

Selección robusta de características biométricas usando *ensembles* y metaheurísticas multi-objetivo paralelas

R. M. Luque-Baena, J.E. Agudo, F. Chávez, J. Valenzuela-Valdés, and F. Luna

Centro Universitario de Mérida
C/Santa Teresa de Jornet 38, Mérida
Universidad de Extremadura, España
{rmluque, jeagudo, fchavez, juanvalenzuela, fluna}@unex.es

Resumen Este artículo presenta una metodología para la selección de características robustas en el ámbito del análisis biométrico de la palma de la mano, utilizando metaheurísticas multi-objetivo paralelas y un ensemble de clasificadores, formado por varias técnicas de clasificación: árboles de decisión, *naive* Bayes, k vecinos más cercanos, perceptrón multicapa y máquinas de vectores de soporte. El objetivo es encontrar el conjunto de rasgos geométricos de la mano mínimo que permita realizar con éxito tareas de identificación biométrica, sin que estas características sean dependientes del método de clasificación utilizado ni de su parametrización. Como resultado, obtenemos un conjunto reducido de características que disminuye la complejidad del proceso de identificación y un *ensemble* de clasificadores optimizado al conjunto de datos analizado que obtiene tasas de acierto cercanas al 98 %.

Keywords: Biometría de la mano, Características geométricas, Metaheurísticas multi-objetivo, Ensemble de clasificadores

1. Introducción

En el mundo globalizado que nos rodea, donde el acceso a datos, la movilidad de las personas, el almacenamiento de información en la nube, etc. está completamente arraigado en nuestra forma de vida, la seguridad se hace, si cabe, una de las tareas más críticas. Es por ello que debemos contar con sistemas que puedan identificar inequívocamente a las personas que hacen uso de los datos, que acceden a la información, viajeros, etc. Uno de los campos de investigación que trabajan en seguridad son los estudios en sistemas biométricos [9]. Un sistema biométrico nos permite identificar a una persona sin margen de error, por medio del análisis del iris, voz, huella dactilar, patrón venoso o de la palma de la mano, entre otros.

El trabajo aquí presentado es la continuación de trabajos previos [12], donde se han presentados resultados satisfactorios en el estudio de sistemas biométricos que hacen uso del análisis completo de la palma de la mano. Este estudio se realiza por medio de la extracción de características que representan la información que debe estudiarse para identificar la palma de la mano de un determinado usuario. La literatura nos ofrece diversos métodos destinados a la identificación de la palma de la mano. Dichos

métodos se basan en identificación del dedo a través de los patrones venosos del mismo [10], reconocimiento biométrico de la mano a través de dispositivos móviles [14], identificación biométrica de la mano en dispositivos que no requieren contacto utilizando características geométricas [6], deformaciones de la mano [8], entre otros. El patrón común de estos métodos se basa en la extracción de características, etapa clave que permitirá identificar la mano que se está analizando. Puede entenderse que a mayor número de características que se extraigan de la mano, mayor será la tasa de acierto de los sistemas diseñados, pero los estudios indican lo contrario, no un mayor número de características garantizan el éxito del sistema [7].

El objetivo principal de esta propuesta es detectar qué características son más discriminantes en función de un ensemble de clasificadores que incluye diferentes métodos de clasificación utilizados a lo largo de la literatura. La selección de las características más idóneas junto con los parámetros óptimos de cada clasificador se realiza mediante un algoritmo metaheurístico multi-objetivo y paralelo, el cual permitirá obtener la mejor configuración de características y parámetros sobre un conjunto de imágenes de entrada.

El artículo se estructura de la siguiente forma: las secciones 2 y 3 describen los pasos necesarios para obtener un conjunto fiable y robusto de rasgos geométricos de la palma de la mano; la sección 4 presenta la metodología propuesta basada en metaheurísticas y un *ensemble* de clasificadores, con el objetivo de proporcionar un subconjunto significativo y discriminante de características; en la sección 5 se muestran los resultados experimentales obtenidos sobre la base de datos GPDS y la sección 6 esboza las conclusiones de este trabajo.

