso se trabajó con el clasificador Máquina de vectores soporte (SVM), a través de kernels o funciones: Lineal, cúbico y gaussiano. Finalmente viene la etapa de reconocimiento, ya en la fase de pruebas, que consiste en identificar la imagen ingresada a que clase corresponde, donde se valida si la identificación es correcta o incorrecta.

5.2.2 Modelo de imágenes facial 3D-2D con máscaras

El modelo de reconocimiento facial en 3D se implementa con la base de datos BU-3DFE, y es muy parecido a los modelos anteriores, pero con una importante diferencia acerca de las proyecciones del modelo o máscara a los tres planos $x-z$, $y-z$ y $z-y$, como se indica en la figura 5.7

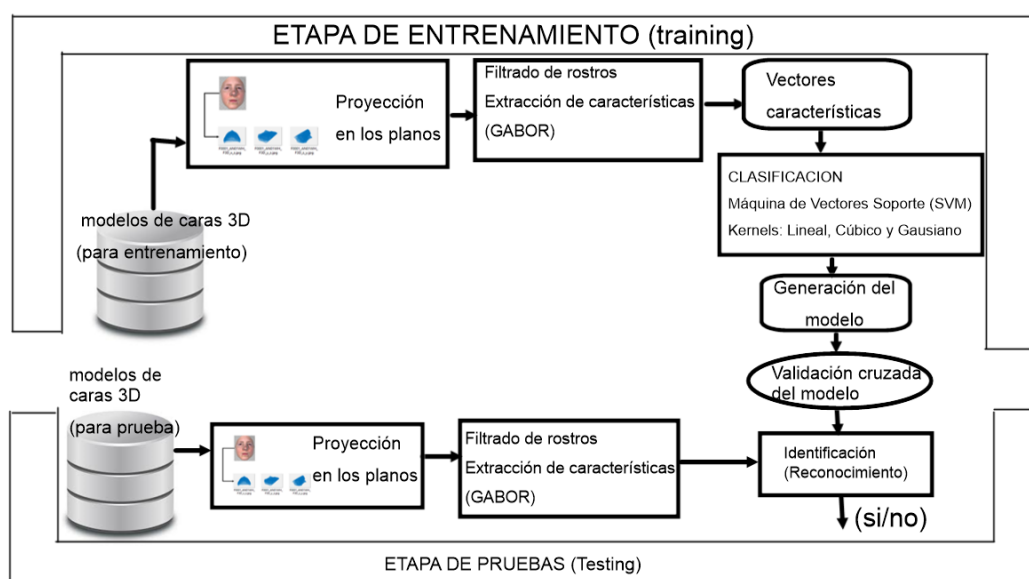


Figura 5. 7 Modelo de reconocimiento facial 3D con BU-3DFE

Componentes del modelo de reconocimiento facial por etapas

- **Etapa de entrenamiento**

La etapa de entrenamiento para el modelo de reconocimiento facial 3D con BU-3DFE tiene varios componentes los cuales incluyen proyecciones en los planos seguido del filtrado de rostros en el cual se da una extracción de características con wavelets de

Gabor, una vez obtenido los vectores características se procede con la clasificación utilizando máquina de vectores soporte o svm a través de los kernels lineal, cúbico y gaussiano, para proceder con la validación el modelo generado a través de la validación cruzada.

- **Etapa de prueba**

Para la etapa de pruebas se inicia con el component del filtrado de rostros y extracción de características por wavelets de Gabor, seguido de una clasificación de estos vectores características para finalmente dar una identificación de reconocimiento de lo cual se determinará si la clase identificada es correcta o nó

En cuanto al segundo caso de reconocimiento 3D, se trabaja con la base de datos BU-3DFE, utilizando una interfaz semejante, pero con un algoritmo para leer modelos de rostros en 3D con formato vmrl (*.wrl), estos modelos son proyectados a los planos x - z , y - z y z - y respectivos, una parte de este proceso se indica en la figura 5.8 y parte de su código en el Anexo 15.




Figura 5.8 Proyección de un modelo de cara 3D en los planos

Una vez proyectado en los planos, estos son procesados como una imagen en 2D, por tanto, el proceso a continuación es similar al experimento anterior con TEXAS3DFRD, es decir las áreas resultantes de la proyección son filtrados, extraído

sus características y finalmente clasificados para la etapa de identificación (reconocimiento).

5.3 Validación del modelo obtenido

5.3.1 Validación del modelo con base de datos TEXAS3DFRD

En cuanto a la validación cruzada del modelo, y con la finalidad de verificar el grado de confianza que tiene este modelo, se procede por validación cruzada como ya se lo mencionó con anterioridad, por lo que, para una mejor visualización, parte de los resultados obtenidos con las dos bases de datos y sus respectivos kernels se indican en las figuras que van desde la 5.9 hasta la 5.11. Es así que al finalizar la validación, se pudieron obtener los resultados que son expuestos en la tabla 5.1 del presente documento.




Figura 5. 9 Validación modelo, bdd TEXAS3DFRD, kernel lineal

En la figura 5.9 se observa una eficiencia de validación del 89,5%, este valor corresponde al promedio de los valores que acreditados como “ok”, es decir que las clases se corresponden y multiplicado por 100 para ser expresado como un porcentaje de eficiencia.




Figura 5. 10 Validación modelo, bdd TEXAS3DFRD kernel cúbico

De igual manera, en la figura 5.10 se observa una eficiencia de validación del 99,5%, es decir logro acertar en reconocimiento 904 imágenes de 908. Este valor de eficiencia se obtiene al promediar los valores acreditados como “ok”, es decir que las clases se corresponden y luego multiplicado por 100 para ser expresado como un porcentaje de eficiencia.

Validación

3) Validar Modelo

	Prediccion	True	Acerto?	probabilidad
1	p1	p1	ok	0.9817 ^
2	p1	p1	ok	0.9923
3	p1	p1	ok	0.1658
4	p1	p1	ok	0.8489
5	p1	p1	ok	0.9904
6	p1	p1	ok	0.9075
7	p1	p1	ok	0.8490
8	p1	p1	ok	0.6701
9	p1	p1	ok	0.7309
10	p1	p1	ok	0.7492
11	p1	p1	ok	0.9570
12	p1	p1	ok	0.9668
13	p18	p1	no	0.7555
14	p1	p1	ok	0.9906 v
	<			>

Aciertos: 794 / 908 Eficacia:
0.874449

Figura 5. 11 Validación modelo, bdd TEXAS3DFRD kernel Gaussiano

Finalmente, en la figura 5.11 se observa una eficiencia de validación del 87,4%, es decir logro acertar en reconocimiento 794 imágenes de 908. Este valor de eficiencia se obtiene al promediar los valores acreditados como “ok”, es decir que las clases se corresponden y luego multiplicado por 100 para ser expresado como un porcentaje de eficiencia.

5.3.2 Validación del modelo con base de datos BU-3DFE

En cuanto a la validación del modelo, está realizado por validación cruzada, parte de los resultados obtenidos con las dos bases de datos y sus respectivos kernels se indican en las figuras: 5.12, 5.13 y 5.14




Figura 5. 12 Validación modelo, bdd BU-3DFE kernel lineal

En la figura 5.12 se observa una eficiencia de validación del 87,3%, es decir logró un acierto de 917 imágenes de 1050. Este valor de eficiencia se obtiene al promediar los valores acreditados como “ok”, es decir que las clases se corresponden y luego multiplicado por 100 para ser expresado como un porcentaje de eficiencia.




Figura 5. 13 Validación modelo, bdd BU-3DFE kernel cúbico

En la figura 5.13 se observa una eficiencia de validación del 98,0 %, es decir logró un acierto de 1029 imágenes de 1050. Este valor de eficiencia se obtiene al promediar los valores acreditados como “ok”, es decir que las clases se corresponden y luego multiplicado por 100 para ser expresado como un porcentaje de eficiencia.




Figura 5. 14 Validación modelo, bdd BU-3DFE kernel Gaussiano

En la figura 5.14 se observa una eficiencia de validación del 94,3 %, es decir logró un acierto de 990 imágenes de 1050. Este valor de eficiencia se obtiene al promediar los valores acreditados como “ok”, es decir que las clases se corresponden y luego multiplicado por 100 para ser expresado como un porcentaje de eficiencia.

Los resultados obtenidos sobre la validación del modelo se resumen en la tabla 5.1

Tabla 5. 1 Resumen de validación cruzada aplicada al modelo generado por la clasificación realizada por el SVM y sus Kernels

BASES DE DATOS	KERNEL LINEAL (%)	KERNEL CUBICO (%)	KERNEL GAUSSIANO (%)
TEXAS3DFRD	89,5	99,6	87,4
BU-3DFE	87,3	98,0	94,3

De los datos presentados en la tabla 5.1, se concluye que bajo la base de datos BU-3DFE, se obtienen en general mejores resultados, sin embargo el valor máximo obtenido de la validación cruzada en el entrenamiento con el kernel cúbico se llega a un 99,6% trabajando con la base de datos TEXAS3DFRD. Finalmente algo muy importante, observar que el kernel cúbico resulta muy eficaz en los ambos casos, por los resultados altos obtenidos.

5.4 Descripción de los experimentos y sus resultados

5.4.1 Descripción de los experimentos y sus resultados con BDD TEXAS3DFRD

Se procede a realizar los experimentos a través de la interfaz que se indica en el Anexo 10, la misma que contempla dos fases de entrenamiento y pruebas, para lo cual se utilizan la base de datos TEXAS3DFRD, con 908 imágenes de rostros para la fase de entrenamiento y 183 para la fase de pruebas, las mismas que corresponden a diferentes edades, color de piel y género, como se resume en figura 5.13



Figura 5.15 Bdd TEXAS3DFRD
Fuente: Extraído de (Gupta et al., 2010b)

En la tabla 5.2 se muestra el resultado obtenido en cuanto a la fase de prueba para cada kernel utilizado por el algoritmo SVM. De acuerdo a las pruebas realizadas con la aplicación diseñada, y analizando los resultados obtenidos, se observa que con el kernel cúbico, se obtiene un mayor acierto de reconocimiento.

Tabla 5.2 Resumen de resultados con Bdd TEXAS3DFRD

RECONOCIMIENTO SEGUN KERNEL APLICADO_BDD_TEXAS

KERNELS	50 imágenes # aciertos	100 imágenes # aciertos	150 imágenes # aciertos	183 imágenes # aciertos
Kernel_Lineal	42	85	132	162
Kernel_Cúbico	50	97	147	180
Kernel_Gaussiano	40	82	124	150

La tabla 5.2 presenta los resultados obtenidos acerca de la identificación de la clase a la que pertenece la persona, en esta prueba se realizó un total de 183 pruebas por cada kernel con un total de 549 pruebas con rostros del dataset TEXAS3DFRD, obteniendo un mayor número de aciertos con el kernel Cúbico con 180 aciertos y un mínimo de 150 aciertos con el kernel gaussiano de un total de 183. Cabe anotar que las pruebas se realizaron en una forma aleatoria con respecto al número de la clase, para ello se utilizó la función aleatoria de Microsoft Excel (ver anexos 11, 12 y 13). Finalmente,

los resultados presentados están divididos en 4 rangos o intervalos, tales como: (1-50, 51-100, 101-150, 151-183) imágenes con el fin de ir visualizando como va variando el número de aciertos.

Estos resultados obtenidos se indican en modo porcentual en la tabla 5.3, al mismo tiempo que se lo puede visualizar gráficamente en la figura 5.16 para su respectivo análisis.

Tabla 5.3 Porcentaje de reconocimiento de clases con Bdd TEXAS3DFRD

% DE RECONOCIMIENTO SEGUN KERNEL APLICADO_BDD_TEXAS

KERNELS	50 imágenes	100 imágenes	150 imágenes	183 imágenes
Kernel_Lineal (%)	84,0	85,0	88,0	88,5
Kernel_Cúbico (%)	100,0	97,0	98,0	98,4
Kernel_Gaussiano (%)	80,0	82,0	82,7	82,0

La tabla 5.3 muestra los resultados anteriores de reconocimiento en una forma porcentual, la misma que figura el kernel Cúbico con un 98,4% de acierto que corresponde al mayor acierto obtenido en las pruebas y un mínimo del 82% con el kernel gaussiano.




Figura 5.16 Porcentaje de reconocimiento de clases con Bdd TEXAS3DFRD

La figura 5.16 permite visualizar la tendencia de la trayectoria de las curvas, sea variable o constante en función del porcentaje de acierto. De acuerdo a los resultados obtenidos, al principio el kernel cúbico en las primeras pruebas tiende a la baja, pero a partir de las 100 primeras imágenes toma una trayectoria constante por sobre los 98% aproximadamente. Mientras que el kernel lineal sigue una trayectoria de subida durante el intervalo 101-150 imágenes, a partir de este último toma una trayectoria casi constante por encima de los 88% aproximadamente.

5.4.2 Descripción de los experimentos y sus resultados con BDD BU-3DFE

En cuanto a la descripción del experimento se la realizó a través de la interfaz que se indica en el Anexo 14, respecto al trabajo con la segunda base de datos, se cuenta con 50 personas, cada persona cuenta con 7 modelos 3D con sus diferentes expresiones, niveles de intensidad y género, para su entrenamiento, como se ilustra un ejemplo en la figura 5.17, dando un total de 350 modelos.




Figura 5.17 Bases de datos BU-3DFE
Fuente: Extraído de (Oyedotun, Demisse, El, & Shabayek, 2017), (Yin, et al, 2010)

Respecto a la etapa de pruebas, sus resultados fueron registrados en una tabla de Excel (ver anexos 17, 18 y 19), mientras que un resumen se indica en la tabla 5.4, la base de datos fue probada con 150 modelos por cada kernel, teniendo un acierto de 130 y 20 deshaciertos con el kernel lineal, además un total de 146 aciertos, 4 deshaciertos con el kernel Cúbico y finalmente un total de 135 aciertos, 15 deshaciertos con el kernel Gaussiano, concluyendo con esto que el kernel cúbico resulta el mejor.

Tabla 5.4 Resultados según la base de datos BU-3DFE

RECONOCIMIENTO SEGUN KERNEL APLICADO_BDD_BU-3DFE

KERNELS	25	50	75	100	125	150
	imágenes	imágenes	imágenes	imágenes	imágenes	imágenes
	#	#	#	#	#	#
	aciertos	aciertos	aciertos	aciertos	aciertos	aciertos
Kernel_Lineal	15	38	63	84	105	130
Kernel_Cúbico	21	46	71	96	121	146
Kernel_Gaussiano	17	39	64	86	110	135

La tabla 5.4 muestra los rangos con los que se clasificaron previo al reconocimiento en la base de datos utilizada, en donde se puede observar que el número de imágenes de 1-25 se tienen 15 aciertos lineales, 21 aciertos cúbicos y 17 aciertos gaussianos. En el rango 26-50 se identifican 38 aciertos lineales, 46 aciertos cúbicos y 39 aciertos gaussianos. En el rango 51-75 se observan 63 aciertos lineales, 71 aciertos cúbicos y

64 aciertos gaussianos, igual forma en el rango 76-100 se identifican 84 aciertos lineales, 96 aciertos cúbicos y 86 aciertos gaussianos, mientras en el rango 101-125 se identifican 105 aciertos lineales, 121 aciertos cúbicos y 110 aciertos gaussianos y finalmente en el rango 126-150 se identifican 130 aciertos lineales, 146 aciertos cúbicos y 135 aciertos gaussianos, el cual se observa que el kernel cúbico aparece con un alto porcentaje de pruebas correctas.

Tabla 5.5 Porcentaje de reconocimiento aplicando BDD BU-3DFE

% DE RECONOCIMIENTO SEGUN KERNEL APLICADO_BDD_BU-3DFE

KERNELS	1-25 imágenes	26-50 imágenes	51-75 imágenes	76-100 imágenes	101-125 imágenes	126-150 imágenes
Kernel_Lineal (%)	60,0	76,0	84,0	84,0	84,0	86,7
Kernel_Cúbico (%)	84,0	92,0	94,7	96,0	96,8	97,3
Kernel_Gaussiano (%)	68,0	78,0	85,3	86,0	88,0	90,0

La tabla 5.5 muestra los resultados de reconocimiento en una forma porcentual, la misma que figura el kernel Cúbico con un 97,3% de acierto que corresponde al mayor acierto obtenido en las pruebas, un 90% con el kernel Gaussiano y un mínimo del 86,7% con el kernel lineal.




Figura 5.18 Porcentaje de reconocimiento de clases con bdd BU-3DFE

La figura 5.18 permite visualizar la tendencia de la trayectoria de las curvas, sea variable o constante en función del porcentaje de acierto. De acuerdo a los resultados al inicio el kernel cúbico en las primeras pruebas tiende a la subida, pero a partir de las 101 primeras imágenes toma una trayectoria constante por sobre los 97% aproximadamente. Mientras que el kernel lineal sigue una trayectoria de subida durante el intervalo 101-150 imágenes, a partir de este último toma una trayectoria casi constante por sobre los 85% aproximadamente, finalmente el kernel gaussiano tiene una trayectoria siempre de subida, sobre los 83% aproximadamente.

5.5 Discusión de los resultados

Con los modelos planteados en la figura 5.6 y 5.7 se realizan los experimentos para la fase de entrenamiento y pruebas con las bases de datos TEXAS3DFRD y BU-3DFE antes anotados. En las tablas 5.2 y 5.3 se muestran los resultados obtenidos con cada base de datos por cada uno de los kernels: lineal, cúbico y gaussiano propios del clasificador SVM.

De acuerdo a los resultados obtenidos en el primer experimento de reconocimiento facial 3D con la base de datos TEXAS3DFRD, se obtiene un mayor acierto del 98,4% con el kernel cúbico y el mínimo con el kernel lineal con un 88,5% de acierto, la prueba se realizó con 183 imágenes correspondientes a 50 personas, con total de 549 pruebas con los 3 kernels, como se indica en la tabla 5.2

Los resultados obtenidos del experimento realizado se comparan con otros trabajos relacionados con reconocimiento facial 3D que utilizan la misma base de datos TEXAS3DFRD. Un resumen de la comparación realizada se indica en la tabla 5.6

Tabla 5. 6 Comparación de resultados con otros trabajos

Métodos	Base de datos	Porcentaje de reconocimiento
Anthroface3D (Song, Luo, Zi, & Tian, 2016)	TEXAS3DFRD	96,8
Curveletface3D (Song et al., 2016)	TEXAS3DFRD	97,1
ACFFR (Song et al., 2016)	TEXAS3DFRD	97,0
Trabajo de Investigación propuesto	TEXAS3DFRD	98,4

De la comparación de los resultados, se observa que el modelo propuesto demostró un resultado superior (98,4%) comparado con los trabajos relacionados con el tema, cabe indicar que todos utilizan la misma base de datos.

