

Tipo de artículo: Artículo original
Temática: Procesamiento de imágenes
Recibido: 15/12/2021 | Aceptado: 17/02/2022

Estrategias de fusión para la clasificación automática de imágenes de úlceras de pie diabético usando técnicas de visión por computadora

Fusion Strategies to Automatically Classify Diabetic Foot Ulcer Images using Computer Vision Techniques

José Daniel López-Cabrera^{1*}, <https://orcid.org/0000-0003-2137-0361>

Yusely Ruiz-Gonzalez¹, <http://orcid.org/0000-0002-6011-1947>

Roberto Díaz-Amador¹, <http://orcid.org/0000-0002-4289-9638>

Alberto Taboada-Crispi¹, <https://orcid.org/0000-0002-7797-1441>

¹ Universidad Central “Marta Abreu” de Las Villas. 54830. josedaniellc@uclv.cu,
 {yuselyr,rdamador,ataboada}@uclv.edu.cu

*Autor para la correspondencia. (josedaniellc@uclv.cu)

RESUMEN

Las úlceras de pie diabético constituyen una de las complicaciones graves que presentan los pacientes diabéticos. El seguimiento e identificación de las lesiones es de vital importancia para aplicar un tratamiento oportuno pues mal atendidas pueden conducir a la amputación del miembro del paciente e incluso provocar su muerte. Este estudio tiene como objetivo evaluar distintas estrategias de fusión para mejorar los índices de desempeño en la tarea de clasificación de imágenes de úlceras de pie diabética. Se evaluaron dos

enfoques de fusión, a nivel de rasgos y a nivel de decisión. Asimismo, se utilizaron dos técnicas de selección de rasgos, ReliefF y MRMR. Se utilizó un clasificador SVM con tres tipos de kernel y se combinaron a partir de cinco funciones de agregación utilizando los cinco mejores clasificadores. Los mejores resultados se obtuvieron usando la estrategia de fusión a nivel de rasgos. Estos a su vez provienen del uso de clasificadores que usaron la estrategia de fusión a nivel de rasgos y usando técnicas de selección de rasgos. Los resultados alcanzados superan a los reportados en la literatura. Ambas alternativas de fusión unidas a los métodos de selección de rasgos mejoraron la clasificación automática de imágenes de úlceras de pie diabético.

Palabras clave: Visión por computadora; Reconocimiento de patrones; Úlceras de pie diabético.

ABSTRACT

Diabetic foot ulcers are one of the serious complications presented by diabetic patients. The follow-up and identification of the lesions is of vital importance in order to apply a timely treatment because if they are poorly treated, they can lead to the amputation of the limb of the patient and even cause death. This study aims to evaluate different fusion strategies to improve performance rates in the diabetic foot ulcer image classification task. Two fusion approaches are evaluated, at the feature level and at the decision level. Also, two feature selection techniques, ReliefF and MRMR, were used. An SVM classifier with three kernel types was used and combined from five aggregation functions using the best five classifiers. The best results were obtained using the feature-level fusion strategy. These in turn come from the use of classifiers using the feature-level fusion strategy and using feature selection techniques. The results achieved exceed those reported in the literature. Both fusion alternatives coupled with feature selection methods improved automatic classification of diabetic foot ulcer images.

Keywords: Computer Vision; Pattern Recognition; Diabetic Foot Ulcers.

Introducción

La diabetes es una enfermedad crónica que afecta actualmente a más de 425 millones de personas a nivel mundial y se prevé que este número aumente considerablemente en los próximos 25 años (Cho et al., 2018). La enfermedad se debe a problemas en el páncreas para sintetizar la insulina necesaria que el cuerpo necesita, lo que provoca un gran número de complicaciones en los pacientes. Una de las complicaciones más graves es la úlcera del pie diabético (DFU) (Armstrong, Boulton y Bus 2017). La DFU se caracteriza por una disfunción celular y un desequilibrio bioquímico, cuya principal manifestación es el retraso del proceso de cicatrización. Esto puede dar lugar a infección e isquemia, pudiendo provocar la amputación de la extremidad donde se encuentra la lesión, y en los casos más graves conducen incluso a la muerte del paciente.