2. Preprocesamiento de las imágenes

El principal objetivo de esta etapa es proporcionar un punto de partida razonable para el proceso de extracción de características. Hay que tener en cuenta que cuanto mayor sea el número de restricciones del sistema físico, más simple será la fase de preproceso. Si es posible evitar cambios repentinos de luz y lograr una iluminación homogénea durante el proceso de adquisición, la tarea de la binarización de la imagen será menos compleja y ardua. No obstante, si el sistema de adquisición permite colocar la mano con cierta libertad, esta tarea no será demasiado tediosa para el usuario final, aunque sí puede elevar la complejidad en el algoritmo de posicionamiento.

Dado que hemos utilizado el conjunto de datos GPDS Hand database¹ adquirido de la Universidad de las Palmas de Gran Canaria[5], estas restricciones están ya definidas. Por tanto, las imágenes deberán ser analizadas para llevar a cabo el procedimiento de preproceso adecuado. Esta base de datos contiene 50 individuos con 10 capturas diferentes de la palma de su mano derecha. Las 500 imágenes han sido obtenidas con un escáner de sobremesa sin soportes o plantillas que puedan obstaculizar el posicionamiento de la mano correctamente. Las manos masculinas constituyen el 68 % de los datos mientras que las femeninas el resto. La edad de los usuarios varía entre los 23 y 30 años. El objetivo es ponerse en la peor situación al utilizar imágenes con edad

¹ La base de datos puede ser descargada de <http://www.gpds.ulpgc.es/download/index.htm>

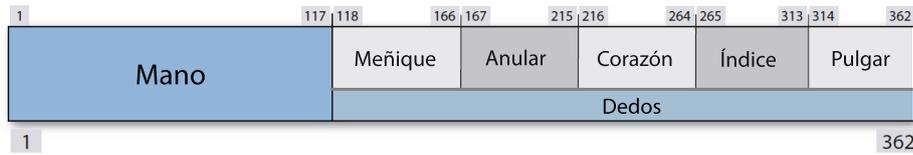


Figura 1. Vector de características. Una tercera parte del vector se corresponde con características de la palma de la mano mientras que el resto se asocian a cada uno de los dedos. Los números delimitan el comienzo y fin del bloque de rasgos obtenidos por cada región.

similar en la que la variación de la forma visual no es tan significativa. Las imágenes tienen 150 dpi y 256 niveles de gris. El preprocesamiento de imágenes propuesto puede dividirse en los siguientes pasos:

- Binarización.** Se observa que el fondo de la imagen es principalmente negro y hay un contraste alto con respecto al primer plano (ver Figura 2(a)). La iluminación es homogénea en toda la imagen y no hay cambios significativos en la extracción de características, con lo que, tras aplicar un filtro mediana para suavizar los picos y reducir las variaciones de pixel no deseadas, utilizamos el método Otsu para obtener un umbral automático y binarizar la imagen [13]. Con posterioridad, se aplican operadores morfológicos para limpiarla rellenando los huecos y eliminando falsos objetos.
- Orientación.** Dado que el sistema de adquisición no tiene soportes de orientación, la mano puede ser posicionada en cualquier lugar de la ventana del escáner y por tanto es necesario localizar la región asociada a la misma. Utilizaremos una variación del algoritmo iterativo propuesto en [1] que se basa en la utilización de operadores morfológicos de cierre y apertura para determinar la localización del dedo corazón y rotar la mano en consecuencia.
- Suavizado de los límites de la mano.** El proceso de binarización no siempre es tan robusto y preciso como se espera. Esto implica que los bordes de la mano podrían presentar algo de ruido e imperfecciones, lo que altera las mediciones geométricas a calcular. Si el contorno es considerado como la curva paramétrica $(x(t), y(t))$, este puede ser suavizado aplicando la técnica de regresión kernel 1D. En este caso, x es la coordenada x del pixel de contorno, y es la coordenada y del pixel de contorno y t es la posición de cada pixel en la curva.