De igual manera, respecto del segundo experimento con la base de datos BU-3DFE, se obtiene un mayor acierto del 97,3% con el kernel cúbico y el mínimo con el kernel lineal con un 86,7% de acierto, la prueba se realizó con 150 imágenes correspondientes a 50 personas, con total de 450 pruebas con los 3 kernels, como se ilustra en la tabla 5.3

Los resultados del experimento realizado se compararon con otros trabajos relacionados con reconocimiento facial 3D. Un resumen de la comparación realizada se indica en la tabla 5.7

Tabla 5. 7 Comparación de resultados con otros trabajos

Métodos	Base de datos	Porcentaje de reconocimiento
Li <i>et al.</i> (X. Li, Ruan, An, et al., 2015)	BU-3DFE	94.56%
Cai <i>et al.</i> (Cai, Lei, Yang, You, & Shan, 2019)	BU-3DFE	99.88%
Derkach, Sukno (Derkach & Sukno, 2018)	BU-3DFE	81.5%
Hariri <i>et al.</i> (Hariri, Tabia, Farah, Benouareth, & Declercq, 2017)	BU-3DFE	92.62%
Hariri <i>et al.</i> (Hariri et al., 2017)	BOSPHORUS	86.17%
Li <i>et al.</i> (X. Li, Ruan, Jin, et al., 2015)	BU-3DFE	93.9%
Savran, Sankur (Savran, 2017)	BOSPHORUS	96.8%
Savran, Sankur (Savran, 2017)	BU-3DFE	96.1%
Shi <i>et al.</i> (R, Shi, Zang, Zheng, & Zhan, 2019)	CASIA-3D	94.0%
Trabajo de Investigación propuesto	BU-3DFE	97.3%

De la comparación de los resultados, se observa que el modelo propuesto demostró resultados superiores comparando con los trabajos relacionados con el tema. Sin embargo, apenas fue superado por un trabajo propuesto por Cai (Cai et al., 2019) que se basa en la misma base de datos. Según la obtención de resultados de los estudios relacionados anteriores, los investigadores concluyen que los datos obtenidos de las BDD de imágenes faciales 3D fueron de gran importancia para los experimentos de reconocimiento facial en 3D.

5.6 Comprobación de hipótesis

Planteada la hipótesis, a través del análisis de los resultados obtenidos se puede confirmar que se obtuvo una eficiencia por encima del 97%, por lo tanto la utilización de algoritmos de reconocimiento facial global planteados en este modelo resulta ser eficaz y quedaría comprobado la hipótesis.

5.7 Conclusiones

El proceso de reconocimiento facial en 3D, resulta más eficiente y práctico en estos tiempos de gran avance tecnológico, pues al momento ya se cuentan con cámaras digitales 3D de gran resolución que facilitan el proceso de identificación de una persona.

A pesar de que existe la presencia de limitadas bases de datos de rostros en 3D libre de costos para la investigación, sin embargo, se presume que muy pronto se abrirán las puertas por parte de muchos laboratorios proporcionando estas bases para futuras investigaciones. De acuerdo a los resultados obtenidos, se encuentran resultados muy buenos, es así que se llega a obtener una eficiencia de reconocimiento del 98,4%, con imágenes reprocesadas de la base de datos TEXAS3DFRD, mientras que con los modelos de imágenes 3D de la base de datos BU-3DFE se obtiene un 97,3% de aciertos.

Dentro de este capítulo tratado sobre imágenes 3D, es necesario destacar que los rostros 3D ya no dependen de la iluminación y en especial las imágenes de la base de datos TEXAS3DFRD pasaron en el laboratorio por un proceso de mejora como la eliminación del ruido, eliminación de algunas regiones sin importancia, y el rellenado de algunas regiones profundas. Estas operaciones sin lugar a dudas fueron importantes que influyeron para los resultados obtenidos.

CAPITULO VI: CONCLUSIONES Y TRABAJOS FUTUROS

6.1 Conclusiones

- En la presente investigación se establecieron importantes etapas de la investigación a realizar, partiendo de una profunda revisión literaria a través de importantes motores de búsqueda de bases de datos como Science direct, Scopus, Dialnet, IEEE, Web of Science, etc.
- Con la revisión literaria se establecieron las bases de datos, algoritmos de extracción de características y clasificadores más adecuados para conseguir una técnica eficiente en el proceso de identificación de la clase a la que corresponde, en nuestro caso se trabajó con los waveles de Gabor y el clasificador SVM con sus kernels lineal, cúbico y gaussiano, a la vez también fue necesario contar con algunas bases de datos de rostros, muy necesario para realizar los entrenamientos y pruebas, en el caso de rostros en 2D se encontró en línea tales como: FERET y MUCT, mientras que resultó complejo adquirir bases de datos de rostros en 3D, sin embargo se encontró a TEXAS3DFRD y con bastante dificultad a BU-3DFE, que dio lugar a la posibilidad de una variada selección, aspecto que se convierte en una ligera ventaja dentro del area de reconocimiento facial en 3D, estas bases de datos contienen variadas imágenes en función de raza, edad, estado emocional y pose sea para 2D y 3D.
- Se definieron modelos de reconocimiento facial para imágenes en 2D y 3D, para ambos casos se utilizó wavelets de Gabor para filtrado y extracción de características, así como la Máquina de vectores de soporte (SVM) para la clasificación con sus kernels: lineal, cúbico y gaussiano.
- Se realizaron las respectivas validaciones del modelo obtenido a través de algoritmos de extracción de características de Gabor y clasificador de patrones SVM con cada uno de los kernels: lineal, cúbico y gaussiano en 2D y 3D respectivamente, con las bases de datos seleccionados.

- Los resultados obtenidos con las dos bases de datos FERET y MUCT son aceptables, dando la mejor eficiencia del 96% con el kernel Gaussiano y base de datos FERET. Es así que se puede indicar que la metodología empleada es acertada con la presencia de Gabor y Máquina de vectores soporte.
- Los resultados obtenidos con las dos bases de datos TEXAS3DFRD y BU-3DFE son muy aceptables, dando una mejor eficiencia del 97,3% con BU-3DFE y 98,4% con TEXAS3DFRD. Esto indica que el proceso empleado es muy acertado con la presencia de Gabor y Máquina de vectores soporte, sin dejar un lado el proceso de proyectar un modelo de imagen 3D hacia los planos. Es necesario destacar que los rostros 3D ya no dependen de la iluminación y por otro lado estas imágenes pasan por un proceso de mejora como: la eliminación del ruido, eliminación de algunas regiones sin importancia, y el rellenado de algunas regiones profundas. Estas operaciones sin lugar a dudas fueron importantes que influyeron para los resultados obtenidos.
- Finalmente, se concluye que el reconocimiento facial sigue siendo un problema complicado, a pesar de la presencia de muchos trabajos de investigación actuales, hay muchas condiciones reales, difíciles de modelar y prever, los mismos que limitan el rendimiento de los sistemas de la actualidad en términos de tiempo y confianza.

6.2 Trabajos futuros

- Tomando una secuencia a la línea del trabajo de investigación se podrían hacer la implementación en nuevas técnicas en la extracción de características, como se ha venido comentando a lo largo del proyecto, la correcta detección de los puntos de interés limitada por la presencia de rasgos propios de la edad en todas las personas, malas condiciones de iluminación, oclusiones, sombras, opacidad en las imágenes, entre otros, una futura línea de trabajo a seguir puede ser la introducción de algunos métodos basados en mallas, las mismas que permitan crear una serie de puntos de referencia, todo esto mediante un sistema operativo Android o iOS;
- Así también como otra línea de investigación podría ser el uso de otros métodos de clasificación y a la vez compararlos mediante algunas técnicas de inteligencia artificial como árboles de decisión.

BIBLIOGRAFIA

- 3D morphable models UR. (2011). Retrieved from
<http://faces.cs.unibas.ch/bfm/main.php>
- A. Moreno, A. S. (2004). Gavabdb: a 3D face database, 75–80.
- A. Savran, N. Alyuz, H. Dibeklioglu, O. Celiktutan, B. Gokberk, B. Sankur, L. A. (2008). Bosphorus database for 3D face analysis, 47–56.
- Acosta, A. N., Pablo, J., & Gonz, N. (2014). Detección y Diagnóstico de Fallas para la Dinámica Lateral de un Automóvil utilizando Máquinas de Soporte Vectorial Multiclase, 73, 167–179.
- Alejandra, M.-O. D. (2016). Re-identificación de personas a través de sus características soft-biométricas en un entorno multi-cámara de video-vigilancia. *Ingeniería, Investigación y Tecnología*, 17(2), 257–271.
<https://doi.org/10.1016/j.riit.2016.06.010>
- Alvarez, D., & Giraldo, E. (2008). Ica aplicado a la extracción de características en imágenes, (40), 43–48.
- B. Pradhan. (2013). A comparative study on the predictive ability of the decision tree, support vector machine and neuro-fuzzy models in landslide susceptibility mapping using GIS, 350–365.
- Bah, S. M., & Ming, F. (2020). An improved face recognition algorithm and its application in attendance management system. *Array*, 5(February 2019), 100014. <https://doi.org/10.1016/j.array.2019.100014>
- Ballantyne, M., Boyer, R. S., & Hines, L. (1996). Woody Bledsoe—His Life and Legacy, 17(1), 7–20.
- Barina, D. (2016). Gabor wavelets in image processing, (2).
- Bartlett, M.-S. (1999). Face image analysis by unsupervised learning and redundancy reduction. *Dissertation-Abstracts-International:-Section-b:-The-Sciences-and-Engineering*.
- Bdd, T. (2010). Texas 3D Face Recognition DatabaseURL. Retrieved from

<http://live.ece.utexas.edu/research/%0Atexas3dfr>

- Bdd, Y. (2011). York 3D database URL. Retrieved from <http://www-users.cs.york.ac.uk/nep/research/3Dface/tomh/%0A3DFaceRecognition.html>
- Belén, A., Díaz, M., & Físicas, C. C. (2004). Reconocimiento Facial Automático mediante Técnicas de Visión Tridimensional Tesis Doctoral Reconocimiento Facial Automático mediante Técnicas de Visión Tridimensional Tesis Doctoral.
- Benini, S., Khan, K., Leonardi, R., Mauro, M., & Migliorati, P. (2019). Face analysis through semantic face segmentation. *Signal Processing: Image Communication*, 74(November 2018), 21–31. <https://doi.org/10.1016/j.image.2019.01.005>
- Benitez-Garcia, G., Olivares-Mercado, J., Aguilar-Torres, G., Sanchez-Perez, G., & Perez-Meana, H. (2012). Face Identification Based on Contrast Limited Adaptive Histogram Equalization (CLAHE), (May 2015).
- Betancour, G. (2005). LAS MÁQUINAS DE SOPORTE VECTORIAL (SVMs). *Scientia Et Technica*, (27), 67–72.
- Blanco Oliver, A., Pino Mejías, R., & Lara Rubio, J. (2014). Modeling the Financial Distress of Microenterprise Start-ups Using Support Vector Machines: a case study. *Innovar: Revista de Ciencias Administrativas y Sociales*, 24(54), 153–168. Retrieved from <https://dialnet.unirioja.es/servlet/articulo?codigo=4932773&orden=1&info=link%5Cnhttps://dialnet.unirioja.es/servlet/extart?codigo=4932773>
- Cabello Pardos, E. (2003). Técnicas de reconocimiento facial mediante redes neuronales, 135. Retrieved from <http://dialnet.unirioja.es/servlet/tesis?codigo=2586&info=resumen&idioma=SPA>
- Cadena, J., & Flores, G. (2018). Reconocimiento facial en sub-espacios: lineales y no-lineales, bases de datos de rostros y máquina de vectores de soporte, 12, 443–457.
- Cadena, J., Montaluisa, R., Flores, G., Chancúsig, J., & Guaypatín, O. (2017). Reconocimiento facial con base en imágenes.
- Cai, Y., Lei, Y., Yang, M., You, Z., & Shan, S. (2019). A fast and robust 3D face recognition approach based on deeply learned face representation, 363, 375–

397. <https://doi.org/10.1016/j.neucom.2019.07.047>

- Carmona, E. (2016). Tutorial sobre Máquinas de Vectores Soporte, 1–27.
- Casia. (2010). Bases de datos CASIA., <http://biometrics.idealtest.org>. Retrieved from <http://biometrics.idealtest.org>
- Casia. (2011). Casia 3D face databaseURL. Retrieved from <http://www.cbsr.ia.ac.cn/english/3DFaceDatabases>
- Castleman, K. R., Markey, M. K., & Bovik, A. C. (2010). Texas 3D Face Recognition Database, 2–5.
- Castrillon, W. A., Alvarez, D. A., & López, A. F. (2008). Técnicas de extracción de características en imágenes para el reconocimiento de expresiones faciales. *Scientia et Technica*, (38), 7–12. <https://doi.org/10.22517/23447214.3681>
- Chan, C. H., & Tahir, M. A. (2013). Multiscale Local Phase Quantization for Robust Component-Based Face Recognition Using Kernel Fusion of Multiple Descriptors, 35(5), 1164–1177.
- Chang, C., & Lin, C. (2013). LIBSVM : A Library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2, 1–39. <https://doi.org/10.1145/1961189.1961199>
- Chao, W. (2017). Gabor wavelet transform and its application.
- Correa, A. C., Salazar, A. E. S., & Ortiz, F. A. P. (2013). Reconocimiento de rostros y gestos faciales mediante un analisis de relevancia con imagenes 3D. *Revista De Investigación, Desarrollo E Innovación*, 4(1), 7–20. <https://doi.org/10.19053/20278306.2563>
- Corso, I., & Lorena, C. (2009). Aplicación de algoritmos de clasificación supervisada usando.
- Cutipa, R. A., Cesar, J., Huanca, L., Posgrado, E. De, & Universitaria, C. (2017). Técnicas de procesamiento digital de imágenes aplicados al reconocimiento automático de rostros digital processing techniques of images applied to automatic face recognition, (051), 287–296.
- D. Cosker, E. Krumhuber, A. H. (2011). A FACS valid 3D dynamic action unit database with applications to 3D dynamic morphable facial modeling.

- Deng, C. (2008). Four face databases in matlab format. Retrieved from <http://www.cad.zju.edu.cn/home/dengcai/Data/FaceData.html>
- Derkach, D., & Sukno, F. M. (2018). Automatic Local Shape Spectrum Analysis for 3D Facial Expression Recognition. *Image and Vision Computing*, #pagerange#. <https://doi.org/10.1016/j.imavis.2018.09.007>
- Devi, H. S., Laishram, R., & Thounaojam, D. M. (2015). Face Recognition using R-KDA with Non-Linear SVM for Multi-View Database. *Procedia Computer Science*, 54, 532–541. <https://doi.org/10.1016/j.procs.2015.06.061>
- Dou, P., & Kakadiaris, I. A. (2017). End-to-end 3D face reconstruction with deep neural networks, (May).
- Escobar, J. (2019). *Herramienta de Reconocimiento facial con técnica de vision computacional 2D*.
- F. Tsalakanidou, S. M. (2010). Real-time 2D+3D facial action and expression recognition, 1763–1775.
- Fadaifard, H., Wolberg, G., & Haralick, R. (2013). Multiscale 3D feature extraction and matching with an application to 3D face recognition. *Graphical Models*, 75(4), 157–176. <https://doi.org/10.1016/j.gmod.2013.01.002>
- G. Pajares. (2008). Ejercicios resueltos de Visión por Computador.
- G. Stratou, A. Ghosh, P. Debevec, L.-P. M. (2011). Effect of illumination on automatic expression recognition: a novel 3D relightable facial database, 1–6.
- Gao, W., Cao, B., Shan, S., Chen, X., Zhou, D., Zhan, X. (2008). The CAS-PEAL large-scale Chinese face database and baseline evaluations, 149–161.
- Gao, Y., Ma, J., Zhao, M., & Y. (2017). Semi-Supervised Sparse Representation Based Classification for Face Recognition with Insufficient Labeled Samples, 1–16.
- Garcia, A. (2014). *El arte de elaborar el estado del arte en una investigación*. Retrieved from https://repositoriotec.tec.ac.cr/bitstream/handle/2238/9145/El_estado_del_arte_2017.pdf?sequence=1
- Garrido, C. B., & Alcaide, T. R. (2018). *AUTOMÁTICO APLICADO AL RECONOCIMIENTO DE VEHÍCULOS. IMPLEMENTACIÓN EN FPSoC*.

- Gavab. (n.d.). Base de datos GAVAB. Retrieved from <http://gavab.escet.urjc.es>
- Graham, D. B., & Mallinson, N. (1998). for General Purpose Face Recognition.
- Gumus, E., Kilic, N., Sertbas, A., & Ucan, O. N. (2010). Evaluation of face recognition techniques using PCA, wavelets and SVM. *Expert Systems with Applications*, 37(9), 6404–6408. <https://doi.org/10.1016/j.eswa.2010.02.079>
- Guo, G., Li, S. Z., & Chan, K. L. (2001). Support vector machines for face recognition. *Image and Vision Computing*, 19, 631–638. [https://doi.org/10.1016/S0262-8856\(01\)00046-4](https://doi.org/10.1016/S0262-8856(01)00046-4)
- Gupta, S., Castleman, K. R., Markey, M. K., & Bovik, A. C. (2010a). Texas 3D Face Recognition Database. *Proceedings of the IEEE Southwest Symposium on Image Analysis and Interpretation*, (June), 97–100. <https://doi.org/10.1109/SSIAI.2010.5483908>
- Gupta, S., Castleman, K. R., Markey, M. K., & Bovik, A. C. (2010b). Texas 3D Face Recognition Database. *Proceedings of the IEEE Southwest Symposium on Image Analysis and Interpretation*, (March 2018), 97–100. <https://doi.org/10.1109/SSIAI.2010.5483908>
- Hariri, W., Tabia, H., Farah, N., Benouareth, A., & Declercq, D. (2017). 3D facial expression recognition using kernel methods on Riemannian manifold. *Engineering Applications of Artificial Intelligence*, 64(May), 25–32. <https://doi.org/10.1016/j.engappai.2017.05.009>
- Hernández, R. (2010). *Metodología de la Investigación* (Quinta). México.
- Kakadiaris, I. A., Toderici, G., Evangelopoulos, G., Passalis, G., Chu, D., Zhao, X., ... Theoharis, T. (2017). 3D-2D face recognition with pose and illumination normalization. *Computer Vision and Image Understanding*, 154, 137–151. <https://doi.org/10.1016/j.cviu.2016.04.012>
- Kamencay, P., Hudec, R., Benco, M., Sykora, P., & Radil, R. (2015). An efficient P-KCCA algorithm for 2D-3D face recognition using SVM. *Advances in Electrical and Electronic Engineering*, 13(4), 399–406. <https://doi.org/10.15598/aece.v13i4.1473>
- Karthika, R., & Parameswaran, L. (2016). Study of Gabor Wavelet for Face Recognition Invariant to Pose and Orientation. <https://doi.org/10.1007/978-81->

322-2671-0

- Kasar, M. M., Bhattacharyya, D., & Kim, T. (2016). Face Recognition Using Neural Network : A Review, *10*(3), 81–100.
- Kerbaa, T. H., Mezache, A., & Oudira, H. (2019). Model Selection of Sea Clutter Using Cross Validation Method a , b Method. *Procedia Computer Science*, *158*, 394–400. <https://doi.org/10.1016/j.procs.2019.09.067>
- Khalil, T. (2014). A Survey of Feature Selection and Feature Extraction Techniques in Machine Learning, 372–378.
- Khan, N. M., Ksantini, R., Ahmad, I. S., & Boufama, B. (2012). A novel SVM+NDA model for classification with an application to face recognition. *Pattern Recognition*, *45*(1), 66–79. <https://doi.org/10.1016/j.patcog.2011.05.004>
- Kim, S.-K., Park, Y. J., Toh, K.-A., & Lee, S. (2010). SVM-based feature extraction for face recognition. *Pattern Recognition*, *43*(8), 2871–2881. <https://doi.org/10.1016/j.patcog.2010.03.008>
- Kong, R., & Zhang, B. (2011). A New Face Recognition Method Based on Fast Least Squares Support Vector Machine. *Physics Procedia*, *22*, 616–621. <https://doi.org/10.1016/j.phpro.2011.11.095>
- L. Benedikt, D. Cosker, P. Rosin, D. M. (2010). Assessing the uniqueness and permanence of facial actions for use in biometric applications, 449–460.
- L. Yin, X. Chen, Y. Sun, T. Worm, M. R. (2008). A high-resolution 3D dynamic facial expression database, 1–6.
- L. Yin, X. Wei, Y. Sun, J. Wang, M. R. (2006). A 3D facial expression database for facial behavior researche, 211–216.
- Laura, L., Waldo, H., César, E., Ronchetti, F., VillaMonte, A., Aquino, G., ... Santana, P. (2015). Redes Neuronales Artificiales plicaciones en Minería de Datos y rocesamiento de Señales Temporales, 5.
- Lei, Y., Bennamoun, M., & El-Sallam, A. A. (2013). An efficient 3D face recognition approach based on the fusion of novel local low-level features. *Pattern Recognition*, *46*(1), 24–37. <https://doi.org/10.1016/j.patcog.2012.06.023>
- Leiva José. (2007). *Extracción de características mediante criterios basados en*

teoría de la información.