3. Extracción de características biométricas

En esta sección presentamos el conjunto de características extraídas de la mano a partir de la imagen binaria. Solamente se han extraído las características geométricas debido a su sencillez en el cálculo, además de que está probada su utilidad en los problemas de reconocimiento biométrico [4]. Estos descriptores geométricos se detallan en la tabla 1, donde cada número se corresponde con el identificador o variable asignada dentro del vector representado en la Figura 1. Cada descriptor se ha aplicado tanto a la mano como a cada dedo individualmente. Así, por ejemplo, las 117 primeras variables

<i>Descriptor</i>	<i>Características</i>					
	<i>Mano</i>	<i>Dedos</i>				
		<i>Meñique</i>	<i>Anular</i>	<i>Corazón</i>	<i>Índice</i>	<i>Pulgar</i>
Área	1	122	171	220	269	318
Perímetro	2	123	172	221	270	319
Compacidad	3	124	173	222	271	320
Ancho	4	119-121	168-170	217-219	266-268	315-317
Largo	5	118	167	216	265	314
Proporción de aspecto	6	126	175	224	273	322
Solidez	7	125	174	223	272	321
Dist. Meñique-Índice	8	-	-	-	-	-
Dist. Meñique-Pulgar	9	-	-	-	-	-
Dist. Índice-Pulgar	10	-	-	-	-	-
Magnitud de Fourier	11-60	147-166	196-215	245-264	294-313	343-362
Fase de Fourier	61-110	127-146	176-195	225-244	274-293	323-342
Momentos de Hu	111-117	-	-	-	-	-

Tabla 1. Significado de cada característica detectada. La información que contiene cada variable o identificador se indica en la primera columna. Cada número representa la posición en el vector de características que definen una mano. Algunos descriptores se corresponden con las medidas que se muestran en la Figura 2(a).

se corresponderán con descriptores de la mano completa, mientras que de la 118 a la 166 se corresponderán con medidas del dedo meñique. Hay que tener en cuenta que este proceso se lleva a cabo automáticamente analizando la silueta de la mano y la región invariante del imagen binaria de la mano obtenida en la sección previa.

Observando la tabla 1, podemos ver como los primeros cinco descriptores (*área* (a), *perímetro* (p), *ancho*, *alto* y *proporción de aspecto*) son los típicos descriptores geométricos. Las tres medidas del *ancho* son calculadas por cada dedo (una por falange). La *proporción de aspecto* está calculada dividiendo el ancho por el alto. Siendo B la imagen binaria resultante, la *solidez* puede ser fácilmente calculada tras obtener el área convexa como $s = a/Convex_B$, mientras que la *compacidad* de una región se define como $c = 4\pi(a/p^2)$.

Además, se calculan también un conjunto de siete momentos invariantes, llamados *momentos de Hu*. Los momentos de un imagen representan importantes propiedades estadísticas y su utilidad ha sido probada para describir objetos tras la segmentación [11]. Estos siete momentos son invariantes a traslaciones, cambios de escala, rotaciones y transformaciones espejo. Una silueta cerrada definida como $(x(t), y(t))$ puede ser representada en términos de P descriptores de Fourier, mediante su magnitud y su fase, donde t es la longitud de la curva desde el punto de partida. Nótese que se han utilizado más descriptores de Fourier para la silueta de la mano ($P = 50$) que para la silueta de cada dedo debido a su complejidad.

Finalmente, se han calculado tres distancias robustas entre puntos interiores del contorno de la mano [4]. Algunas características están representadas en la Figura 2(a) y se describen en la Tabla 1, donde podemos ver la posición en el vector de características

(ver Figura 1). En total, se han extraído 362 características que definen y representan cada imagen de la mano.

4. Metodología

La metodología propuesta implica la utilización de metaheurísticas para la optimización de dos objetivos: la minimización del número de características y la minimización del error de clasificación de un *ensemble* de clasificadores. La utilización de un *ensemble* se justifica debido a que la optimización del error genera un conjunto de características más robustas, pues no nos quedamos con aquéllas que mejoran sólo a un clasificador en concreto.

4.1. Ensemble de clasificadores

El *ensemble* estará formado por varios métodos de clasificación bastante frecuentes en la literatura y que tratarán de clasificar el conjunto de datos de entrada. Estas técnicas se detallan a continuación:

- El clasificador J48 es un algoritmo de clasificación basado en árbol de decisión generado por C4.5, el cual genera un árbol binario. Con esta técnica, se construye un árbol para modelar el proceso de clasificación.
- El algoritmo *Naive Bayes* es un clasificador probabilístico simple que calcula un conjunto de probabilidades contando la frecuencia y combinaciones de un determinado conjunto de datos. El algoritmo utiliza el teorema de Bayes y asume que todos los atributos son independientes dado el valor de la variable de clase.
- El MLP es un tipo especial de red neuronal artificial (ANN sus siglas en inglés). Las ANNs se desarrollan para replicar el aprendizaje y la generalización de las capacidades de comportamiento de humano, en un intento de modelar las funciones de las redes neuronales biológicas del cerebro humano. Cada neurona artificial en el MLP calcula una función sigmoidea de la suma ponderada de todas sus entradas. Un MLP consta de una capa de entrada, una capa de salida y un número de capas ocultas o intermedias.
- El algoritmo de los k-vecinos más cercanos (kNN) es un método no paramétrico usado en clasificación y regresión. En la fase de entrenamiento se crean vectores en un espacio de características multidimensionales, cada uno con una etiqueta de clase. En la fase de clasificación, k es una constante, y dado un vector de entrada se clasificará mediante la asignación de la etiqueta que es más frecuente entre las muestras de entrenamiento k más cercanas a ese punto de consulta definido por el usuario.
- *Sequential minimal optimization* (SMO sus siglas en inglés) es un algoritmo para resolver el problema de programación cuadrática que surge durante el entrenamiento de las máquinas de vectores soporte (SVM sus siglas en inglés). SMO trocea el problema en una serie de pequeños posibles sub-problemas, que luego se resuelven analíticamente.

Clasificador	Parámetros
J48 (Decision Tree)	ConfidenceFactor, $C = [0,0,0,5]$ MinNumObj, $M = [1, 20]$ NumFolds, $N = [1, 20]$ BinarySplits, $B = \{True, False\}$ ErrorPruning, $R = \{True, False\}$ SubTreeRaising, $S = \{True, False\}$ Unpruned, $U = \{True, False\}$ UseLaplace, $A = \{True, False\}$
NB (Naive Bayes)	UseKernelStimator, $K = \{True, False\}$
MLP (Multilayer perceptron)	LearningRate, $L = [0,2,0,4]$ Momentum, $M = [0,2,0,3]$ TrainingTime, $N = [500, 1000]$ ValidationSetSite, $V = [0, 100]$ ValidationThreshold, $E = [1, 20]$ HiddenNeurons, $H = [2, 50]$
kNN (k-nearest neighbors search)	#Neighbours, $K = [1, 20]$ WindowsSize, $H = [0, 500]$ DistanceWeighting, $IorF = \{None, Inverse, Similarity\}$ MeanSquared, $E = \{True, False\}$ SearchAlgorithm, $A = \{LinearNNSearch, KDTree, CoverTree, BallTree\}$
SMO (support vector machine)	Complexity, $C = [0, 100]$ FilterType, $N = \{None, Normalize, Standarize\}$ Kernel, $W = \{NormalizedPolyKernel, PolyKernel, Puk, RBFKenel\}$

Tabla 2. Rangos de parámetros de los clasificadores que forman el ensemble.

Uno de los objetivos subyacentes de este trabajo es encontrar un conjunto mínimo de características discriminante que sea independiente del clasificador a utilizar. La optimización del error de un sólo clasificador sesgaría el conjunto de características obtenidas, pues dicho conjunto sólo sería efectivo y con capacidad para discernir diferentes manos con el clasificador utilizado en la optimización. Por tanto, el valor final a optimizar será la media del error de clasificación de todos los métodos. No utilizamos otra métrica diferente (mediana, etc.) porque el objetivo es que las características seleccionadas sean significativas para las tareas de clasificación con todos los métodos, lo que redundará en su robustez. Cada técnica contará con un conjunto de parámetros a especificar y cuyos valores se proporcionan en la Tabla 2. Estos parámetros también serán optimizados por el algoritmo multi-objetivo descrito a continuación.

4.2. Algoritmo de optimización

Esta sección está dedicada a introducir brevemente el algoritmo multiobjetivo paralelo utilizado tanto para la selección de características como para optimizar los parámetros de funcionamiento de los distintos clasificadores que componen el ensemble.