- Leon, E. C. (2016). *Introducción a las máquinas de vector soporte (SVM) en aprendizaje supervisado.*
- Li, J., Perrine, K., Wu, L., & Walton, C. M. (2019). Cross-validating traffic speed measurements from probe and stationary sensors through state reconstruction. *International Journal of Transportation Science and Technology*, 8(3), 290–303. <https://doi.org/10.1016/j.ijst.2019.04.002>
- Li, W., Liu, L., & Gong, W. (2011). Multi-objective uniform design as a SVM model selection tool for face recognition. *Expert Systems with Applications*, 38(6), 6689–6695. <https://doi.org/10.1016/j.eswa.2010.11.066>
- Li, X., Ruan, Q., An, G., Jin, Y., & Zhao, R. (2015). Multiple strategies to enhance automatic 3D facial expression recognition. *Neurocomputing*, 161, 89–98. <https://doi.org/10.1016/j.neucom.2015.02.063>
- Li, X., Ruan, Q., Jin, Y., An, G., & Zhao, R. (2015). Fully automatic 3D facial expression recognition using polytypic multi-block local binary patterns. *Signal Processing*, 108, 297–308. <https://doi.org/10.1016/j.sigpro.2014.09.033>
- Lin, W.-H., Wang, P., & Tsai, C.-F. (2016). Face recognition using support vector model classifier for user authentication. *Electronic Commerce Research and Applications*, 18(February), 1–12. <https://doi.org/10.1016/j.elerap.2016.01.005>
- Luo, Y., Wu, C. M., & Zhang, Y. (2013). Facial expression recognition based on fusion feature of PCA and LBP with SVM. *Optik*, 124(17), 2767–2770. <https://doi.org/10.1016/j.ijleo.2012.08.040>
- Manju, D., & Radha, V. (2020). A Novel Approach for Pose Invariant Face Recognition in Surveillance Videos. *Procedia Computer Science*, 167(2019), 890–899. <https://doi.org/10.1016/j.procs.2020.03.428>
- Mano, Y. (2018). Method validation studies and an inter-laboratory cross validation study of lenvatinib assay in human plasma using LC-MS / MS. *Practical Laboratory Medicine*, 12(May), 1–9. <https://doi.org/10.1016/j.plabm.2018.e00103>
- Manso, M. (2017). Predicción y selección de características , mediante análisis local de la fiabilidad , para el mercado de valores y su extensión a problemas de

clasificación y regresión.

Mariñas Guillermo. (2009). *Evaluación de algoritmos supervisados de extracción de características para clasificación de texturas*.

<https://doi.org/10.1016/j.biopha.2017.01.089>

Milborrow, S., Morkel, J., & Nicolls, F. (2010). The MUCT Landmarked Face Database.

Montoya, J. F. (2015). Identificación de patrones sísmicos en registros 2D mediante máquinas de soporte vectorial (SVM), 68–79.

Moreno, A., & Sanchez, a. (2005). Face recognition using 3D local geometrical features: PCA vs. SVM. *Image and Signal ...*, (1), 185–190.

<https://doi.org/10.1109/ispa.2005.195407>

Nacelle, A. (2009). Redes neuronales artificiales, 1–9.

Olivares-Mercado, J., Toscano-Medina, K., Sánchez-Pérez, G., Nakano-Miyatake, M., & Pérez-Meana, H. (2016). Modifications to the Eigenphases Method for Face Recognition Based on SVM. *Ingeniería, Investigación y Tecnología*, 17(1), 119–129. <https://doi.org/10.1016/j.riit.2016.01.011>

ORL. (1994). Database of Faces. Retrieved from

<http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>

Oyedotun, O. K., Demisse, G., El, A., & Shabayek, R. (2017). Facial Expression Recognition via Joint Deep Learning of RGB-Depth Map Latent Representations Facial Expression Recognition via Joint Deep Learning of RGB-Depth Map Latent Representations, (December).

<https://doi.org/10.1109/ICCVW.2017.374>

P.J. Phillips, H. Moon, S. Rizvi, P. R. (2000). The FERET evaluation methodology for face recognition algorithms, 1090–1104.

Palella, S. (2012). *Metodología de la Investigación Cuantitativa*. (FEDUPEL, Ed.). Caracas.

Passalis, G., Kakadiaris, I. A., Theoharis, T., Toderici, G., & Murtuza, N. (2014). Evaluation of the UR3D algorithm using the FRGC v2 data set Evaluation of the UR3D algorithm using the FRGC v2 data set, (June).

- Pérez Flores, C. (2015). Reconocimiento frontal de rostros en base a imágenes de alta resolución, 68.
- Pérez, L. B. (2013). Reconocimiento facial basado en puntos característicos de la cara en entornos no controlados, 110. Retrieved from http://atvs.ii.uam.es/seminars/PFC_Luis_Blazquez.pdf
- R, J. V. C. I., Shi, B., Zang, H., Zheng, R., & Zhan, S. (2019). An efficient 3D face recognition approach using Frenet feature of iso-geodesic curves. *Journal of Visual Communication and Image Representation*, 59, 455–460. <https://doi.org/10.1016/j.jvcir.2019.02.002>
- Robert, B. A. M. (2014). The AR Face Database. *Autonomous University of Barcelona*, (January 1998).
- Romero, A. (2011). Nuevos paradigmas para el análisis estadístico de imágenes tomográficas cerebrales.
- Rosato, M. J. (2016). A 3D facial expression database for facial behavior research A 3D Facial Expression Database For Facial Behavior Research, (May 2006). <https://doi.org/10.1109/FGR.2006.6>
- Ruiz, J. Z. (2018). COMPARATIVA Y ANÁLISIS DE ALGORITMOS.
- Sadhya, D., & Kumar, S. (2019). Neurocomputing A comprehensive survey of unimodal facial databases in 2D and 3D domains. *Neurocomputing*, 358, 188–210. <https://doi.org/10.1016/j.neucom.2019.05.045>
- Samaria, F., & Harter, A. (1994). Parameterisation of a stochastic model for human face identification.
- Sandbach, G., Zafeiriou, S., Pantic, M., & Yin, L. (2012). Static and dynamic 3D facial expression recognition: A comprehensive survey. *Image and Vision Computing*, 30(10), 683–697. <https://doi.org/10.1016/j.imavis.2012.06.005>
- Sandoval, M. M., Rubio, J., & Eds, L. (2019). *Avances en Ciencias en Ingeniería y Tecnologías Computacionales*.
- Savran, A. (2017). Non-rigid Registration Based Model-free 3D Facial Expression Recognition. <https://doi.org/10.1016/j.cviu.2017.07.005>
- Serratos, F. (2013). La biometría para la identificación de las personas.

- Shao, Y. H., Chen, W. J., Wang, Z., Li, C. N., & Deng, N. Y. (2014). Weighted linear loss twin support vector machine for large-scale classification. *Knowledge-Based Systems*, 73(1), 276–288.
<https://doi.org/10.1016/j.knosys.2014.10.011>
- Shen, L., & Bai, Æ. L. (2006). A review on Gabor wavelets for face recognition, 273–292. <https://doi.org/10.1007/s10044-006-0033-y>
- Sim, T., Baker, S., & Bsat, M. (2003). The {CMU} pose, illumination, and expression database. *Pami*, 25(12), 1615–1618.
<https://doi.org/10.1109/AFGR.2002.1004130>
- Song, D., Luo, J., Zi, C., & Tian, H. (2016). 3D Face Recognition Using Anthropometric and Curvelet Features Fusion, 2016.
- Stan, L., & Jain, A. (2011). Handbook of facial recognition, 447–460.
- Sujitha, P., Venkatramaphanikumar, S., & V, K. K. K. (2019). Scale Invariant Face Recognition with Gabor Wavelets and SVM, (5), 100–104.
- Sun, W., Zhao, H., & Jin, Z. (2018). PT • The learned ROIs are partly consistent with the emotion specific Action. *Neurocomputing*.
<https://doi.org/10.1016/j.neucom.2018.03.034>
- T. Faltemier, K. Bowyer, P. F. (2008). Using multi-instance enrollment to improve performance of 3D face recognition, 114–125.
- Torkhani, G., Ladgham, A., Sakly, A., & Mansouri, M. N. (2017). A 3D–2D face recognition method based on extended Gabor wavelet combining curvature and edge detection. *Signal, Image and Video Processing*, 11(5), 969–976.
<https://doi.org/10.1007/s11760-016-1046-7>
- V. Blanz, T. V. (1999). A morphable model for the synthesis of 3D faces, 187–194.
- Valverde, G., Criollo, R., Plua, D., Quinche, P., & Quiroz, M. (2014). Aplicación del paradigma semiótico en una implementación de reconocimiento facial – Estado del.
- Vapnik, V. N. (1998). Statistical Learning Theory. *Adaptive and Learning Systems for Signal Processing, Communications and Control*, 2, 1–740.
<https://doi.org/10.2307/1271368>

- Wen, Y. (2012). An improved discriminative common vectors and support vector machine based face recognition approach. *Expert Systems with Applications*, 39(4), 4628–4632. <https://doi.org/10.1016/j.eswa.2011.09.119>
- Weyrauch, B., Heisele, B., & Blanz, V. (2004). Component-based Face Recognition with 3D Morphable Models 2 . Generation of 3D Face Models, 0–4.
- X. Peng. (2010). An efficient twin support vector machine for regression, 365–372.
- Xu, Y., Fang, X., Li, X., Yang, J., You, J., Liu, H., & Teng, S. (2014). Data Uncertainty in Face Recognition, 1950–1961.
- Y. Chang, M. Vieira, M. Turk, L. V. (2005). Automatic 3D facial expression analysis in videos, 293–307.
- Yang, P. Y., Hui, C. J., Tien, D. J., Snowden, A. W., Derfus, G. E., Opel, C. F., & Carlo, M. (2019). Accurate definition of control strategies using cross validated stepwise regression and Monte Carlo simulation. *Journal of Biotechnology: X*, 2(April), 100006. <https://doi.org/10.1016/j.btecx.2019.100006>
- Z. Qi, Y. Tian, Y. S. (2013). Robust twin support vector machine for pattern classification, 305–316.
- Zhan, Y., & Shen, D. (2005). Design efficient support vector machine for fast classification. *Pattern Recognition*, 38(1), 157–161. <https://doi.org/10.1016/j.patcog.2004.06.001>
- Zhao, M., Fu, C., Ji, L., Tang, K., & Zhou, M. (2011). Feature selection and parameter optimization for support vector machines: A new approach based on genetic algorithm with feature chromosomes. *Expert Systems with Applications*, 38(5), 5197–5204. <https://doi.org/10.1016/j.eswa.2010.10.041>

ANEXOS

ANEXO 1. Resumen de trabajos revisados que involucran a la técnica SVM.

AUTOR	TITULO	FUENTE	AÑO
Acosta, A. N., Pablo, J., & Gonz, N.	Detección y Diagnóstico de Fallas para la Dinamica Lateral de un Automovil utilizando Maquinas de Soporte Vectorial Multiclase	Computing Science	2014
Belén, A., Díaz, M.	Reconocimiento Facial Automático a través de técnicas de Visión Tridimensional. Tesis Doctoral	U. Politécnica Madrid. Tesis doctoral	2004
Bellakhdhar, F., Loukil, K., & ABID, M.	Face recognition approach using Gabor Wavelets, PCA and SVM	IJCSI International Journal of Computer Science Issues	2013
Betancour, G.	LAS MÁQUINAS DE SOPORTE VECTORIAL (SVMs)	Scientia et Technica	2005
Blanco Oliver, A., Pino Mejías, R., & Lara Rubio, J.	Modeling the Financial Distress of Microenterprise Start-ups Using Support Vector Machines: a case study	Innovar Journal	2014
Cabello Pardos, E.	Técnicas de reconocimiento facial mediante redes neuronales	Tesis Doctoral	2004
Cao, J., & Tong, C.	Facial Expression Recognition Based on LBP-EHMM	IEEE	2008
CAO, N. T., TON-THAT, A. H., & CHOI, H. IL.	Facial Expression Recognition Based on Local Binary Pattern Features and Support Vector Machine	International Journal of Pattern Recognition	2014

		and Artificial Intelligence	
Cárdenas, J. P., Olivares, G., & Alfaro, R.	Automatic text classification using words networks	Scielo	2014
Çarıkçı, M. üg., & Özen, F.	A Face Recognition System Based on Eigenfaces Method	Elsevier	2012
Chen, S., & Liu, C.	Eye detection using discriminatory Haar features and a new efficient SVM	Elsevier	2015
Chowdhury, S., Sing, J. K., Basu, D. K., & Nasipuri, M.	Face recognition by generalized two-dimensional FLD method and multi-class support vector machines	Elsevier	2011
Chuang, C.-F., & Shih, F. Y.	Recognizing facial action units using independent component analysis and support vector machine	Elsevier	2006
Concha, M. F.	Hybrid Support Vector Machines to Classify Traffic Accidents in the Región Metropolitana de Santiago	Journal of Technological Possibilism	2012
Déniz, O., Castrillón, M., & Hernández, M.	Face recognition using independent component analysis and support vector machines	Elsevier	2003
Devi, H. S., Laishram, R., & Thounaojam, D. M.	Face Recognition using R-KDA with Non – Linear, Machines vectors support for Multi-View Database	Elsevier	2015

Dindarloo, S. R.	Peak particle velocity prediction using support vector machines : a surface blasting case study	The Journal of The Southern African Institute of Mining and Metallurgy	2015
Emre, G., Haklı, H., & Harun, U.	Support vector machines classification based on particle swarm optimization for bone age determination	Elsevier	2014
Espinosa, V	Evaluación de sistemas de reconocimiento biométrico	U. Politécnica Madrid	2000
Fortuna, J., & Capson, D.	Improved support vector classification using PCA and ICA feature space modification	Elsevier	2004
Garc, M. V.	Reconocimiento de rostros combinando técnicas 2D y 3D	Universidad Católica de Cataluña. Tesis	2007
García, G.	Procesamiento de Caras Humanas Mediante Integrales Proyectivas	Universidad de Murcia. Tesis doctoral	2007
Giral, D.	Implementación de algoritmos basados en máquinas de soporte vectorial (SVM) para sistemas eléctricos: revisión de tema	U. Distrital Francisco José de Caldas	2016
Góes, A. R. T., Steiner, M. T. A., & Peniche, R. A.	Classification of Power Quality Considering Voltage Sags in Distribution Systems Using Kdd Process	Journal Pesquisa Operacional	2015
Gumus, E., Kilic, N., Sertbas, A., & Ucan, O. N.	Evaluation of face recognition techniques using PCA, wavelets and SVM	Elsevier	2010

Guo, G., Li, S. Z., & Chan, K. L.	Support vector machine for facial recognition	Elsevier	2001
Gutiérrez, J. D.	Clasificación de imágenes usando Máquinas de Soporte Vectorial	Universidad Nacional de Colombia	2007
Hayat, M., Bennamoun, M., & El-Sallam, A. A.	An RGB-D based image set classification for robust face recognition from Kinect data	Elsevier	2016
Heisele, B., Ho, P., Wu, J., & Poggio, T.	Face recognition: component-based versus global approaches	Elsevier	2003
Hjelmås, E., & Low, B. K.	Face Detection: A Survey	Idealibrary	2001
García, Inés	Diseño e implementación de una herramienta de detección facial	Instituto Politécnico Nacional México	2009
Juang, C.-F., & Shiu, S.-J.	Using self-organizing fuzzy network with support vector learning for face detection in color images	Elsevier	2008
Khan, N. M., Ksantini, R., Ahmad, I. S., & Boufama, B	A novel SVM+NDA model for classification with an application to face recognition	Elsevier	2012
Kim, S.-K., Park, Y. J., Toh, K.-A., & Lee, S	SVM-based feature extraction for face recognition	Elsevier	2010
Kong, R., & Zhang, B	A New Facial Recognition Method Based on Fast Least Squares Support Vector Machine	Elsevier	2011
La Serna Palomino, N., Pró Concepción,	Diseño de un sistema de recuperación de imágenes de	RISI	2013

L., & Román Concha, U.	individuos malhechores para seguridad ciudadana		
Lai, C.-C., & Ko, C.-H.	Facial expression recognition based on two-stage features extraction	Elsevier	2014
Lauer, F., & Bloch, G.	Incorporating Prior Knowledge in Support Vector Machines for Classification: a Review	Elsevier	2008
Le, T. H., & Bui, L	Face Recognition Based on SVM and 2DPCA	International Journal of Signal Processing	2011
Lei, Y., Bennamoun, M., Hayat, M., & Guo, Y.	An efficient 3D face recognition approach using local geometrical signatures	Elsevier	2014
Li, W., Liu, L., & Gong, W.	Multi-objective uniform design as a SVM model selection tool for face recognition	Elsevier	2011
Liau, H. F., & Isa, D.	Feature selection for support vector machine-based face-iris multimodal biometric system	Elsevier	2011
Lin, W.-H., Wang, P., & Tsai, C.-F.	Facial recognition using support vector model classifier for user authentication	Elsevier	2016
Luo, Y., Wu, C. M., & Zhang, Y.	Facial expression recognition based on fusion feature of PCA and LBP with machine vectors support	Elsevier	2013
Manso, M.	Predicción y selección de características, mediante análisis local de la fiabilidad , para el mercado de valores y su extensión	U. Carlos III Madrid. Tesis doctoral	2017

	a problemas de clasificación y regresión		
Milborrow, S., Morkel, J., & Nicolls, F.	The MUCT Landmarked Face Database	Elecceng. Proceedings Pattern Recognition Association of South Africa	2010
Montoya, J. F.	Identificación de patrones sísmicos en registros 2D mediante máquinas de soporte vectorial (SVM)	Grupo Solsytec	2015
Moreno, A., & Sanchez, a.	Face recognition using 3D local geometrical features: PCA vs. SVM.	Researchgate	2005
Salas, Rodrigo	Redes neuronales artificiales	Universidad del Valparaiso	2009
Nasiri, J. A., Moghadam Charkari, N., & Jalili, S.	Least squares twin multi-class classification support vector machine	Elsevier	2015
Nayef, M. Z.	Face Recognition System based on Wavelet, PCA-LDA and SVM	Computer Engineering and Intelligent Systems	2013
Olivares-Mercado, J., Toscano-Medina, K., Sánchez-Pérez, G., Nakano- Miyatake, M., & Pérez-Meana, H.	Modifications to the Eigenphases Method for Facial Recognition Based on Machine vectors support. Ingeniería, Investigación Y Tecnología	Ingeniería Investigación y Tecnología	2016