NSGA-II El algoritmo NSGA-II fue propuesto por Deb et al. en [2]. Se trata de un algoritmo genético generacional en el que, a partir de una población P , de tamaño n , genera otra población Q , también de tamaño n , mediante el uso de operadores genéticos (selección, cruce y mutación). Una vez que se ha generado Q , NSGA-II usa ranking

(medida de convergencia) y crowding (estimador de densidad) en el conjunto de soluciones formado por $P \cup Q$ para seleccionar las n mejores soluciones, que se incluyen de nuevo en P para proceder con la siguiente iteración.

Dadas las características del problema de optimización que se está abordando, se ha utilizado una representación *ad hoc* para las soluciones tentativas, que están compuestas por un array binario con las características seleccionadas, y un vector de números reales para los parámetros de los distintos clasificadores, cuyos rangos están definidos en la Tabla 2. De la misma forma, se han utilizado operadores de búsqueda evolutivos especializados de forma que, para la parte real de las soluciones, se utiliza *Simulated Binary Crossover* (SBX) y mutación polinomial y, para la parte binaria, se utiliza cruce de un punto (SPX) y mutación bit-flip. Las tasas de cruce (p_c) y mutación (p_m) se han fijado de forma independiente para las partes real y binaria. Así, $p_c^r = 0,9$ y $p_c^b = 0,6$, y $p_m^r = 1/L^r$ y $p_m^b = 5/L^b$, donde L^r y L^b son las longitudes de las partes reales y binarias.

Paralelización de NSGA-II En este trabajo se usa un esquema de paralelización basado en el paradigma maestro/esclavo en el que las soluciones tentativas, es decir, el número de características y la tasa de error del ensemble, se evalúa de forma remota. En concreto, se ha utilizado la versión generacional asíncrona, *NSGA-II^{asy}_{gen}*, presentada en [3] ya que es la más estándar, a la vez que paralela, de este algoritmo clásico. Su funcionamiento sigue el esquema generacional típico en el que, en cada iteración, se espera a que se complete una generación para proceder con la siguiente, pero se generan tantos individuos como esclavos hay en la plataforma paralela de cómputo. Análogamente, tan pronto llegan individuos suficientes para completar la población, se itera sin tener en cuenta si realmente esos individuos se han generado en la generación anterior o una previa (debido a la potencia de cómputo no homogénea en los esclavos).

Toda la lógica del proceso evolutivo (selección, cruce, y mutación) está implementada en el maestro, que usa hebras para manejar múltiples conexiones en paralelo con los esclavos de forma eficiente, y que posibilita la evaluación paralela de soluciones. Los esclavos, una vez se crean, quedan a la espera de recibir un ensemble; una vez que la hebra correspondiente en el maestro lo envía, la evalúa, y vuelve a empaquetarlo para enviarlo de vuelta al maestro.

Para desplegar NSGA-II en el cluster de 330 nodos se ha utilizado el sistema Condor [15], utilizando sólo aquellos procesadores que están ociosos, y que pertenecen a laboratorios de docencia del Departamento de Lenguajes y Ciencias de la Computación de la Universidad de Málaga. Es decir, podemos usar un sistema grid como plataforma de cómputo.

5. Resultados

En esta sección se detallarán los experimentos realizados sobre la base de datos de manos GPDS, que dispone de 50 individuos y 10 muestras para cada uno de ellos. En total, tendremos 500 imágenes que serán distribuidas en un esquema de validación cruzada con 5 iteraciones (*5 K-fold*) en dos niveles. En el primer nivel, se distribuirán los patrones en dos conjuntos: entrenamiento y validación en un conjunto y test o patrones

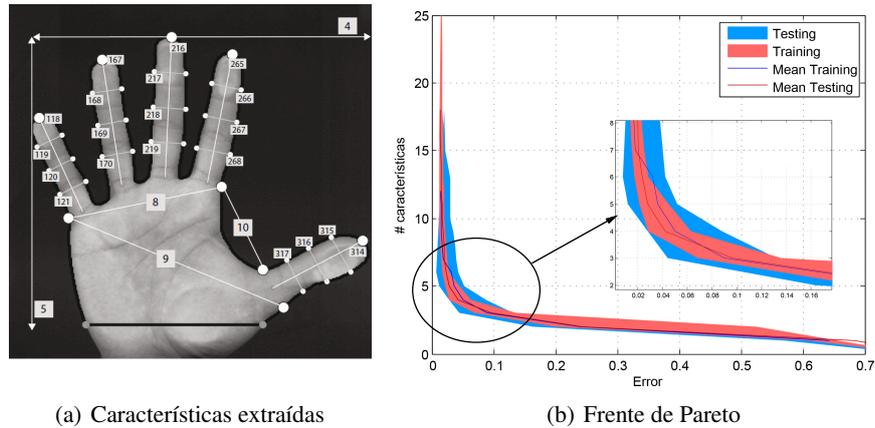


Figura 2. (a) Representación de algunas de las características extraídas. El significado puede observarse en la Tabla 1. (b) Dispersión y frentes de Pareto promedio para *training* y *testing*.

blind en otro. Este conjunto de test se utilizará al final del proceso para evaluar el poder de discriminación de las características seleccionadas y del *ensemble* de clasificadores. Nótese que este conjunto no se utilizará para la selección de características ni para la optimización de los parámetros de los clasificadores, con objeto de no sesgar los resultados. En el segundo nivel de validación cruzada (*5 K-fold*), se toma el conjunto de entrenamiento y validación (subconjunto de 400 imágenes) para aplicar el algoritmo multiobjetivo NSGA-II para la selección de las características de la mano más robustas y de los parámetros de los clasificadores. Los patrones de validación se utilizarán para guiar al algoritmo evolutivo en la minimización del error del *ensemble* de clasificadores propuesto. A la inversa del error en clasificación lo llamaremos precisión y se utilizará como medida de acierto en la Tabla 3.

		Entrenamiento			Test		
		<i>Eq.</i>	<i>Best Acc.</i>	<i>Best Feat.</i>	<i>Eq.</i>	<i>Best Acc.</i>	<i>Best Feat.</i>
Precisión	Ensemble	97.92±0.15	98.74±0.07	92.47±0.52	97.46±0.31	97.97±0.21	92.45±0.65
	J48	91.75±1.12	94.51±0.62	86.28±0.81	90.80±0.81	91.16±0.95	86.32±1.93
	NaiveBayes	98.81±0.23	99.77±0.14	93.68±0.59	98.72±0.64	99.84±0.09	94.40±0.81
	MLP	99.48±0.18	99.84±0.07	93.39±0.67	99.00±0.32	99.68±0.18	93.44±1.01
	kNN	99.73±0.22	99.65±0.20	94.27±1.10	99.20±0.14	99.40±0.20	93.24±1.24
	SMO	99.82±0.08	99.93±0.06	94.74±0.88	99.60±0.28	99.76±0.22	94.84±0.99
# Características		6.28±0.58	17.48±1.58	3.44±0.17	6.28±0.58	17.48±1.58	3.44±0.17

Tabla 3. Resultados de los dos objetivos definidos: precisión del *ensemble* de clasificadores y número de características obtenido (representados como media ± desviación típica). Los valores se muestran tanto para entrenamiento como para test, en función del tipo de individuo elegido: equilibrado (*Eq.*), mejor individuo en precisión (*Best Acc.*) y mejor individuo en número de características (*Best Feat.*).

Tras la ejecución de la propuesta contaremos con 25 frentes de Pareto diferentes (5 *k-fold* por 5 *k-fold*), cuya información se agrega usando *attainment functions* o funciones de consecución. Así, las superficies incluidas en la Fig. 2(b) muestran la dispersión de los frentes en *testing* y *training* (área comprendida entre las funciones de consecución al 5% y 95%, i.e., lo que se podría considerar los percentiles 5 y 95). Estas superficies muestran claramente que hay un sobreajuste en *training* que, al movernos a *testing*, hace que los frentes tengan más dispersión. Esto es especialmente notable en la zona de interés con bajo error y bajo número de características. La figura también incluye la función de consecución al 50%, que viene a ser como el "frente de Pareto promedio" que se cubre en las 25 ejecuciones realizadas. De esta parte queremos resaltar la parte ampliada, que se corresponde con la rodilla del frente o zona del mismo con las mejores soluciones de compromiso entre ambas funciones objetivo. Se puede observar que con valores de error por debajo de 0.02, en la parte superior izquierda de la ampliación, el frente en *testing* incluso supera (domina) al de *training*. Eso quiere decir que se está generalizando bastante bien con el conjunto de características y la parametrización de los clasificadores alcanzada. Hay, no obstante, una zona con un error de clasificación entre 0.02 y 0.07 en el que el frente promedio en *testing* es algo peor, lo que se puede justificar por algo de sobreentrenamiento que, en cualquier caso, es mínimo. A partir de un error superior a 0.07, el frente promedio en *testing* siempre es ligeramente mejor (domina) al de *training*.