Quezada, V.	Reconocimiento de rostros utilizando análisis de componentes principales : limitaciones del algoritmo	Universidad Iberoamericana. Tesis Doctoral	2005
Resendiz Trejo, J.	Las maquinas de vectores de soporte para identificación en línea	Instituto Politécnico Nacional México. Tesis	2006
Riobó Otero, V.	Reconocimiento de Localizaciones mediante Máquinas de Soporte Vectorial	U. Carlos III Madrid. Tesis doctoral	2012
Rodríguez-vázquez, S., & Martínez-borges, A. V.	Clasificación de células cervicales con Máquinas de Soporte Vectorial empleando rasgos del núcleo	Revista Cubana de Ciencias Informáticas	2015
Saint-exupery, A. De, & Cedex, V.	Segmentación de la región de la boca en imágenes faciales : Revisión bibliográfica	Universidad Antioquia	2009
Schwaninger, A., & Yang, J.	Schwaninger, A., & Yang, J.	Elsevier	2011
Shao, Y. H., Chen, W. J., Wang, Z., Li, C. N., & Deng, N. Y.	Weighted linear loss twin support vector machine for large-scale classification	Elsevier	2015
Shih, P., & Liu, C.	Face detection using discriminating feature analysis and support vector machine	Elsevier	2006
Sistemas, I. D. E.	SEGUIMIENTO DE PATRONES FACIALES POR DESCRIPTORES DE FORMA	Universidad de Barcelona. Tesis	2008
SOHAIL, A. S. M., & BHATTACHARYA, P.	Classifying Facial Expressions Using Level Set Method Based Lip Contour Detection and Multi-Class Support Vector Machines	International Journal of Pattern Recognition and Artificial	2011

		Intelligence. World Cientific	
Song, F., Yang, J., & Liu, S.	Large margin linear projection and face recognition	Elsevier	2004
Villalón, Dario	DISEÑO E IMPLEMENTACIÓN DE UNA PLATAFORMA DE SOFTWARE PARA RECONOCIMIENTO FACIAL EN VIDEO	Universidad de Chile	2012
Valvert, J.	Métodos y técnicas de reconocimiento de rostros en imágenes digitales bidimensionales	U. San Carlos de Gatemala	2006
Vapnik, V. N.	Statistical Learning Theory	by John Wiley & Sons	1998
Wang, R.	AdaBoost for Feature Selection, Classification and Its Relation with SVM, A Review	Elsevier	2012
Wang, X. H., Liu, A., & Zhang, S. Q.	New facial expression recognition based on FSVM and KNN	Elsevier	2015
Wang, X., & Wang, S.	Enhanced algorithm for high-dimensional data classification	Elsevier	2015
Wei, J., Jian-Qi, Z., & Xiang, Z.	Face recognition method based on support vector machine and particle swarm optimization	Elsevier	2011
Wen, Y.	An improved discriminative common vectors and support vector machine based face recognition approach	Elsevier	2012

Paola Rondón y Henry Arguello, B. P. P.	Sistema de reconocimiento facial basado en imágenes con color	UIS Ingenierías	2011
Zhan, Y., & Shen, D.	Design efficient support vector machine for fast classification	Elsevier	2005
Zhang, S., & Zhao, X.	Locality-sensitive kernel sparse representation classification for face recognition	Elsevier	2014
Zhang, X., Mahoor, M. H., & Mavadati, S. M	Facial expression recognition using lp-norm MKL multiclass-SVM	Springer	2015
Zhang, X., & Gao, Y.	Face recognition across pose: A review	Elsevier	2009
Zhao, M., Fu, C., Ji, L., Tang, K., & Zhou, M	Feature selection and parameter optimization for support vector machines: A new approach based on genetic algorithm with feature chromosomes	Elsevier	2011
Zong, W., & Huang, G.-B	Face recognition based on extreme learning machine	Elsevier	2011

ANEXO 2: Elementos importantes que contemplan la implementación del modelo para reconocimiento 2D

Código para descargar base de datos

```

% --- Executes on button press in pushbuttonSeleccionarImágenes.
function pushbuttonSeleccionarImágenes_Callback(hObject, eventdata, handles)
% hObject      handle to pushbuttonSeleccionarImágenes (see GCBO)
% eventdata    reserved - to be defined in a future version of MATLAB
% handles      structure with handles and user data (see GUIDATA)

dbseleccionada=get(handles.radiobutton1,'Value');
folder_path = uigetdir;% abrir file chooser
disp(folder_path);
global gaborArray
if(dbseleccionada==1)
    %% 1) cargar la base de datos 1

```

Código para generar los filtros de Gabor

```

%% Create Gabor filters
% Create u*v gabor filters each being an m by n matrix

gaborArray = cell(u,v);
fmax = 0.25;
gama = sqrt(2);
eta = sqrt(2);

for i = 1:u


    fu = fmax/((sqrt(2))^(i-1));
    alpha = fu/gama;
    beta = fu/eta;

    for j = 1:v
        tetav = ((j-1)/v)*pi;
        gFilter = zeros(m,n);

        for x = 1:m
            for y = 1:n
                xprime = (x-((m+1)/2))*cos(tetav)+(y-((n+1)/2))*sin(tetav);
                yprime = -(x-((m+1)/2))*sin(tetav)+(y-((n+1)/2))*cos(tetav);
                gFilter(x,y) = (fu^2/(pi*gama*eta))*exp(-((alpha^2)*(xprime^2)+(beta^2)*(yprime^2)))*exp(1i*2*pi*fu*xprime);
            end
        end
    end
end

```

Resultado de la aplicación de un filtro de Gabor



Código para extraer características por Gabor

```

% Extract feature vector from input image
featureVector = [];
for i = 1:u
    for j = 1:v

        gaborAbs = abs(gaborResult{i,j});
        gaborAbs = downsample(gaborAbs,d1);
        gaborAbs = downsample(gaborAbs.',d2);
        gaborAbs = gaborAbs(:);

        % Normalized to zero mean and unit variance. (if not applicable, please comment this line)
        gaborAbs = (gaborAbs-mean(gaborAbs))/std(gaborAbs,1);

        featureVector = [featureVector; gaborAbs];
        % disp('matriz de características-----');
        % disp(size(featureVector));

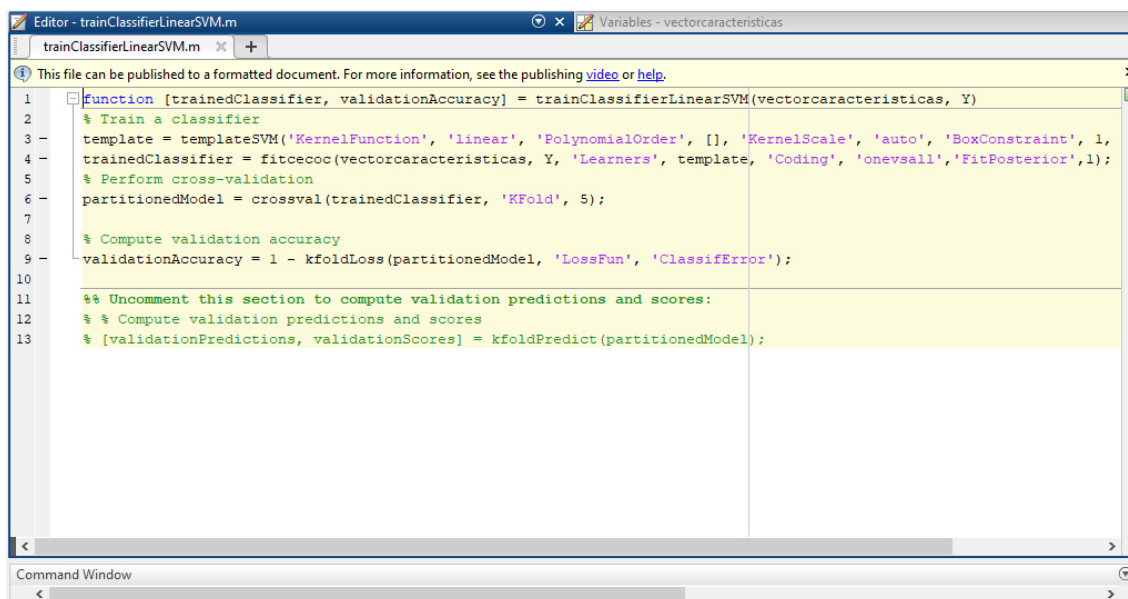
    end
end

```

Banco de vectores características de bdd FERET

	1	2	3	4	5	6	7	8	9	10	11	12	13
5	0.7489	1.9145	-0.6735	-0.6601	-0.6487	-0.6810	2.1832	0.0292	-0.5172	-0.5018	-0.5715	-0.6220	2.2325
6	0.7580	1.9095	-0.6823	-0.6590	-0.6566	-0.6696	2.1662	0.1072	-0.6025	-0.5653	-0.5182	-0.5873	2.2290
7	0.7600	1.9084	-0.6741	-0.6503	-0.6685	-0.6755	2.1564	0.1437	-0.6072	-0.5056	-0.5813	-0.6060	2.2355
8	0.7672	1.9044	-0.6700	-0.6600	-0.6660	-0.6757	2.1171	0.2812	-0.6014	-0.5791	-0.5927	-0.6250	2.2145
9	0.7442	1.9170	-0.6754	-0.6406	-0.6674	-0.6778	2.1760	0.0680	-0.5876	-0.5431	-0.5427	-0.5707	2.2355
10	0.7237	1.9282	-0.6691	-0.6556	-0.6643	-0.6629	2.1659	0.1101	-0.5752	-0.5362	-0.5714	-0.5932	2.2315
11	0.7412	1.9187	-0.6730	-0.6502	-0.6662	-0.6705	2.1645	0.1168	-0.5736	-0.5632	-0.5819	-0.5627	2.2365
12	0.8295	1.8683	-0.6746	-0.6440	-0.7048	-0.6744	2.1967	-0.0415	-0.4610	-0.5623	-0.6068	-0.5252	2.1835
13	1.3467	1.4796	-0.7021	-0.7009	-0.7166	-0.7066	2.2285	-0.2762	-0.4968	-0.4358	-0.4906	-0.5292	2.2355
14	1.3162	1.5078	-0.7039	-0.6974	-0.7181	-0.7047	2.2176	-0.1764	-0.5413	-0.4275	-0.5487	-0.5238	2.2355
15	1.2973	1.5248	-0.7209	-0.6986	-0.7175	-0.6851	2.2323	-0.3290	-0.4691	-0.4416	-0.5152	-0.4774	2.2345
16	1.7812	0.9678	-0.6670	-0.7083	-0.6737	-0.7001	2.2211	-0.1987	-0.4467	-0.5235	-0.5250	-0.5272	2.2355

Código del proceso de clasificación SVM



```
Editor - trainClassifierLinearSVM.m
Variables - vectorcaracteristicas
trainClassifierLinearSVM.m
This file can be published to a formatted document. For more information, see the publishing video or help.
1 function [trainedClassifier, validationAccuracy] = trainClassifierLinearSVM(vectorcaracteristicas, Y)
2 % Train a classifier
3 template = templateSVM('KernelFunction', 'linear', 'PolynomialOrder', [], 'KernelScale', 'auto', 'BoxConstraint', 1,
4 trainedClassifier = fitcecoc(vectorcaracteristicas, Y, 'Learners', template, 'Coding', 'onevsall', 'FitPosterior', 1);
5 % Perform cross-validation
6 partitionedModel = crossval(trainedClassifier, 'KFold', 5);
7
8 % Compute validation accuracy
9 validationAccuracy = 1 - kfoldLoss(partitionedModel, 'LossFun', 'ClassifError');
10
11 %% Uncomment this section to compute validation predictions and scores:
12 %% Compute validation predictions and scores
13 % [validationPredictions, validationScores] = kfoldPredict(partitionedModel);

Command Window
```

ANEXO 3: Interfaz para el reconocimiento facial en 2D

trainingVentana

Cargar Clasificadores, Vectores Características, e Imágenes

Base de datos

Base de datos 1 → BASE DE DATOS 1

Base de datos 2 → BASE DE DATOS UCT

Cargar Clasificador → ESCOGER UN .MAT DE LA CARPETA DE CLASIFICADORES

Cargar vector características para validar clasificador → ESCOGER UN .MAT CON LAS IMAGENES YA EXTRAIDAS LAS CARACTERISTICAS DE LA CARPETA Imagenes procesadas se cargara el vector de características y el vector Y con el nombre de cada persona

Seleccionar Carpeta Imagenes para validar clasificador → Seleccionar una carpeta para sacar la características y crear el vector de características y el vector Y

Validación —CON EL MODELO CARGADO HACER PREDICT DE TODAS LAS IMAGENES EN EL VECTOR DE CARACTERISTICAS Y COMPARAR LOS RESULTADOS

Validar Modelo

Imagen	VERDADERO	PREDECIDO	ACIERTO
1			
2			
3			
4			

Reconocimiento

ABRIR IMAGEN

RECONOCER

Clasificación

	1	2
1		
2		
3		
4		

Aciertos: Eficacia:

MOSTRAR LAS PROBABILIDADES PARA LA COMPARACION CON CADA PERSONA

ANEXO 4. Resultados con la bdd FERET, kernel LINEAL,

RESULTADOS CON LA BASE DE DATOS FERET
KERNEL LINEAL

ROSTROS DE PRUEBA	CLASE PERSONA IDENTIFICADA	VALIDACION
23	P5	CORRECTA
10	P2	CORRECTA
84	p17	CORRECTA
37	P8	CORRECTA
85	P17	CORRECTA
25	P5	CORRECTA
41	P9	CORRECTA
88	P18	CORRECTA
95	P19	CORRECTA
47	P10	CORRECTA
33	P7	CORRECTA
64	P13	CORRECTA
79	P16	CORRECTA
90	P18	CORRECTA
73	P15	CORRECTA
77	P16	CORRECTA
5	P1	CORRECTA
6	P2	CORRECTA
13	P3	CORRECTA
67	P14	CORRECTA
12	P3	CORRECTA
75	P15	CORRECTA
14	P3	CORRECTA
8	P2	CORRECTA
74	P15	CORRECTA
7	P2	CORRECTA
55	P11	CORRECTA
3	P1	CORRECTA
30	P6	CORRECTA
45	P9	CORRECTA
66	P14	CORRECTA
54	P11	CORRECTA
21	P5	CORRECTA
87	P18	CORRECTA
28	P6	CORRECTA
97	P20	CORRECTA
34	P7	CORRECTA

correcta incorrecta
25 0

35	P7	CORRECTA		
31	P7	CORRECTA		
98	P20	CORRECTA		
94	P19	CORRECTA		
46	P10	CORRECTA		
1	P1	CORRECTA		
72	P15	CORRECTA		
59	P12	CORRECTA		
36	P8	CORRECTA		
40	P8	CORRECTA		
71	P15	CORRECTA		
17	P4	CORRECTA	correcta	incorrecta
70	P14	CORRECTA	50	0
86	P18	CORRECTA		
48	P10	CORRECTA		
51	P11	CORRECTA		
89	P18	CORRECTA		
68	P14	CORRECTA		
62	P13	CORRECTA		
42	P9	CORRECTA		
57	P12	CORRECTA		
61	P13	CORRECTA		
16	P19	INCORRECTA		
83	P17	CORRECTA		
11	P3	CORRECTA		
80	P16	CORRECTA		
99	P20	CORRECTA		
43	P9	CORRECTA		
91	P19	CORRECTA		
9	P2	CORRECTA		
19	P11	INCORRECTA		
49	P10	CORRECTA		
2	P1	CORRECTA		
60	P12	CORRECTA		
52	P11	CORRECTA		
56	P12	CORRECTA		
18	P11	INCORRECTA	correcta	incorrecta
93	P19	CORRECTA	72	3
22	P5	CORRECTA		
24	P5	CORRECTA		
100	P20	CORRECTA		
15	P3	CORRECTA		
78	P16	CORRECTA		
63	P13	CORRECTA		

53	P11	CORRECTA		
32	P7	CORRECTA		
69	P14	CORRECTA		
27	P6	CORRECTA		
44	P9	CORRECTA		
92	P19	CORRECTA		
76	P16	CORRECTA		
50	P10	CORRECTA		
39	P8	CORRECTA		
20	P19	INCORRECTA		
26	P6	CORRECTA		
38	P7	INCORRECTA		
81	P17	CORRECTA		
29	P6	CORRECTA		
4	P1	CORRECTA		
82	P17	CORRECTA		
96	P20	CORRECTA		
58	P12	CORRECTA	correcta	incorrecta
65	P13	CORRECTA	95	2

TOTAL ACIERTOS 95

TOTAL DESHACIERTOS 5

TOTAL IMÁGENES DE PRUEBA: 100

Correcta: Cuando SI identificó la clases correcta a la que pertenece

Incorrecta: Cuando NO identificó la clases correcta a la que pertenece

ANEXO 5. Resultados con la bdd FERET, kernel CUBICO

RESULTADOS CON LA BASE DE DATOS

FERET

KERNEL

CUBICO

ROSTRO S DE PRUEBA	CLASE PERSONA IDENTIFICAD A	VALIDACION
23	P5	CORRECTA
10	P2	CORRECTA
84	P17	CORRECTA
37	P8	CORRECTA
85	P17	CORRECTA
25	P5	CORRECTA
41	P9	CORRECTA
88	P18	CORRECTA
95	P11	INCORRECTA
47	P10	CORRECTA
33	P7	CORRECTA
64	P13	CORRECTA
79	P16	CORRECTA
90	P18	CORRECTA
73	P15	CORRECTA
77	P16	CORRECTA
5	P5	INCORRECTA
6	P2	CORRECTA
13	P3	CORRECTA
67	P14	CORRECTA
12	P3	CORRECTA

75	P15	CORRECTA		
14	P3	CORRECTA		
8	P8	CORRECTA	correcta	incorrecta
74	P15	CORRECTA	23	2
7	P2	CORRECTA		
55	P11	CORRECTA		
3	P5	INCORRECT A		
30	P6	CORRECTA		
45	P9	CORRECTA		
66	P14	CORRECTA		
54	P11	CORRECTA		
21	P5	CORRECTA		
87	P18	CORRECTA		
28	P6	CORRECTA		
97	P20	CORRECTA		
34	P7	CORRECTA		
35	P7	CORRECTA		
31	P7	CORRECTA		
98	P20	CORRECTA		
94	P19	CORRECTA		
46	P10	CORRECTA		
1	P1	CORRECTA		
72	P15	CORRECTA		
59	P12	CORRECTA		
36	P8	CORRECTA		
40	P18	INCORRECT A		
71	P15	CORRECTA		
17	P4	CORRECTA	correcta	incorrecta
70	P14	CORRECTA	46	2
86	P18	CORRECTA		

48	P10	CORRECTA		
51	P11	CORRECTA		
89	P18	CORRECTA		
68	P14	CORRECTA		
62	P13	CORRECTA		
42	P9	CORRECTA		
57	P12	CORRECTA		
61	P13	CORRECTA		
16	P11	INCORRECT A		
83	P17	CORRECTA		
11	P3	CORRECTA		
80	P16	CORRECTA		
99	P20	CORRECTA		
43	P9	CORRECTA		
91	P19	CORRECTA		
9	P2	CORRECTA		
19	P11	INCORRECT A		
49	P10	CORRECTA		
2	P1	CORRECTA		
60	P12	CORRECTA		
52	P11	CORRECTA		
56	P12	CORRECTA		
18	P11	INCORRECT A	correcta	incorrecta
93	P19	CORRECTA	68	3
22	P5	CORRECTA		
24	P5	CORRECTA		
100	P20	CORRECTA		
15	P3	CORRECTA		
78	P16	CORRECTA		

63	P13	CORRECTA		
53	P11	CORRECTA		
32	P7	CORRECTA		
69	P14	CORRECTA		
27	P6	CORRECTA		
44	P9	CORRECTA		
92	P19	CORRECTA		
76	P16	CORRECTA		
50	P10	CORRECTA		
39	P8	CORRECTA		
20	P11	INCORRECTA		
26	P6	CORRECTA		
38	P8	CORRECTA		
81	P17	CORRECTA		
29	P6	CORRECTA		
4	P1	CORRECTA		
82	P17	CORRECTA		
96	P20	CORRECTA		
58	P12	CORRECTA	correcta	incorrecta
65	P13	CORRECTA	92	1

TOTAL, ACIERTOS 92

TOTAL, DESHACIERTOS 8

TOTAL, IMÁGENES DE

PRUEBA: 100

Correcta: Cuando SI identificó la clase correcta a la que pertenece

Incorrecta: Cuando NO identificó la clase correcta a la que pertenece

ANEXO 6. Resultados con la bdd FERET, kernel GAUSSIANO

RESULTADOS CON LA BASE DE DATOS

FERET

KERNEL GAUSSIANO

ROSTRO S DE PRUEBA	CLASE PERSONA IDENTIFICAD A	VALIDACION
23	P5	CORRECTA
10	P2	CORRECTA
84	P17	CORRECTA
37	P8	CORRECTA
85	P17	CORRECTA
25	P5	CORRECTA
41	P9	CORRECTA
88	P18	CORRECTA
95	P19	CORRECTA
47	P10	CORRECTA
33	P7	CORRECTA
64	P13	CORRECTA
79	P16	CORRECTA
90	P18	CORRECTA
73	P15	CORRECTA
77	P16	CORRECTA
5	P1	CORRECTA
6	P2	CORRECTA
13	P3	CORRECTA
67	P14	CORRECTA
12	P3	CORRECTA
75	P15	CORRECTA
14	P3	CORRECTA
8	P2	CORRECTA

correcta incorrecta

74	P15	CORRECTA	25	0
7	P2	CORRECTA		
55	P11	CORRECTA		
3	P1	CORRECTA		
30	P6	CORRECTA		
45	P9	CORRECTA		
66	P14	CORRECTA		
54	P11	CORRECTA		
21	P5	CORRECTA		
87	P18	CORRECTA		
28	P6	CORRECTA		
97	P20	CORRECTA		
34	P7	CORRECTA		
35	P7	CORRECTA		
31	P7	CORRECTA		
98	P20	CORRECTA		
94	P19	CORRECTA		
46	P10	CORRECTA		
1	P1	CORRECTA		
72	P15	CORRECTA		
59	P12	CORRECTA		
36	P8	CORRECTA		
40	P8	CORRECTA		
71	P15	CORRECTA		
17	P4	CORRECTA	correcta	incorrecta
70	P14	CORRECTA	50	0
86	P18	CORRECTA		
48	P10	CORRECTA		
51	P11	CORRECTA		
89	P18	CORRECTA		
68	P14	CORRECTA		
62	P13	CORRECTA		

42	P9	CORRECTA
57	P12	CORRECTA
61	P13	CORRECTA
16	P11	INCORRECT A
83	P17	CORRECTA
11	P3	CORRECTA
80	P16	CORRECTA
99	P20	CORRECTA
43	P9	CORRECTA
91	P19	CORRECTA
9	P2	CORRECTA
19	P11	INCORRECT A
49	P10	CORRECTA
2	P1	CORRECTA
60	P12	CORRECTA
52	P11	CORRECTA
56	P12	CORRECTA
18	P11	INCORRECT A
93	P19	CORRECTA
22	P5	CORRECTA
24	P5	CORRECTA
100	P20	CORRECTA
15	P3	CORRECTA
78	P16	CORRECTA
63	P13	CORRECTA
53	P11	CORRECTA
32	P7	CORRECTA
69	P14	CORRECTA
27	P6	CORRECTA

correcta incorrecta

72 3

44	P9	CORRECTA		
92	P19	CORRECTA		
76	P16	CORRECTA		
50	P10	CORRECTA		
39	P8	CORRECTA		
20	P19	INCORRECT A		
26	P6	CORRECTA		
38	P8	CORRECTA		
81	P17	CORRECTA		
29	P6	CORRECTA		
4	P1	CORRECTA		
82	P17	CORRECTA		
96	P20	CORRECTA		
58	P12	CORRECTA	correcta	incorrecta
65	P13	CORRECTA	96	1

TOTAL ACIERTOS 96

TOTAL DESHACIERTOS 4

TOTAL IMÁGENES DE

PRUEBA: 100

Correcta: Cuando SI identificó la clases correcta a la que pertenece

Incorrecta: Cuando NO identificó la clases correcta a la que pertenece

ANEXO 7. Resultados con la bdd MUCT, kernel LINEAL

RESULTADOS CON LA BASE DE DATOS

MUCT

KERNEL

LINEAL

ROSTRO S DE PRUEBA	CLASE PERSONA IDENTIFICAD A	VALIDACION
183	P60	CORRECTA
88	P29	CORRECTA
259	P86	CORRECTA
124	P41	CORRECTA
10	P3	CORRECTA
17	P5	CORRECTA
233	P77	CORRECTA
303	P100	CORRECTA
4	P1	CORRECTA
64	P21	CORRECTA
257	P85	CORRECTA
71	P23	CORRECTA
213	P70	CORRECTA
14	P4	CORRECTA
114	P37	CORRECTA
235	P78	CORRECTA
119	P39	CORRECTA
80	P26	CORRECTA
245	P81	CORRECTA
13	P4	CORRECTA
206	P68	CORRECTA
8	P2	CORRECTA
300	P99	CORRECTA

162	P53	CORRECTA		
47	P15	CORRECTA		
274	P91	CORRECTA		
146	P48	CORRECTA		
87	P28	CORRECTA		
154	P51	CORRECTA		
278	P92	CORRECTA		
174	P57	CORRECTA		
85	P28	CORRECTA		
189	P62	CORRECTA		
239	P79	CORRECTA		
110	P36	CORRECTA		
133	P44	CORRECTA		
26	P8	CORRECTA		
208	P69	CORRECTA		
129	P42	CORRECTA		
172	P57	CORRECTA		
153	P50	CORRECTA		
277	P92	CORRECTA		
90	P29	CORRECTA		
28	P9	CORRECTA		
140	P46	CORRECTA		
34	P11	CORRECTA		
302	P100	CORRECTA		
250	P83	CORRECTA		
203	P67	CORRECTA	CORRECTA	INCORRECTA
193	P64	CORRECTA	S	S
70	P23	CORRECTA	50	0
44	P14	CORRECTA		
118	P39	CORRECTA		
226	P75	CORRECTA		

1	P0	CORRECTA
286	P7	INCORRECTA
158	P52	CORRECTA
240	P79	CORRECTA
7	P2	CORRECTA
43	P14	CORRECTA
66	P21	CORRECTA
185	P61	CORRECTA
268	P54	INCORRECTA
171	P56	CORRECTA
181	P60	CORRECTA
104	P34	CORRECTA
139	P46	CORRECTA
166	P55	CORRECTA
63	P20	CORRECTA
292	P97	CORRECTA
3	P0	CORRECTA
191	P63	CORRECTA
247	P82	CORRECTA
215	P71	CORRECTA
31	P100	CORRECTA
15	P4	CORRECTA
117	P38	CORRECTA
82	P27	CORRECTA
29	P9	CORRECTA
219	P72	CORRECTA
175	P58	CORRECTA
97	P32	CORRECTA
285	P94	CORRECTA
217	P72	CORRECTA
163	P54	CORRECTA
214	P71	CORRECTA

65	P21	CORRECTA		
50	P16	CORRECTA		
255	P84	CORRECTA		
210	P69	CORRECTA		
211	P70	CORRECTA		
25	P8	CORRECTA		
167	P55	CORRECTA		
291	P96	CORRECTA		
101	P33	CORRECTA		
216	P71	CORRECTA		
190	P63	CORRECTA		
196	P65	CORRECTA		
280	P93	CORRECTA	CORRECTA	INCORRECTA
243	P80	CORRECTA	S	S
24	P7	CORRECTA	98	2
68	P22	CORRECTA		
39	P12	CORRECTA		
69	P22	CORRECTA		
225	P74	CORRECTA		
2	P0	CORRECTA		
260	P86	CORRECTA		
178	P59	CORRECTA		
224	P61	INCORRECTA		
296	P98	CORRECTA		
98	P77	INCORRECTA		
184	P61	CORRECTA		
35	P9	INCORRECTA		
198	P65	CORRECTA		
169	P56	CORRECTA		
231	P76	CORRECTA		
294	P97	CORRECTA		

234	P77	CORRECTA
123	P40	CORRECTA
273	P90	CORRECTA
20	P46	INCORRECTA
290	P96	CORRECTA
156	P51	CORRECTA
284	P10	INCORRECTA
248	P82	CORRECTA
84	P27	CORRECTA
30	P9	CORRECTA
262	P87	CORRECTA
122	P40	CORRECTA
59	P19	CORRECTA
218	P72	CORRECTA
253	P84	CORRECTA
295	P98	CORRECTA
83	P27	CORRECTA
142	P47	CORRECTA
130	P43	CORRECTA
45	P11	INCORRECTA
301	P100	CORRECTA
246	P81	CORRECTA
222	P73	CORRECTA
165	P54	CORRECTA
92	P30	CORRECTA
86	P85	INCORRECTA
51	P16	CORRECTA
275	P28	INCORRECTA
289	P96	CORRECTA
126	P41	CORRECTA
204	P67	CORRECTA

			CORRECTA	INCORRECTA
279	P92	CORRECTA	S	S
147	P48	CORRECTA	140	10
127	P29	INCORRECTA		
136	P45	CORRECTA		
58	P19	CORRECTA		
199	P66	CORRECTA		
202	P67	CORRECTA		
267	P46	INCORRECTA		
41	P13	CORRECTA		
11	P3	CORRECTA		
230	P76	CORRECTA		
176	P58	CORRECTA		
16	P5	CORRECTA		
49	P16	CORRECTA		
155	P98	INCORRECTA		
187	P54	INCORRECTA		
102	P33	CORRECTA		
144	P47	CORRECTA		
195	P64	CORRECTA		
53	P17	CORRECTA		
135	P44	CORRECTA		
18	P5	CORRECTA		
19	P6	CORRECTA		
168	P55	CORRECTA		
74	P24	CORRECTA		
180	P59	CORRECTA		
37	P12	CORRECTA		
194	P64	CORRECTA		
205	P68	CORRECTA		
109	P36	CORRECTA		
200	P66	CORRECTA		

55	P34	INCORRECTA		
57	P94	INCORRECTA		
6	P1	CORRECTA		
137	P45	CORRECTA		
107	P35	CORRECTA		
261	P86	CORRECTA		
237	P78	CORRECTA		
9	P2	CORRECTA		
94	P9	INCORRECTA		
265	P88	CORRECTA		
209	P69	CORRECTA		
42	P13	CORRECTA		
212	P70	CORRECTA		
62	P20	CORRECTA		
197	P65	CORRECTA		
113	P37	CORRECTA		
256	P85	CORRECTA		
186	P61	CORRECTA		
141	P46	CORRECTA		
100	P32	INCORRECTA	CORRECTA	INCORRECTA
27	P8	CORRECTA	S	S
236	P78	CORRECTA	182	18
75	P24	CORRECTA		
207	P68	CORRECTA		
152	P85	INCORRECTA		
182	P60	CORRECTA		
32	P10	CORRECTA		
232	P10	INCORRECTA		
12	P3	CORRECTA		
38	P12	CORRECTA		
188	P9	INCORRECTA		

177	P58	CORRECTA
249	P82	CORRECTA
282	P93	CORRECTA
67	P22	CORRECTA
287	P26	INCORRECTA
252	P83	CORRECTA
81	P26	CORRECTA
227	P75	CORRECTA
148	P49	CORRECTA
293	P97	CORRECTA
112	P37	CORRECTA
173	P57	CORRECTA
271	P90	CORRECTA
46	P15	CORRECTA
91	P30	CORRECTA
116	P7	INCORRECTA
254	P84	CORRECTA
297	P98	CORRECTA
54	P17	CORRECTA
288	P95	CORRECTA
96	P26	INCORRECTA
266	P88	CORRECTA
40	P13	CORRECTA
229	P76	CORRECTA
170	P56	CORRECTA
103	P34	CORRECTA
145	P48	CORRECTA
128	P42	CORRECTA
99	P32	CORRECTA
270	P89	CORRECTA
263	P87	CORRECTA
79	P26	CORRECTA

115	P38	CORRECTA		
143	P47	CORRECTA		
192	P63	CORRECTA		
121	P40	CORRECTA		
111	P36	CORRECTA		
299	P99	CORRECTA		
258	P85	CORRECTA	CORRECTA	INCORRECTA
73	P24	CORRECTA	S	S
220	P73	CORRECTA	226	24
221	P73	CORRECTA		
298	P5	INCORRECTA		
244	P81	CORRECTA		
36	P96	INCORRECTA		
179	P59	CORRECTA		
228	P75	CORRECTA		
5	P1	CORRECTA		
238	P79	CORRECTA		
134	P66	INCORRECTA		
160	P53	CORRECTA		
120	P39	CORRECTA		
89	P29	CORRECTA		
150	P49	CORRECTA		
61	P20	CORRECTA		
95	P31	CORRECTA		
276	P28	INCORRECTA		
149	P49	CORRECTA		
281	P93	CORRECTA		
72	P23	CORRECTA		
93	P89	INCORRECTA		
272	P90	CORRECTA		
23	P7	CORRECTA		

283	P94	CORRECTA		
157	P52	CORRECTA		
108	P35	CORRECTA		
21	P6	CORRECTA		
269	P54	INCORRECTA		
48	P15	CORRECTA		
106	P35	CORRECTA		
223	p74	CORRECTA		
77	P25	CORRECTA		
161	P53	CORRECTA		
241	P80	CORRECTA		
22	P7	CORRECTA		
52	P17	CORRECTA		
164	P54	CORRECTA		
159	P52	CORRECTA		
151	P50	CORRECTA		
60	P19	CORRECTA		
125	P6	INCORRECTA		
56	P8	INCORRECTA		
251	P83	CORRECTA		
242	P80	CORRECTA		
264	P87	CORRECTA		
131	P43	CORRECTA		
201	P66	CORRECTA		
78	P25	CORRECTA		
33	P10	CORRECTA		
138	P45	CORRECTA		
105	P34	CORRECTA		
132	P43	CORRECTA	CORRECTA	INCORRECTA
76	P25	CORRECTA	S	S
			271	32

TOTAL ACIERTOS 271

TOTAL DESHACIERTOS 32

TOTAL IMÁGENES DE

PRUEBA: 303

Correcta: Cuando SI identificó la clases correcta a la que pertenece

Incorrecta: Cuando NO identificó la clases correcta a la que pertenece

ANEXO 8. Resultados con la bdd MUCT, kernel CUBICO

RESULTADOS CON LA BASE DE DATOS MUCT
 KERNEL
 CUBICO

ROSTROS DE PRUEBA	CLASE O PERSONA IDENTIFICADA	VALIDACION
183	P60	CORRECTA
88	P29	CORRECTA
259	P86	CORRECTA
124	P41	CORRECTA
10	P3	CORRECTA
17	P5	CORRECTA
233	P77	CORRECTA
303	P100	CORRECTA
4	P1	CORRECTA
64	P21	CORRECTA
257	P85	CORRECTA
71	P23	CORRECTA
213	P70	CORRECTA
14	P4	CORRECTA
114	P37	CORRECTA
235	P78	CORRECTA
119	P39	CORRECTA
80	P26	CORRECTA
245	P81	CORRECTA
13	P4	CORRECTA
206	P68	CORRECTA
8	P2	CORRECTA
300	P99	CORRECTA
162	P53	CORRECTA
47	P15	CORRECTA

274	P91	CORRECTA
146	P48	CORRECTA
87	P28	CORRECTA
154	P51	CORRECTA
278	P92	CORRECTA
174	P57	CORRECTA
85	P28	CORRECTA
189	P62	CORRECTA
239	P79	CORRECTA
110	P36	CORRECTA
133	P44	CORRECTA
26	P8	CORRECTA
208	P69	CORRECTA
129	P42	CORRECTA
172	P57	CORRECTA
153	P50	CORRECTA
277	P92	CORRECTA
90	P29	CORRECTA
28	P9	CORRECTA
140	P46	CORRECTA
34	P11	CORRECTA
302	P100	CORRECTA
250	P83	CORRECTA
203	P67	CORRECTA
193	P64	CORRECTA
70	P23	CORRECTA
44	P14	CORRECTA
118	P39	CORRECTA
226	P75	CORRECTA
1	P0	CORRECTA
286	P95	CORRECTA
158	P52	CORRECTA

CORRECTAS INCORRECTAS

50

0

240	P30	INCORRECTA
7	P2	CORRECTA
43	P14	CORRECTA
66	P21	CORRECTA
185	P61	CORRECTA
268	P89	CORRECTA
171	P56	CORRECTA
181	P60	CORRECTA
104	P34	CORRECTA
139	P46	CORRECTA
166	P55	CORRECTA
63	P3	INCORRECTA
292	P97	CORRECTA
3	P0	CORRECTA
191	P63	CORRECTA
247	P82	CORRECTA
215	P71	CORRECTA
31	P10	CORRECTA
15	P4	CORRECTA
117	P38	CORRECTA
82	P27	CORRECTA
29	P9	CORRECTA
219	P72	CORRECTA
175	P58	CORRECTA
97	P32	CORRECTA
285	P94	CORRECTA
217	P72	CORRECTA
163	P54	CORRECTA
214	P71	CORRECTA
65	P77	INCORRECTA
50	P16	CORRECTA
255	P46	INCORRECTA