La Tabla 3 muestra los valores obtenidos por cada uno de los objetivos a optimizar, a saber, la minimización del error (o maximización de la precisión), de la tercera fila a la octava, y el número de rasgos de la mano, en la novena fila. La precisión en clasificación se muestra para el *ensemble* y para cada uno de los clasificadores utilizados de forma individual. Los valores de los objetivos se dividen en entrenamiento y test, observándose que no se produce un sobreentrenamiento excesivo al aplicar esta metodología. Tanto los rasgos de la mano seleccionados como los parámetros de cada clasificador que se obtienen en el entrenamiento se conservan para la fase de test (ver fila novena de la Tabla 3). Debido a que el frente de Pareto genera un gran número de individuos óptimos, en este trabajo seleccionaremos tres de ellos: el individuo más equilibrado (columna *Eq.*), que se corresponde con el punto no dominado del frente de Pareto más cercano al origen (0,0) en función del error en clasificación y el número de características; el mejor individuo asociado al objetivo del error en clasificación (columna *Best Acc.*), con la restricción de que el número de características sea menor que 30; y el mejor individuo asociado al objetivo del número de características (columna *Best Feat.*), con la restricción de que la precisión sea mayor del 90%.

Así, se observa que si queremos un *ensemble* de clasificación con error muy bajo necesitaremos un mayor número de características mientras que si nuestra premisa es reducir el número de características, el error en clasificación se elevará ligeramente. Nótese que, en general y salvo para el clasificador J48, el error de clasificación utilizando el *ensemble* es superior al error obtenido clasificando con un método concreto. De hecho, si optimizáramos el error de clasificación de un sólo método obtendríamos mejores resultados de precisión, pero la importancia de las características obtenidas estaría más sesgada a ese clasificador en concreto. El hecho de usar el *ensemble* radica en descubrir descriptores universales con alto poder de predicción y discriminación, y que

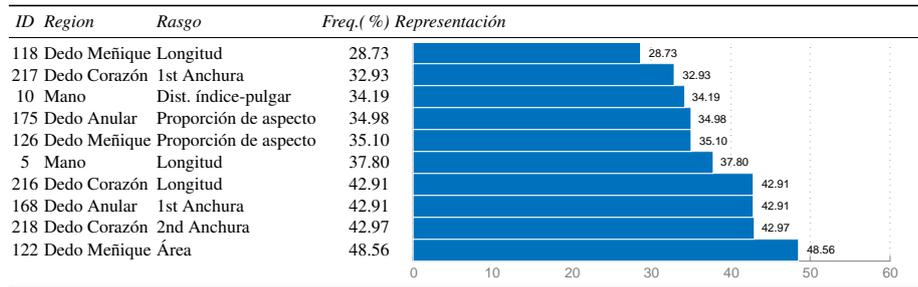


Tabla 4. Los diez rasgos más seleccionados para la base de datos GPDS. La frecuencia de selección de la característica es representada por una barra horizontal. De las columnas uno a la tres se muestran el identificador, la región de la mano y el nombre de la característica.

sean independientes del clasificador utilizado. Conocer que estas características seleccionadas son buenas para tareas de clasificación con todos los clasificadores, reafirma su importancia como descriptor biométrico con alto poder de independencia de la metodología utilizada. En la Tabla 4 se muestran las características más seleccionadas por los mejores individuos generados por el algoritmo de optimización. Nótese que todas son medidas geométricas básicas y que los dedos meñique y corazón tienen bastante relevancia como descriptores para esta base de datos.

6. Conclusiones

En este trabajo hemos propuesto una metodología para la selección de características robustas de la palma de la mano con objeto de mejorar los sistemas de identificación biométrica. Dicha metodología está basada en metaheurísticas multi-objetivo paralelas, que tratan de minimizar el número de rasgos de la palma de la mano y el error de clasificación de un ensemble de clasificadores. Los resultados obtenidos son reveladores, reduciendo de 362 características a una media de 7 rasgos con tasas de acierto en clasificación cercanas al 98 %, y obteniendo un conjunto de clasificadores optimizados que servirán para la identificación biométrica de nuevos usuarios.