210	P69	CORRECTA
211	P70	CORRECTA
25	P8	CORRECTA
167	P55	CORRECTA
291	P1	INCORRECTA
101	P33	CORRECTA
216	P71	CORRECTA
190	P63	CORRECTA
196	P65	CORRECTA
280	P93	CORRECTA
243	P80	CORRECTA
24	P7	CORRECTA
68	P22	CORRECTA
39	P12	CORRECTA
69	P22	CORRECTA
225	P74	CORRECTA
2	P0	CORRECTA
260	P86	CORRECTA
178	P59	CORRECTA
224	P74	CORRECTA
296	P98	CORRECTA
98	P32	CORRECTA
184	P61	CORRECTA
35	P11	CORRECTA
198	P65	CORRECTA
169	P56	CORRECTA
231	P76	CORRECTA
294	P97	CORRECTA
234	P77	CORRECTA
123	P37	INCORRECTA
273	P90	CORRECTA
20	P6	CORRECTA

CORRECTAS INCORRECTAS

95

5

290	P96	CORRECTA
156	P51	CORRECTA
284	P94	CORRECTA
248	P41	INCORRECTA
84	P27	CORRECTA
30	P9	CORRECTA
262	P14	INCORRECTA
122	P37	INCORRECTA
59	P19	CORRECTA
218	P72	CORRECTA
253	P84	CORRECTA
295	P98	CORRECTA
83	P27	CORRECTA
142	P47	CORRECTA
130	P43	CORRECTA
45	P14	CORRECTA
301	P100	CORRECTA
246	P81	CORRECTA
222	P73	CORRECTA
165	P54	CORRECTA
92	P30	CORRECTA
86	P28	CORRECTA
51	P16	CORRECTA
275	P91	CORRECTA
289	P96	CORRECTA
126	P41	CORRECTA
204	P67	CORRECTA
279	P92	CORRECTA
147	P48	CORRECTA
127	P42	CORRECTA
136	P45	CORRECTA
58	P19	CORRECTA

CORRECTAS INCORRECTAS

141

9

199	P66	CORRECTA
202	P67	CORRECTA
267	P88	CORRECTA
41	P13	CORRECTA
11	P3	CORRECTA
230	P76	CORRECTA
176	P58	CORRECTA
16	P5	CORRECTA
49	P41	INCORRECTA
155	P51	CORRECTA
187	P62	CORRECTA
102	P33	CORRECTA
144	P47	CORRECTA
195	P64	CORRECTA
53	P17	CORRECTA
135	P44	CORRECTA
18	P5	CORRECTA
19	P6	CORRECTA
168	P55	CORRECTA
74	P24	CORRECTA
180	P59	CORRECTA
37	P12	CORRECTA
194	P64	CORRECTA
205	P68	CORRECTA
109	P36	CORRECTA
200	P66	CORRECTA
55	P18	CORRECTA
57	P18	CORRECTA
6	P1	CORRECTA
137	P45	CORRECTA
107	P88	INCORRECTA
261	P86	CORRECTA

237	P78	CORRECTA
9	P2	CORRECTA
94	P31	CORRECTA
265	P88	CORRECTA
209	P69	CORRECTA
42	P13	CORRECTA
212	P70	CORRECTA
62	P20	CORRECTA
197	P63	INCORRECTA
113	P37	CORRECTA
256	P85	CORRECTA
186	P61	CORRECTA
141	P46	CORRECTA
100	P33	CORRECTA
27	P8	CORRECTA
236	P78	CORRECTA
75	P24	CORRECTA
207	P68	CORRECTA
152	P50	CORRECTA
182	P60	CORRECTA
32	P10	CORRECTA
232	P77	CORRECTA
12	P3	CORRECTA
38	P12	CORRECTA
188	P62	CORRECTA
177	P58	CORRECTA
249	P82	CORRECTA
282	P93	CORRECTA
67	P22	CORRECTA
287	P95	CORRECTA
252	P83	CORRECTA
81	P26	CORRECTA

CORRECTAS INCORRECTAS

188

12

227	P75	CORRECTA
148	P49	CORRECTA
293	P97	CORRECTA
112	P37	CORRECTA
173	P57	CORRECTA
271	P90	CORRECTA
46	P15	CORRECTA
91	P30	CORRECTA
116	P38	CORRECTA
254	P84	CORRECTA
297	P98	CORRECTA
54	P17	CORRECTA
288	P95	CORRECTA
96	P31	CORRECTA
266	P88	CORRECTA
40	P13	CORRECTA
229	P76	CORRECTA
170	P56	CORRECTA
103	P89	INCORRECTA
145	P48	CORRECTA
128	P42	CORRECTA
99	P32	CORRECTA
270	P89	CORRECTA
263	P87	CORRECTA
79	P95	INCORRECTA
115	P38	CORRECTA
143	P50	INCORRECTA
192	P50	INCORRECTA
121	P71	INCORRECTA
111	P36	CORRECTA
299	P99	CORRECTA
258	P85	CORRECTA

CORRECTAS INCORRECTAS

73	P24	CORRECTA	233
220	P73	CORRECTA	
221	P7	INCORRECTA	
298	P99	CORRECTA	
244	P81	CORRECTA	
36	P11	CORRECTA	
179	P59	CORRECTA	
228	P75	CORRECTA	
5	P1	CORRECTA	
238	P51	INCORRECTA	
134	P44	CORRECTA	
160	P53	CORRECTA	
120	P39	CORRECTA	
89	P29	CORRECTA	
150	P49	CORRECTA	
61	P20	CORRECTA	
95	P31	CORRECTA	
276	P91	CORRECTA	
149	P49	CORRECTA	
281	P93	CORRECTA	
72	P23	CORRECTA	
93	P30	CORRECTA	
272	P90	CORRECTA	
23	P7	CORRECTA	
283	P94	CORRECTA	
157	P52	CORRECTA	
108	P35	CORRECTA	
21	P6	CORRECTA	
269	P89	CORRECTA	
48	P15	CORRECTA	
106	P35	CORRECTA	
223	P74	CORRECTA	

77	P25	CORRECTA		
161	P53	CORRECTA		
241	P80	CORRECTA		
22	P7	CORRECTA		
52	P17	CORRECTA		
164	P54	CORRECTA		
159	P52	CORRECTA		
151	P50	CORRECTA		
60	P19	CORRECTA		
125	P41	CORRECTA		
56	P18	CORRECTA		
251	P83	CORRECTA		
242	P80	CORRECTA		
264	P87	CORRECTA		
131	P43	CORRECTA		
201	P66	CORRECTA		
78	P25	CORRECTA		
33	P10	CORRECTA		
138	P45	CORRECTA		
105	P34	CORRECTA		
132	P43	CORRECTA	CORRECTAS	INCORRECTAS
76	P25	CORRECTA	284	19

TOTAL ACIERTOS 284

TOTAL DESHACIERTOS 19

TOTAL IMÁGENES DE

PRUEBA: 303

CORRECTA: Cuando SI identificó la clase correcta a la que pertenece

INCORRECTO: Cuando NO identificó la clase correcta a la que pertenece

ANEXO 9. Resultados con la bdd MUCT, kernel GAUSSIANO

RESULTADOS CON LA BASE DE DATOS
MUCT

KERNEL GAUSSIANO

ROSTRO S DE PRUEBA	CLASE PERSONA IDENTIFICAD A	VALIDACION
183	P60	CORRECTA
88	P29	CORRECTA
259	P86	CORRECTA
124	P41	CORRECTA
10	P3	CORRECTA
17	P5	CORRECTA
233	P77	CORRECTA
303	P100	CORRECTA
4	P1	CORRECTA
64	P21	CORRECTA
257	P85	CORRECTA
71	P23	CORRECTA
213	P70	CORRECTA
14	P4	CORRECTA
114	P37	CORRECTA
235	P78	CORRECTA
119	P39	CORRECTA
80	P26	CORRECTA
245	P81	CORRECTA
13	P4	CORRECTA
206	P68	CORRECTA
8	P2	CORRECTA
300	P99	CORRECTA
162	P53	CORRECTA
47	P15	CORRECTA
274	P91	CORRECTA
146	P48	CORRECTA
87	P28	CORRECTA
154	P51	CORRECTA
278	P92	CORRECTA
174	P57	CORRECTA
85	P28	CORRECTA
189	P62	CORRECTA
239	P79	CORRECTA
110	P36	CORRECTA

133	P44	CORRECTA
26	P8	CORRECTA
208	P69	CORRECTA
129	P42	CORRECTA
172	P57	CORRECTA
153	P50	CORRECTA
277	P92	CORRECTA
90	P29	CORRECTA
28	P9	CORRECTA
140	P46	CORRECTA
34	P11	CORRECTA
302	P100	CORRECTA
250	P83	CORRECTA
203	P67	CORRECTA
193	P64	CORRECTA
70	P23	CORRECTA
44	P14	CORRECTA
118	P39	CORRECTA
226	P75	CORRECTA
1	P0	CORRECTA
286	P95	CORRECTA
158	P52	CORRECTA
240	P79	CORRECTA
7	P2	CORRECTA
43	P14	CORRECTA
66	P21	CORRECTA
185	P61	CORRECTA
268	P54	INCORRECTA
171	P56	CORRECTA
181	P60	CORRECTA
104	P34	CORRECTA
139	P46	CORRECTA
166	P55	CORRECTA
63	P20	CORRECTA
292	P97	CORRECTA
3	P0	CORRECTA
191	P63	CORRECTA
247	P82	CORRECTA
215	P71	CORRECTA
31	P10	CORRECTA
15	P4	CORRECTA
117	P38	CORRECTA
82	P27	CORRECTA

CORRECTA	INCORRECTA
S	S
50	0

29	P9	CORRECTA
219	P72	CORRECTA
175	P58	CORRECTA
97	P32	CORRECTA
285	P94	CORRECTA
217	P72	CORRECTA
163	P54	CORRECTA
214	P71	CORRECTA
65	P21	CORRECTA
50	P16	CORRECTA
255	P84	CORRECTA
210	P69	CORRECTA
211	P70	CORRECTA
25	P8	CORRECTA
167	P55	CORRECTA
291	P96	CORRECTA
101	P33	CORRECTA
216	P71	CORRECTA
190	P63	CORRECTA
196	P65	CORRECTA
280	P93	CORRECTA
243	P80	CORRECTA
24	P7	CORRECTA
68	P22	CORRECTA
39	P12	CORRECTA
69	P22	CORRECTA
225	P74	CORRECTA
2	P0	CORRECTA
260	P86	CORRECTA
178	P59	CORRECTA
224	P61	INCORRECTA
296	P98	CORRECTA
98	P77	INCORRECTA
184	P95	INCORRECTA
35	P11	CORRECTA
198	P65	CORRECTA
169	P56	CORRECTA
231	P76	CORRECTA
294	P97	CORRECTA
234	P77	CORRECTA
123	P40	CORRECTA
273	P90	CORRECTA
20	P46	INCORRECTA

CORRECTA	INCORRECTA
S	S
99	1

290	P96	CORRECTA		
156	P51	CORRECTA		
284	P10	INCORRECTA		
248	P82	CORRECTA		
84	P27	CORRECTA		
30	P9	CORRECTA		
262	P87	CORRECTA		
122	P40	CORRECTA		
59	P19	CORRECTA		
218	P72	CORRECTA		
253	P84	CORRECTA		
295	P98	CORRECTA		
83	P27	CORRECTA		
142	P47	CORRECTA		
130	P43	CORRECTA		
45	P89	INCORRECTA		
301	P100	CORRECTA		
246	P81	CORRECTA		
222	P73	CORRECTA		
165	P54	CORRECTA		
92	P30	CORRECTA		
86	P85	INCORRECTA		
51	P16	CORRECTA		
275	P28	INCORRECTA		
289	P96	CORRECTA		
126	P41	CORRECTA		
204	P67	CORRECTA		
279	P92	CORRECTA	CORRECTA	INCORRECTA
147	P48	CORRECTA	S	S
127	P29	INCORRECTA	141	1
136	P45	CORRECTA		
58	P19	CORRECTA		
199	P66	CORRECTA		
202	P67	CORRECTA		
267	P88	CORRECTA		
41	P13	CORRECTA		
11	P3	CORRECTA		
230	P76	CORRECTA		
176	P58	CORRECTA		
16	P5	CORRECTA		
49	P16	CORRECTA		
155	P98	INCORRECTA		
187	P54	INCORRECTA		

102	P33	CORRECTA
144	P47	CORRECTA
195	P64	CORRECTA
53	P17	CORRECTA
135	P44	CORRECTA
18	P5	CORRECTA
19	P6	CORRECTA
168	P55	CORRECTA
74	P24	CORRECTA
180	P59	CORRECTA
37	P12	CORRECTA
194	P64	CORRECTA
205	P68	CORRECTA
109	P36	CORRECTA
200	P66	CORRECTA
55	P34	INCORRECTA
57	P94	INCORRECTA
6	P1	CORRECTA
137	P45	CORRECTA
107	P35	CORRECTA
261	P86	CORRECTA
237	P78	CORRECTA
9	P2	CORRECTA
94	P9	INCORRECTA
265	P88	CORRECTA
209	P69	CORRECTA
42	P13	CORRECTA
212	P70	CORRECTA
62	P20	CORRECTA
197	P65	CORRECTA
113	P37	CORRECTA
256	P85	CORRECTA
186	P61	CORRECTA
141	P46	CORRECTA
100	P33	CORRECTA
27	P8	CORRECTA
236	P78	CORRECTA
75	P24	CORRECTA
207	P68	CORRECTA
152	P85	INCORRECTA
182	P60	CORRECTA
32	P10	CORRECTA
232	P10	INCORRECTA

CORRECTA	INCORRECTA
S	S
185	15

12	P3	CORRECTA		
38	P12	CORRECTA		
188	P9	INCORRECTA		
177	P58	CORRECTA		
249	P82	CORRECTA		
282	P93	CORRECTA		
67	P22	CORRECTA		
287	P26	INCORRECTA		
252	P83	CORRECTA		
81	P70	INCORRECTA		
227	P75	CORRECTA		
148	P49	CORRECTA		
293	P97	CORRECTA		
112	P37	CORRECTA		
173	P57	CORRECTA		
271	P90	CORRECTA		
46	P15	CORRECTA		
91	P30	CORRECTA		
116	P38	CORRECTA		
254	P84	CORRECTA		
297	P98	CORRECTA		
54	P17	CORRECTA		
288	P95	CORRECTA		
96	P26	INCORRECTA		
266	P88	CORRECTA		
40	P13	CORRECTA		
229	P76	CORRECTA		
170	P56	CORRECTA		
103	P34	CORRECTA		
145	P48	CORRECTA		
128	P42	CORRECTA		
99	P32	CORRECTA		
270	P89	CORRECTA		
263	P87	CORRECTA		
79	P26	CORRECTA		
115	P38	CORRECTA		
143	P47	CORRECTA		
192	P63	CORRECTA		
121	P40	CORRECTA		
111	P36	CORRECTA		
299	P99	CORRECTA		
258	P85	CORRECTA	CORRECTA	INCORRECTA
73	P24	CORRECTA	S	S
			229	21

220	P73	CORRECTA
221	P73	CORRECTA
298	P63	INCORRECTA
244	P81	CORRECTA
36	P96	INCORRECTA
179	P59	CORRECTA
228	P75	CORRECTA
5	P1	CORRECTA
238	P79	CORRECTA
134	P66	INCORRECTA
160	P53	CORRECTA
120	P39	CORRECTA
89	P29	CORRECTA
150	P49	CORRECTA
61	P20	CORRECTA
95	P31	CORRECTA
276	P28	INCORRECTA
149	P49	CORRECTA
281	P93	CORRECTA
72	P23	CORRECTA
93	P89	INCORRECTA
272	P90	CORRECTA
23	P7	CORRECTA
283	P94	CORRECTA
157	P52	CORRECTA
108	p35	CORRECTA
21	p6	CORRECTA
269	P54	INCORRECTA
48	P15	CORRECTA
106	P35	CORRECTA
223	P74	CORRECTA
77	P25	CORRECTA
161	P53	CORRECTA
241	P80	CORRECTA
22	P7	CORRECTA
52	P17	CORRECTA
164	P54	CORRECTA
159	P52	CORRECTA
151	P50	CORRECTA
60	p19	CORRECTA
125	P6	INCORRECTA
56	P8	INCORRECTA
251	P83	CORRECTA
242	P80	CORRECTA

264	P87	CORRECTA		
131	P43	CORRECTA		
201	P66	CORRECTA		
78	P25	CORRECTA		
33	P9	CORRECTA		
138	P45	CORRECTA		
105	P34	CORRECTA		
132	P43	CORRECTA	CORRECTA	INCORRECTA
76	P25	CORRECTA	S	S
			274	29

TOTAL ACIERTOS 274

TOTAL DESHACIERTOS 29

TOTAL IMÁGENES DE
PRUEBA: 303

Correcta: Cuando SI identificó la clases correcta a la que pertenece

Incorrecta: Cuando NO identificó la clases correcta a la que pertenece

ANEXO 10: Interfaz para reconocimiento facial 3D con bdd TEXAS3DFRD y sus kernels: lineal, cúbico y gaussiano.

training/Ventana

Desarrollado por: Ing. José A. Cadena M. Mg.c.
Asesora: Dra. Nora La Serna

UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS

Técnica eficiente para reconocimiento facial global utilizando wavelets y Maquinas de vectores de soporte en imágenes 3D

Catálogo

Instrucciones para el reconocimiento de un conjunto de imágenes

- 1) Cargue el clasificador
- 2) Cargue el vector de características o seleccione una carpeta para validar el clasificador
- 3) Oprima Validar Modelo para ver los resultados del reconocimiento

Cargar Clasificadores , Vectores Características , e Imágenes

1) Cargar Clasificador

2) Cargar vector Características para validar clasificación

3) Seleccionar Carpeta Imágenes para validar clasificación

Validación

Valida el modelo y visualiza la eficacia del entrenamiento o aprendizaje de máquina

	Predicción	True	Acerto?	probabilidad
1	p1	p1	ok	0.9561
2	p1	p1	ok	0.9914
3	p1	p1	ok	0.9562
4	p1	p1	ok	0.9561
5	p1	p1	ok	0.9978
6	p1	p1	ok	0.9562
7	p1	p1	ok	0.9561
8	p1	p1	ok	0.9562
9	p1	p1	ok	0.9562
10	p1	p1	ok	0.9561
11	p1	p1	ok	0.9562
12	p1	p1	ok	0.9562
13	p1	p1	ok	0.9562
14	p1	p1	ok	0.9561
<				>

Aciertos: 904 / 908 Eficacia: 0.995595

Instrucciones Reconocimiento de una imagen

- 1) Cargue el clasificador
- 2) Oprima Abrir imagen para seleccionar un archivo
- 3) Oprima Reconocer, para ver los resultados del reconocimiento

Reconocimiento

2) ABRIR IMAGEN
3) RECONOCER

p30

Nombre de la clase identificada en base a la mayor probabilidad

se	probabilidad	score
1	0.0055783304	-0.07985141
2	0.0024960399	-0.07969800
3	0.0003041992	-0.08007335
4	0.0194858670	-0.07853881
5	0.0010749133	-0.08001169
6	0.0098156359	-0.07931243
7	0.0111020616	-0.07920952
<		>

ANEXO 11. Resultados con la bdd Texas 3DFRD, kernel Lineal

RESULTADOS CON LA BASE DE DATOS
TEXAS_3D

KERNEL
LINEAL

ROSTROS DE PRUEBA	CLASE PERSONA IDENTIFICADA	O VALIDACION
53	P44	SI
157	p14	SI
171	P16	SI
133	P10	SI
110	P6	SI
144	P12	SI
176	P17	SI
82	P13	NO
79	P2	SI
175	P17	SI
114	P7	SI
126	P9	SI
86	P2	SI
118	P8	SI
137	P11	SI
25	P31	SI
15	P26	SI
50	P43	SI
127	P15	NO
113	P7	SI
16	P7	NO
108	P6	SI
123	P8	SI
104	P5	SI
47	P41	SI
7	P22	SI
88	P2	SI
27	P32	SI
17	P27	SI
129	P10	SI
107	P6	SI
30	P17	NO
20	P28	SI
33	P11	NO
181	P18	SI

44	P11	NO
2	P19	SI
91	P3	SI
51	P43	SI
84	P2	SI
83	P2	SI
169	P12	SI
158	P14	SI
32	P34	SI
152	P13	SI
109	P1	NO
45	P11	NO
90	P3	SI
35	P36	SI
65	P50	SI
3	P6	NO
153	P13	SI
151	P13	SI
52	P17	NO
178	P18	SI
73	P1	SI
112	P7	SI
67	P1	SI
26	P31	SI
164	P15	SI
61	P48	SI
155	P18	SI
167	P15	NO
36	P36	SI
1	P19	SI
143	P12	SI
120	P8	SI
180	P18	SI
105	P5	SI
31	P34	SI
22	P29	SI
135	P48	NO
117	P7	SI
59	P47	SI
24	P30	SI
147	P12	SI
87	P2	SI
78	P2	SI
10	P13	NO

CORRECTA INCORRECTO
42 8

96	P11	SI
43	P39	SI
29	P33	SI
115	P7	SI
66	P1	SI
100	P5	SI
132	P10	SI
92	P3	SI
4	P16	NO
99	P4	SI
9	P2	NO
140	P11	SI
68	P1	SI
11	P24	SI
58	P47	SI
145	P12	SI
69	P1	SI
75	P1	SI
63	P49	SI
28	P32	SI
182	P18	SI
179	p18	SI
41	p38	SI
80	P2	SI
170	P16	SI
12	P24	SI
136	P11	SI
77	P2	SI
141	P11	SI
128	P9	SI
64	P50	SI
23	P30	SI
150	P13	SI
146	P12	SI
94	P3	SI
156	P17	SI
81	P2	SI
165	P15	SI
85	P2	SI
98	P4	SI
21	P29	SI
76	P5	NO
102	P5	SI
89	P3	SI

CORRECTA INCORRECTO

85

15

138	P11	SI
97	P4	SI
101	P5	SI
160	P15	SI
106	P6	SI
37	P37	SI
93	P3	SI
159	P14	SI
131	P10	SI
56	P18	NO
125	P9	SI
18	P27	SI
121	P8	SI
49	P42	SI
161	P15	SI
72	P1	SI
48	P42	SI
71	P1	SI
54	P45	SI
39	P37	SI
5	P8	NO
14	P25	SI
163	P15	SI
148	P13	SI
62	P49	SI
40	P38	SI
174	P17	SI
166	P16	SI
55	P45	SI
142	P12	SI
19	P28	SI
34	P35	SI
183	P18	SI
154	P14	SI
134	P18	NO
173	P17	SI
95	P4	SI
130	P10	SI
60	P48	SI
6	P8	NO
8	P22	SI
162	P15	SI
168	P11	NO
57	P46	SI

CORRECTA INCORRECTO

132

18

70	P1	SI		
177	P17	SI		
74	P1	SI		
119	P8	SI		
139	P11	SI		
42	P39	SI		
38	P37	SI		
149	P13	SI		
172	P17	SI		
13	P25	SI		
116	P7	SI		
111	P6	SI		
46	P41	SI		
122	P8	SI		
103	P5	SI	CORRECTA	INCORRECTO
124	P9	SI	162	21

TOTAL, ACIERTOS 162

TOTAL, DESHACIERTOS 21

TOTAL, IMÁGENES DE
PRUEBA: 183

Correcta: Cuando SI identificó la clase correcta a la que pertenece

Incorrecta: Cuando NO identificó la clase correcta a la que pertenece

ANEXO 12. Resultados con la bdd Texas 3DFRD, kernel Cúbico

ROSTROS DE PRUEBA	CLASE O PERSONA IDENTIFICADA	VALIDACION
53	P44	SI
157	P14	SI
171	P16	SI
133	P10	SI
110	P6	SI
144	P12	SI
176	P17	SI
82	P1	SI
79	P2	SI
175	P17	SI
114	P7	SI
126	P9	SI
86	P2	SI
118	P8	SI
137	P11	SI
25	P31	SI
15	P26	SI
50	P43	SI
127	P9	SI
113	P7	SI
16	P26	SI
108	P6	SI
123	P8	SI
104	P5	SI
47	P41	SI
7	P22	SI
88	P2	SI
27	P32	SI
17	P27	SI
129	P10	SI
107	P6	SI
30	P33	SI
20	P28	SI
33	P35	SI
181	P18	SI
44	P40	SI
2	P19	SI
91	P3	SI
51	P43	SI

84	P2	SI
83	P2	SI
169	P12	SI
158	P14	SI
32	P34	SI
152	P13	SI
109	P6	SI
45	P40	SI
90	P3	SI
35	P36	SI
65	P50	SI
3	P12	NO
153	P13	SI
151	P13	SI
52	P44	SI
178	P18	SI
73	P1	SI
112	P7	SI
67	P1	SI
26	P31	SI
164	P15	SI
61	P48	SI
155	P18	SI
167	P15	NO
36	P36	SI
1	P19	SI
143	P12	SI
120	P8	SI
180	P18	SI
105	P5	SI
31	P34	SI
22	P29	SI
135	P10	SI
117	P7	SI
59	P47	SI
24	P30	SI
147	P12	SI
87	P2	SI
78	P2	SI
10	P23	SI
96	P11	SI
43	P39	SI
29	P33	SI
115	P7	SI

CORRECTA INCORRECTO

50

0

66	P1	SI
100	P5	SI
132	P10	SI
92	P3	SI
4	P16	NO
99	P4	SI
9	P23	SI
140	P11	SI
68	P1	SI
11	P24	SI
58	P47	SI
145	P12	SI
69	P1	SI
75	P1	SI
63	P49	SI
28	P32	SI
182	P18	SI
179	P18	SI
41	P38	SI
80	P2	SI
170	P16	SI
12	P24	SI
136	P11	SI
77	P2	SI
141	P11	SI
128	P9	SI
64	P50	SI
23	P30	SI
150	P13	SI
146	P12	SI
94	P3	SI
156	P17	SI
81	P2	SI
165	P15	SI
85	P2	SI
98	P4	SI
21	P29	SI
76	P1	SI
102	P5	SI
89	P3	SI
138	P11	SI
97	P4	SI
101	P5	SI
160	P15	SI

CORRECTA INCORRECTO

97

3

106	P6	SI
37	P37	SI
93	P3	SI
159	P14	SI
131	P10	SI
56	P46	SI
125	P9	SI
18	P27	SI
121	P8	SI
49	P42	SI
161	P15	SI
72	P1	SI
48	P42	SI
71	P1	SI
54	P45	SI
39	P37	SI
5	P21	SI
14	P25	SI
163	P15	SI
148	P13	SI
62	P49	SI
40	P38	SI
174	P17	SI
166	P16	SI
55	P45	SI
142	P12	SI
19	P28	SI
34	P35	SI
183	P18	SI
154	P14	SI
134	P10	SI
173	P17	SI
95	P4	SI
130	P10	SI
60	P48	SI
6	P8	SI
8	P22	SI
162	P15	SI
168	P16	SI
57	P46	SI
70	P1	SI
177	P17	SI
74	P1	SI
119	P8	SI

CORRECTA INCORRECTO
147 3

139	P11	SI		
42	P39	SI		
38	P37	SI		
149	P13	SI		
172	P17	SI		
13	P25	SI		
116	P7	SI		
111	P6	SI		
46	P41	SI		
122	P8	SI		
103	P5	SI		
124	P9	SI		
			CORRECTA	INCORRECTO
			180	3

TOTAL ACIERTOS 180

TOTAL DESHACIERTOS 3

TOTAL IMÁGENES DE
PRUEBA: 183

Correcta: Cuando SI identificó la clases correcta a la que pertenece

Incorrecta: Cuando NO identificó la clases correcta a la que pertenece

ANEXO 13. Resultados con la bdd Texas 3DFRD, kernel Gaussiano

RESULTADOS CON LA BASE DE DATOS
TEXAS_3D

KERNEL GAUSSIANO

ROSTROS DE PRUEBA	CLASE PERSONA IDENTIFICADA	O VALIDACION
53	P44	SI
157	P8	NO
171	P16	SI
133	P10	SI
110	P6	SI
144	P12	SI
176	P17	SI
82	P5	NO
79	P2	SI
175	P17	SI
114	P7	SI
126	P9	SI
86	P5	NO
118	P8	SI
137	P11	SI
25	P31	SI
15	P7	NO
50	P43	SI
127	P15	NO
113	P7	SI
16	P7	NO
108	P6	SI
123	P8	SI
104	P5	SI
47	P41	SI
7	P22	SI
88	P2	SI
27	P8	NO
17	P27	SI
129	P10	SI
107	P6	SI
30	P33	SI
20	P28	SI
33	P11	NO
181	P18	SI
44	P40	SI

2	P19	SI
91	P3	SI
51	P43	SI
84	P2	SI
83	P2	SI
169	P12	SI
158	P14	SI
32	P34	SI
152	P13	SI
109	P1	NO
45	P5	NO
90	P3	SI
35	P36	SI
65	P50	SI
3	P6	NO
153	P13	SI
151	P13	SI
52	P44	SI
178	P18	SI
73	P1	SI
112	P7	SI
67	P1	SI
26	P31	SI
164	P15	SI
61	P48	SI
155	P14	NO
167	P15	NO
36	P36	SI
1	P19	SI
143	P12	SI
120	P8	SI
180	P18	SI
105	P5	SI
31	P34	SI
22	P29	SI
135	P10	SI
117	P7	SI
59	P47	SI
24	P30	SI
147	P12	SI
87	P2	SI
78	P2	SI
10	P13	NO
96	P11	SI

CORRECTA INCORRECTO
40 10

43	P15	NO
29	P33	SI
115	P7	SI
66	P1	SI
	P5	SI
132	P10	SI
92	P3	SI
4	P18	NO
99	P4	SI
9	P2	NO
140	P11	SI
68	P1	SI
11	P24	SI
58	P47	SI
145	P12	SI
69	P1	SI
75	P1	SI
63	P49	SI
28	P17	NO
182	P18	SI
179	P18	SI
41	P38	SI
80	P2	SI
170	P18	NO
12	P24	SI
136	P11	SI
77	P5	NO
141	P11	SI
128	P9	SI
64	P50	SI
23	P30	SI
150	P2	NO
146	P12	SI
94	P3	SI
156	P17	SI
81	P2	SI
165	P11	NO
85	P2	SI
98	P4	SI
21	P29	SI
76	P5	NO
102	P18	NO
89	P3	SI
138	P11	SI

CORRECTA INCORRECTO

82

18

97	P4	SI
101	P5	SI
160	P15	SI
106	P6	SI
37	P37	SI
93	P3	SI
159	P14	SI
131	P10	SI
56	P46	SI
125	P9	SI
18	P27	SI
121	P17	NO
49	P42	SI
161	P15	SI
72	P1	SI
48	P42	SI
71	P1	SI
54	P45	SI
39	P37	SI
5	P8	NO
14	P25	SI
163	P15	SI
148	P13	SI
62	P49	SI
40	P38	SI
174	P17	SI
166	P5	NO
55	P11	NO
142	P12	SI
19	P28	SI
34	P11	NO
183	P18	SI
154	P12	NO
134	P15	NO
173	P17	SI
95	P4	SI
130	P10	SI
60	P48	SI
6	P8	SI
8	P22	SI
162	P15	SI
168	P5	NO
57	P46	SI
70	P1	SI

CORRECTA INCORRECTO
124 26

177	P17	SI	
74	P1	SI	
119	P8	SI	
139	P11	SI	
42	P39	SI	
38	P37	SI	
149	P13	SI	
172	P17	SI	
13	P25	SI	
116	P7	SI	
111	P6	SI	
46	P41	SI	
122	P12	NO	
103	P5	SI	
124	P9	SI	
		CORRECTA	INCORRECTO
		150	33

TOTAL, ACIERTOS 150


TOTAL, DESHACIERTOS 33

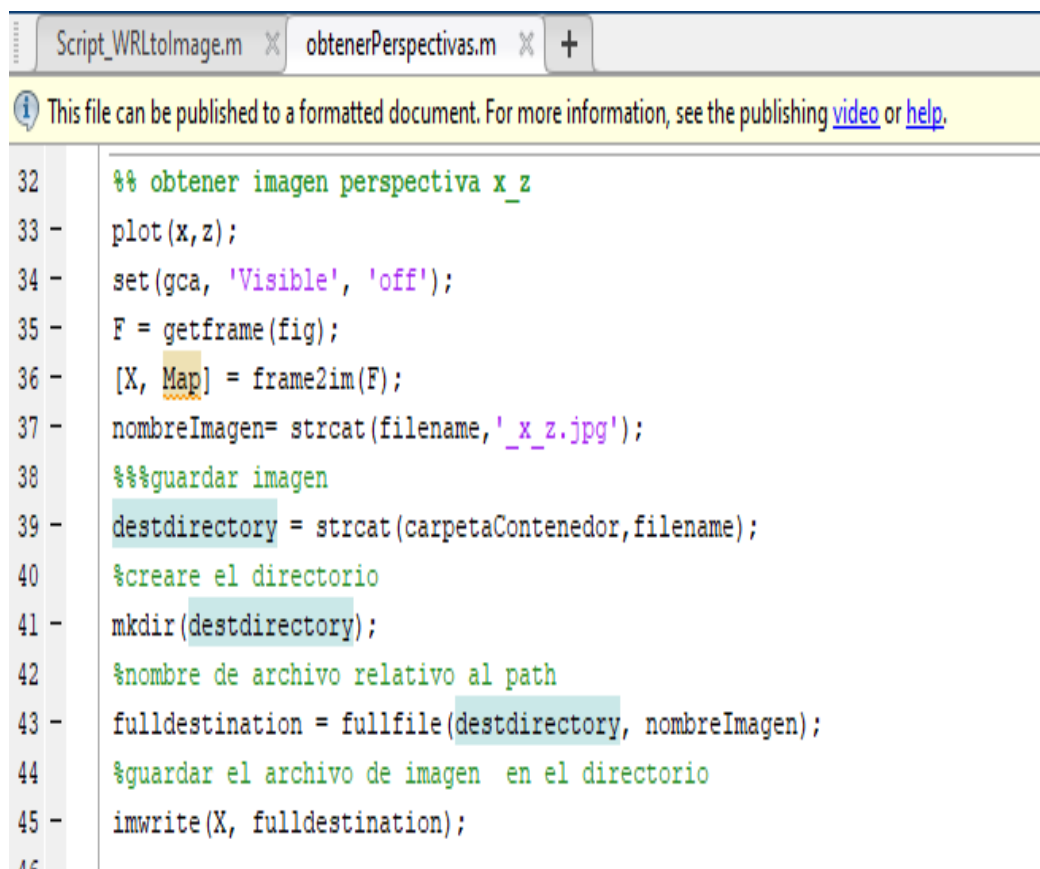
TOTAL, IMÁGENES DE
PRUEBA: 183

Correcta: Cuando SI identificó la clase correcta a la que pertenece

Incorrecta: Cuando NO identificó la clase correcta a la que pertenece

ANEXO 14: INTERFAZ PARA RECONOCIMIENTO FACIAL EN 3D CON BU-3DFE



ANEXO 15: Código para obtener una perspectiva de un modelo de cara 3D

```
Script_WRLtoImage.m x obtenerPerspectivas.m x +
This file can be published to a formatted document. For more information, see the publishing video or help.
32 %% obtener imagen perspectiva x_z
33 - plot(x,z);
34 - set(gca, 'Visible', 'off');
35 - F = getframe(fig);
36 - [X, Map] = frame2im(F);
37 - nombreImagen= strcat(filename, '_x_z.jpg');
38 %%guardar imagen
39 - destdirectory = strcat(carpetasContenedor,filename);
40 %crear el directorio
41 - mkdir(destdirectory);
42 %nombre de archivo relativo al path
43 - fulldestination = fullfile(destdirectory, nombreImagen);
44 %guardar el archivo de imagen en el directorio
45 - imwrite(X, fulldestination);
46
```

ANEXO 16: RESULTADOS CON LA BASE DE DATOS BU_3DFE – KERNEL LINEAL

**RESULTADOS CON LA BASE DE DATOS BU_3DFE
KERNEL LINEAL**

ROSTROS DE PRUEBA	CLASE O PERSONA IDENTIFICADA	VALIDACION
1	p1	Si
2	p1	si
3	p1	si
4	p2, p50, p26	no
5	p2, p24, p2	si
6	p40, p30, p11	no
7	p3	si
8	p3, p44, p7	no
9	p43, p19, p23	no
10	p4, p10, p23	no
11	p4, p24, p21	no
12	p4	si
13	p5, p5, p7	si
14	p5, p5, p30	si
15	p44, p45, p5	no
16	p6	si
17	p6	si
18	p6	si
19	p7	si
20	p7	si
21	p7	si
22	p10, p29, p44	no
23	p47, p47, p26	no
24	p26, p44, p47	no
25	p9	si
26	p9	si
27	p9	si
28	p10	si
29	p10	si
30	p10	si
31	p11	si
32	p11	si
33	p11	si
34	p26, p12, p12	si
35	p12	si
36	p12	si

37	p13	si
38	p13	si
39	p13	si
40	p47, p14, p14	si
41	p14, p14, p47	si
42	p14	si
43	p15	si
44	p15	si
45	p15, p21, p15	si
46	p16, p29,30	no
47	p16, p47, p16	si
48	p16, p47p26	no
49	p17	si
50	p17	si
51	p17, p17, p11	si
52	p18	si
53	p18	si
54	p18	si
55	p19	si
56	p19	si
57	p19	si
58	p20	si
59	p20	si
60	p20	si
61	p21	si
62	p21	si
63	p21	si
64	p22	si
65	p22	si
66	p22	si
67	p23	si
68	p23	si
69	p23	si
70	p24	si
71	p24	si
72	p24	si
73	p25	si
74	p25, p25, p3	si
75	p25	si
76	p26	si
77	p26	si
78	p26	si
79	p27	si
80	p27	si

81	p27	si
82	p23, p44, p45	no
83	p47, p30, p11	no
84	p19, p44, p24	no
85	p29	si
86	p29	si
87	p29	si
88	p30	si
89	p30	si
90	p30	si
91	p31, p31, p30	si
92	p31	si
93	p31	si
94	p45, p32, p32	si
95	p32, p32, p21	si
96	p32, p32, p45	si
97	p26, p33, p33	si
98	p33	si
99	p33	si
100	p21, p29, p21	no
101	p50, p29, p34	no
102	p44, p10, p34	no
103	p35	si
104	p35	si
105	p35	si
106	p36	si
107	p11, p36, p43	no
108	p36	si
109	p37	si
110	p37	si
111	p37	si
112	p38	si
113	p38	si
114	p38	si
115	p39	si
116	p39	si
117	p39	si
118	p40	si
119	p40, p29, p40	si
120	p40	si
121	p41, p44, p24	no
122	p29, p41, p41	si
123	p41	si
124	p42	si