Cabe señalar que todos los experimentos han sido llevado a cabo utilizando el conjunto de datos GPDS. De hecho, la realización de un análisis más profundo y con más conjuntos de datos sería interesante para justificar la elección de un subconjunto de características estándar que sea independiente no sólo de los clasificadores utilizados, sino también de las imágenes analizadas. Otro trabajo futuro de interés sería el estudio de los valores paramétricos más seleccionados por cada clasificador, con objeto de acotar el rango y analizar las combinaciones paramétricas más relevantes.

Agradecimientos. Este trabajo ha sido parcialmente financiado por el Gobierno de Extremadura y el Fondo Europeo de Desarrollo Regional (FEDER) bajo el proyecto IB13113, y por la Diputación de Cáceres bajo el proyecto ACCION VII-14.

Referencias

1. Amayeh, G., Bebis, G., Erol, A., Nicolescu, M.: Hand-based verification and identification using palm-finger segmentation and fusion. *Computer Vision and Image Understanding* 113(4), 477–501 (2009)
2. Deb, K., Pratap, A., Agarwal, S., Meyarivan, T.: A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation* 6(2), 182–197 (2002)
3. Durillo, J.J., Nebro, A.J., Luna, F., Alba, E.: A study of master-slave approaches to parallelize NSGA-II. In: *Int. Parallel and Distributed Processing Symp, NIDISC'08*. pp. 1–8 (2008)
4. Faundez-Zanuy, M., Elizondo, D., Ferrer-Ballester, M.Á., Travieso-González, C.: Authentication of individuals using hand geometry biometrics: A neural network approach. *Neural Processing Letters* 26, 201–216 (2007)
5. Ferrer, M., Morales, A., Travieso, C., Alonso, J.: Low cost multimodal biometric identification system based on hand geometry, palm and finger print texture. In: *41st Annual IEEE International Carnahan Conference on Security Technology*. pp. 52–58 (2007)
6. Ferrer, M., Vargas, F., Morales, A.: Bispectral contactless hand based biometric system. In: *2nd National Conference on Telecommunications (CONATEL)*. pp. 1–6 (2011)
7. Guyon, I., Elisseeff, A.: An introduction to variable and feature selection. *Journal of Machine Learning Research* 3, 1157–1182 (2003)
8. Jain, A., Duta, N.: Deformable matching of hand shapes for user verification. In: *International Conference on Image Processing, ICIP*. vol. 2, pp. 857–861 (1999)
9. Jain, A., Ross, A., Prabhakar, S.: An introduction to biometric recognition. *IEEE Transactions on Circuits and Systems for Video Technology* 14(1), 4–20 (2004)
10. Kumar, A., Zhou, Y.: Human identification using finger images. *IEEE Transactions on Image Processing* 21(4), 2228–2244 (2012)
11. Liao, S.X., Pawlak, M.: On image analysis by moments. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 18(3), 254–266 (1996)
12. Luque, R., Elizondo, D., López-Rubio, E., Palomo, E.: Feature selection of hand biometrical traits based on computational intelligence techniques. In: *Computational Intelligence for Privacy and Security*. *Studies in Computational Intelligence*, vol. 394, pp. 159–180 (2012)
13. Otsu, N.: A Threshold Selection Method from Gray-level Histograms. *IEEE Transactions on Systems, Man and Cybernetics* 9(1), 62–66 (1979)
14. de Santos Sierra, A., Avila, C., Bailador del Pozo, G., Guerra Casanova, J.: Gaussian multiscale aggregation oriented to hand biometric segmentation in mobile devices. In: *Third World Congress on Nature and Biologically Inspired Computing (NaBIC)*. pp. 237–242 (2011)
15. Thain, D., Tannenbaum, T., Livny, M.: Condor and the Grid. In: Berman, F., Fox, G., Hey, T. (eds.) *Grid Computing: Making the Global Infrastructure a Reality*. John Wiley & Sons Inc. (December 2002)