125	p42	si
126	p42	si
127	p43	si
128	p43	si
129	p43	si
130	p44	si
131	p44	si
132	p44	si
133	p45	si
134	p45	si
135	p45	si
136	p46	si
137	p46	si
138	p46	si
139	p47	si
140	p47	si
141	p47	si
142	p48	si
143	p48	si
144	p48	si
145	p49	si
146	p49	si
147	p49	si
148	p50, p44, p50	si
149	p50	si
150	p50	si

TOTAL, ACIERTOS 130

TOTAL, DESHACIERTOS 20

TOTAL, IMÁGENES DE PRUEBA: 150

Correcta: Cuando SI identificó la clase correcta a la que pertenece

Incorrecta: Cuando NO identificó la clase correcta a la que pertenece

ANEXO 17: RESULTADOS CON LA BASE DE DATOS BU_3DFE – KERNEL CUBICO

RESULTADOS CON LA BASE DE DATOS BU_3DFE
KERNEL CUBICO

ROSTROS DE PRUEBA	CLASE O PERSONA IDENTIFICADA	VALIDACION
1	p1	si
2	p1	si
3	p1	si
4	p2	si
5	p2	si
6	p2	si
7	p3	si
8	p3	si
9	p5, p10, p23	no
10	p4	si
11	p4	si
12	p4	si
13	p5	si
14	p5	si
15	p5	si
16	p6	si
17	p6	si
18	p6	si
19	p7	si
20	p7	si
21	p7	si
22	p21, p18, p42	no
23	p30, p21, p21	no
24	p12, p42, p24	no
25	p9	si
26	p9	si
27	p9	si
28	p10	si
29	p10	si
30	p10	si
31	p11	si
32	p11	si
33	p11	si
34	p12	si
35	p12	si
36	p12	si

37	p13	si
38	p13	si
39	p13	si
40	p14	si
41	p14	si
42	p14	si
43	p15	si
44	p15	si
45	p15	si
46	p16	si
47	p16	si
48	p16	si
49	p17	si
50	p17	si
51	p17	si
52	p18	si
53	p18	si
54	p18	si
55	p19	si
56	p19	si
57	p19	si
58	p20	si
59	p20	si
60	p20	si
61	p21	si
62	p21	si
63	p21	si
64	p22	si
65	p22	si
66	p22	si
67	p23	si
68	p23	si
69	p23	si
70	p24	si
71	p24	si
72	p24	si
73	p25	si
74	p25	si
75	p25	si
76	p26	si
77	p26	si
78	p26	si
79	p27	si
80	p27	si

81	p27	si
82	p28	si
83	p28	si
84	p28	si
85	p29	si
86	p29	si
87	p29	si
88	p30	si
89	p30	si
90	p30	si
91	p31	si
92	p31	si
93	p31	si
94	p32	si
95	p32	si
96	p32	si
97	p33	si
98	p33	si
99	p33	si
100	p34	si
101	p34	si
102	p34	si
103	p35	si
104	p35	si
105	p35	si
106	p36	si
107	p36	si
108	p36	si
109	p37	si
110	p37	si
111	p37	si
112	p38	si
113	p38	si
114	p38	si
115	p39	si
116	p39	si
117	p39	si
118	p40	si
119	p40	si
120	p40	si
121	p41	si
122	p41	si
123	p41	si
124	p42	si

125	p42	si
126	p42	si
127	p43	si
128	p43	si
129	p43	si
130	p44	si
131	p44	si
132	p44	si
133	p45	si
134	p45	si
135	p45	si
136	p46	si
137	p46	si
138	p46	si
139	p47	si
140	p47	si
141	p47	si
142	p48	si
143	p48	si
144	p48	si
145	p49	si
146	p49	si
147	p49	si
148	p50	si
149	p50	si
150	p50	si

TOTAL, ACIERTOS 146

TOTAL, DESHACIERTOS 4

TOTAL, IMÁGENES DE PRUEBA: 150

Correcta: Cuando SI identificó la clase correcta a la que pertenece

Incorrecta: Cuando NO identificó la clase correcta a la que pertenece

ANEXO 18: RESULTADOS CON LA BASE DE DATOS BU_3DFE – KERNEL GAUSSIANO

RESULTADOS CON LA BASE DE DATOS BU_3DFE
KERNEL GAUSSIANO

ROSTROS DE PRUEBA	CLASE O PERSONA IDENTIFICADA	VALIDACION
1	P1	SI
2	P1	si
3	p1	si
4	p2	si
5	p2	si
6	p2	si
7	p3	si
8	p3	no
9	p3	no
10	p4	si
11	p4	no
12	p4	si
13	p5	no
14	p5	no
15	p5	si
16	p6	si
17	p6	si
18	p6	si
19	p7	si
20	p7	si
21	p7	si
22	p8	no
23	p8	no
24	p8	no
25	p9	si
26	p9	si
27	p9	si
28	p10	si
29	p10	si
30	p10	si
31	p11	si
32	p11	si
33	p11	si
34	p12	si
35	p12	si
36	p12	si

37	p13	si
38	p13	si
39	p13	si
40	p14	si
41	p14	si
42	p14	si
43	p15	si
44	p15	si
45	p15	si
46	p16	no
47	p16	no
48	p16	no
49	p17	si
50	p17	si
51	p17	si
52	p18	si
53	p18	si
54	p18	si
55	p19	si
56	p19	si
57	p19	si
58	p20	si
59	p20	si
60	p20	si
61	p21	si
62	p21	si
63	p21	si
64	p22	si
65	p22	si
66	p22	si
67	p23	si
68	p23	si
69	p23	si
70	p24	si
71	p24	si
72	p24	si
73	p25	si
74	p25	si
75	p25	si
76	p26	si
77	p26	si
78	p26	si
79	p27	si
80	p27	si

81	p27	si
82	p28	no
83	p28	no
84	p28	no
85	p29	si
86	p29	si
87	p29	si
88	p30	si
89	p30	si
90	p30	si
91	p31	si
92	p31	si
93	p31	si
94	p32	si
95	p32	si
96	p32	si
97	p33	si
98	p33	si
99	p33	si
100	p34	si
101	p34	si
102	p34	si
103	p35	si
104	p35	si
105	p35	si
106	p36	si
107	p36	no
108	p36	si
109	p37	si
110	p37	si
111	p37	si
112	p38	si
113	p38	si
114	p38	si
115	p39	si
116	p39	si
117	p39	si
118	p40	si
119	p40	si
120	p40	si
121	p41	si
122	p41	si
123	p41	si
124	p42	si

125	p42	si
126	p42	si
127	p43	si
128	p43	si
129	p43	si
130	p44	si
131	p44	si
132	p44	si
133	p45	si
134	p45	si
135	p45	si
136	p46	si
137	p46	si
138	p46	si
139	p47	si
140	p47	si
141	p47	si
142	p48	si
143	p48	si
144	p48	si
145	p49	si
146	p49	si
147	p49	si
148	p50	si
149	p50	si
150	p50	si

TOTAL, ACIERTOS 135

TOTAL, DESHACIERTOS 15

TOTAL, IMÁGENES DE

PRUEBA: 150

Correcta: Cuando SI identificó la clase correcta a la que pertenece

Incorrecta: Cuando NO identificó la clase correcta a la que pertenece

ANEXO: 19 PUBLICACIONES REALIZADAS SOBRE LA INVESTIGACION

El cúmulo de conocimientos adquiridos, durante el proceso de investigación, que comenzó con la revisión literaria hasta los resultados obtenidos se fueron plasmando en publicaciones a través de diferentes revistas indexadas en bases de datos como: Scopus, Web of science, latindex, Dialnet, siendo las siguientes.

- Técnica eficiente para el reconocimiento de imágenes faciales con máquinas de vectores de soporte en imágenes 2D con validación cruzada en Matlab. Revista Wseas. Año 2020. DOI: 10.37394/23203.2020.15.18 Indexado en SCOPUS. Ver Anexo 20

Link: <https://www.wseas.org/multimedia/journals/control/2020/a365103-946.pdf>

WSEAS TRANSACTIONS on SYSTEMS and CONTROL
DOI: 10.37394/23203.2020.15.18

Jose Augusto Cadena Moreano,
Nora Bertha La Serna Palomino

Efficient Technique for Facial Image Recognition with Support Vector Machines in 2D Images with Cross-Validation in Matlab

JOSE AUGUSTO CADENA MOREANO
Facultad de Ingeniería de Sistemas e
Informática
Universidad Nacional Mayor "San Marcos"
Av. Universitaria
Lima, PERU

NORA BERTHA LA SERNA PALOMINO
Facultad de Ingeniería de Sistemas e
Informática
Universidad Nacional Mayor "San Marcos"
Av. Universitaria
Lima, PERU

Abstract: - This article presented in the context of 2D global facial recognition, using Gabor Wavelet's feature extraction algorithms, and facial recognition Support Vector Machines (SVM), the latter incorporating the kernel functions: linear, cubic and Gaussian. The models generated by these kernels were validated by the cross validation technique through the Matlab application. The objective is to observe the results of facial recognition in each case. An efficient technique is proposed that includes the mentioned algorithms for a database of 2D images. The technique has been processed in its training and testing phases, for the facial image databases FERET [1] and MUCT [2], and the models generated by the technique allowed to perform the tests, whose results achieved a facial recognition of individuals over 96%.

Key-Words: Facial recognition, support vector machines, gabor wavelet, kernels, 2D images, databases feret, databases nmct.

Received: March 24, 2020. Revised: April 22, 2020. Accepted: May 8, 2020. Published: May 11, 2020.

1 Introduction

Face recognition has now become an area of active research that encompasses various disciplines, such as image processing, pattern sorter, computer vision, etc. This research topic has been around for many years, but it is always in permanent progress until at some point you can reach 100% recognition, also within the field of object recognition, where the face is a three-dimensional subject to variations of lighting, gestures, pose, etc. It is important to consider the difference between identification and verification. The identification is

the same one that is focused on Gabor's wavelet state of the art and the support vector machine (SVM), very important algorithms for the process of extraction of characteristics and classification of patterns respectively. Below is a description of the technique used with Gabor and SVM in the face recognition process, a description of the experiments carried out with the software designed for it is also made, then an analysis of the results obtained is carried out, both in the training and in the testing stage. In function of citizen security, the control of the entry and exit of personnel, etc., it is

- Global Facial Recognition Using Gabor Wavelet, Support Vector Machines and 3D Face Models. Revista JAiT. Año: 2020. DOI: 10.12720/jait.11.3.143-148 Indexado en SCOPUS. Ver Anexo 20

Link:

<http://www.jait.us/index.php?m=content&c=index&a=show&catid=199&id=1106>



The screenshot displays the journal's website interface. At the top, the journal title 'Journal of Advances in Information Technology' and ISSN '1798-2340' are visible. A navigation menu includes 'HOME', 'About JAiT', 'Editorial Boards', 'Author Guide', 'Editor Guide', 'Reviewer Guide', 'Published Issues', and 'Contact Us'. The main content area shows the article title, authors 'José Augusto Cadena Moreano and Nora Bertha La Serna Palomino', and their affiliation 'National University of San Marcos, Lima, Peru'. The abstract describes a method for face recognition using wavelet Gabor filtering, feature extraction, and SVM on the BU-3DFE database. The 'Index Terms' include databases, support vector machine, facial recognition, Gabor, and feature extraction. A citation is provided at the bottom: 'Cite: José Augusto Cadena Moreano and Nora Bertha La Serna Palomino, "Global Facial Recognition Using Gabor Wavelet, Support Vector Machines and 3D Face Models," Journal of Advances in Information Technology, Vol. 11, No. 3, pp. 143-148, August 2020. doi: 10.12720/jait.11.3.143-148'. On the left sidebar, there are sections for 'JAiT News' and 'Submissions'.

Journal of Advances in Information Technology
ISSN: 1798-2340

HOME About JAiT Editorial Boards Author Guide Editor Guide Reviewer Guide Published Issues Contact Us

Home > Published Issues > 2020 > Volume 11, No. 3, August 2020 >

JAiT News

- July 14th, 2020 News! (CFP) 2021 the annual meeting of JAiT Editorial Board, ICFIT 2021, will be held in Paris, France during March 14-16, 2021.
- July 14th, 2020 News! Vol. 11, No. 3 has been published online!
- April 17th, 2020 News! Vol. 11, No. 2 has been published online!
- March 16th, 2020 News! JAiT will be accepted for inclusion in Scopus.

Submissions

- Please send your full manuscript to: jait@etpub.com

Global Facial Recognition Using Gabor Wavelet, Support Vector Machines and 3D Face Models

José Augusto Cadena Moreano and Nora Bertha La Serna Palomino

National University of San Marcos, Lima, Peru

Abstract—The present research is aimed to develop an optimal method for face recognition based on wavelet Gabor filtering, feature extraction, and Support Vector Machine (SVM) using the BU-3DFE database containing 3D face models. Process for working with 350 models corresponding to 50 persons, i.e. 10 models per person divided seven for training and three for testing. The proposed technique involves projecting the face models obtained from the BU-3DFE database to the three planes using Matlab 2015a functions, and then, treating them as 2D images for recognition. The aim of this work is to achieve efficient 3D facial recognition with acceptable performance. As a result, the highest obtained value was 97.3% for SVM (kernel cubical). The results obtained for the proposed approach were compared with those of other recent 3D facial recognition methods to evaluate the potential of the former. Contribution of the present research is to facilitate urban security through providing a more efficient way for recognition of people who threaten the peace and tranquility of society, public or private institution, etc.

Index Terms—databases, support vector machine, facial recognition, Gabor, feature extraction

Cite: José Augusto Cadena Moreano and Nora Bertha La Serna Palomino, "Global Facial Recognition Using Gabor Wavelet, Support Vector Machines and 3D Face Models," Journal of Advances in Information Technology, Vol. 11, No. 3, pp. 143-148, August 2020. doi: 10.12720/jait.11.3.143-148

- Técnicas de reconocimiento facial utilizando SVM: un análisis comparativo. Revista Enfoque UTE. Año: 2019. DOI: 10.29019/enfoque.v10n3.493.

Indexado en WEB OF SCIENCE. Ver Anexo 20

Link:

<https://ingenieria.ute.edu.ec/enfoqueute/index.php/revista/article/view/493/559>

Enfoque UTE, V.10 - N.3, Sep. 2019, pp. 98-111
<http://ingenieria.ute.edu.ec/enfoqueute/>
e-ISSN: 1390-6542 / p-ISSN: 1390-9363

Recibido (Received): 2019/07/22
Aceptado (Accepted): 2019/09/05
CC BY 4.0

Facial recognition techniques using SVM: A comparative analysis

*(Técnicas de reconocimiento facial usando SVM:
un análisis comparativo)*

José Augusto Cadena Moreano¹, Nora La Serna Palomino², Alex Christian Llano Casa³

Abstract

This paper presents a literary review of facial recognition in 2D, which plays an important role in the life of the human being in terms of safety, work activity, etc. The focus is on the results obtained by some researchers with the application of feature extraction techniques, pattern classifiers, databases and their respective percentage of efficiency obtained. The objective is to determine efficient techniques that allow an optimal 2D facial recognition process, based on the quality of databases, feature extractors and pattern classifiers.

Keywords

Databases, Support vector machine, Facial recognition, Artificial neural networks.

Resumen

Este trabajo presenta una revisión literaria sobre reconocimiento facial en 2D, la cual juega un papel importante en la vida del ser humano en cuanto a su seguridad, actividad laboral, etc. El enfoque está en los resultados obtenidos por algunos investigadores con la aplicación de técnicas de extracción de características, clasificadores de patrones, bases de datos y su respectivo porcentaje de eficiencia obtenida. El objetivo es determinar técnicas eficientes que permitan realizar un proceso óptimo de reconocimiento facial en 2D, en función de la calidad de bases de datos, extractores de características y clasificador de patrones.

- Reconocimiento facial en subespacios: lineal y no lineal, bases de datos faciales y máquina de vectores de soporte. Revista Arjé. Año: 2018. Indexado en LATINDEX. Ver Anexo 20

Link: <http://arje.bc.uc.edu.ve/arje22e/art41.pdf>



**RECONOCIMIENTO FACIAL EN SUB-ESPACIOS:
LINEALES Y NO-LINEALES, BASES DE DATOS DE
ROSTROS Y MÁQUINA DE VECTORES DE SOPORTE**

JOSÉ AUGUSTO CADENA MOREANO

Universidad Técnica de Cotopaxi

jose.cadena@utc.edu.ec

GALO ALFREDO FLORES LAGLA

Universidad Técnica de Cotopaxi

galo.flores@utc.edu.ec

MANUEL WILLIAM VILLA QUISHPE

Universidad Técnica de Cotopaxi

manuel.villa@utc.edu.ec

JUAN CARLOS CHANCÚSIG CHISAG

Universidad Técnica de Cotopaxi

juan.chancusig@utc.edu.ec

OSCAR ALEJANDRO GUAYPATÍN PICO

Universidad Técnica de Cotopaxi

Recibido: 05/02/2018

Aprobado: 06/06/2018

- Reconocimiento facial con base en imágenes. Revista Redipe. Año 2017.

Indexado en DIALNET. Ver Anexo 20

Link: <https://dialnet.unirioja.es/servlet/articulo?codigo=6145639>

The screenshot shows the Redipe journal website. The header includes the journal name 'revista redipe' and navigation links: HOME, ACERCA DE, ACTUAL, ARCHIVOS, ANTIPLAGIO Y ÉTICA. A search bar is located on the right. The main content area displays the article title 'Reconocimiento facial con base en imágenes' and lists the authors: José Augusto Cadena Moreano, Raúl Humberto Montaluisa Pulloquina, Galo Alfredo Flores Lagla, Juan Carlos Chancúsig Chisag, and Oscar Alejandro Guaypatin Pico, all from Universidad Técnica de Cotopaxi. A PDF icon is available for download. The publication date is May 29, 2017. A 'Cómo citar' section provides the citation information. On the right sidebar, there is a language selector (English, Español) and logos for indexing services: latindex, DOAJ (Directory of Open Access Journals), and ERIH PLUS.

Inicio / Archivos / Vol. 6 Núm. 5 (2017): Educación ambiental, sustentabilidad y diseño curricular / Artículos

Reconocimiento facial con base en imágenes

José Augusto Cadena Moreano
Universidad Técnica de Cotopaxi

Raúl Humberto Montaluisa Pulloquina
Universidad Técnica de Cotopaxi.

Galo Alfredo Flores Lagla
Universidad Técnica de Cotopaxi.

Juan Carlos Chancúsig Chisag
Universidad Técnica de Cotopaxi.

Oscar Alejandro Guaypatin Pico
Universidad Técnica de Cotopaxi

PDF

Publicado
may 29, 2017

Cómo citar

Cadena Moreano JA, Montaluisa Pulloquina RH, Flores Lagla GA, Chancúsig Chisag JC, Guaypatin Pico OA. Reconocimiento facial con base en imágenes. bol.redipe [Internet]. 29 de mayo de 2017 [citado 12 de julio de 2020];6(5):143 -151. Disponible en:

Idioma
» English
» Español (España)

revista | redipe
latindex

revista | redipe
DOAJ DIRECTORY OF OPEN ACCESS JOURNALS

revista | redipe
ERIH PLUS