En la actualidad se trabaja para mejorar la atención a los pacientes y reducir la presión sobre los sistemas sanitarios. Para ello, la detección temprana de las DFU y el seguimiento regular constituyen una tarea primordial. Dentro de las estrategias utilizadas para estos fines aparece una basada en técnicas de visión por computadora. Las investigaciones recientes se han centrado en la creación de algoritmos de detección que podrían utilizarse como parte de una aplicación móvil que capacite a los propios pacientes o a un cuidador/pareja en este sentido (Goyal et al., 2019). Estas técnicas han sentado las bases para crear los primeros conjuntos de imágenes de paciente con DFU a ser usados en tareas de visión por computadora. Los principales esfuerzos se han realizado en la identificación de las lesiones y la segmentación de las mismas, sobre todo a partir del DFU Challenge 2020 (Cassidy et al., 2021; Yap et al., 2020).

Por otro lado, el tema de la clasificación automática de estas imágenes ha sido menos abordado, razón por la cual se lanza el reto DFUC2021^a. Es decir, solo se reportan escasos trabajos que realizan clasificación de las lesiones de DFU. Por ejemplo, en el trabajo de (Goyal, Reeves, Davison, et al., 2020) se propone una nueva arquitectura de CNN para abordar un problema de clasificación binaria de las lesiones en normal y anormal. Se compararon además otras CNN pre-entrenadas como LeNet, AlexNet, GoogleNet así como otras variantes de métodos de extracción de rasgos como Local Binary Pattern (LBP), Histogram of Oriented Gradient (HOG) y basados en color usando los espacios RGB, HSV y LUV. Por otro lado, en (Goyal, Reeves, Rajbhandari, et al., 2020) es la primera vez que se intenta clasificar en isquemia e

infección, pero en tareas disjuntas. Es decir, se evalúan dos tareas de clasificación automática binarias. Para ello se utilizó un nuevo descriptor basado en el color de las imágenes luego de aplicar una segmentación usando SLIC Superpixel. Además, se utilizaron rasgos basados en textura como LBP y HOG, así como rasgos basados en el color en los espacios RGB y CIELAB. También se evaluaron distintas arquitecturas de redes neuronales de convolución (CNN) como InceptionV3, ResNet50 e InceptionResNetV2. Los mejores resultados se alcanzaron usando la combinación de las CNN. Recientemente en (Yap et al., 2021), por primera vez se realiza la clasificación como un problema multiclase. Las clases fueron infección, isquemia, ambas y nada. Este problema se abordó utilizando solamente el enfoque de aprendizaje profundo. Para ellos se evaluaron las redes VGG16, ResNet101, InceptionV3, DenseNet121 y EfficientNet. Los mejores resultados se alcanzaron para las dos últimas redes antes mencionadas utilizando técnicas de aumento de datos. Se reporta un macroF1score de 0.55, una precisión de 0.57 y una sensibilidad de 0.58. Más recientemente en el trabajo de (López-Cabrera et al., 2021) se obtuvieron mejores resultados. En dicho estudio se exploraron distintas estrategias de extracción de rasgos, basadas en color, basadas en el descriptor SURF (Bay, Tuytelaars y Van Gool 2006) y usando la red DenseNet201 como método de extracción de rasgos. Se reportó un macroF1score máximo de 0.681 para un clasificador SVM.

Tomando como referencia el trabajo de (López-Cabrera et al., 2021) en el cual se analizó el papel que juegan por separado las distintas estrategias de extracción de rasgos en la tarea de clasificación. En este artículo, se explora la combinación de estas estrategias de extracción de rasgos para la clasificación automática en cuatro clases de imágenes de DFU. Se investigan la fusión a nivel de rasgos y a nivel de decisión. La fusión a nivel de rasgos combina diferentes vectores de rasgos en un único vector de rasgos. Por otro lado, la fusión a nivel de decisión se realiza sobre los resultados probabilísticos de cada proceso de clasificación individual y combina las distintas decisiones en una final. Asimismo, se exploran dos estrategias de selección de rasgos para obtener aquellos que arrojen los mejores resultados. Según nuestro conocimiento este es el primer estudio que reporta la combinación a distintos niveles, como métodos para la clasificación de imágenes DFU. De esta manera, los resultados obtenidos sobrepasan los reportados en la literatura.

Materiales y Métodos

Conjunto de imágenes usados

Las imágenes usadas en esta investigación son fotografías recopiladas de los Hospitales Docentes de Lancashire, Reino Unido y pertenecen a pacientes con DFU. Una descripción más detallada sobre el conjunto aparece en (Yap et al., 2021). A partir de la imagen original se extraen las regiones de interés (ROIs) que se corresponden con las lesiones encontradas. En el propio proceso de extracción de las ROIs se realiza un aumento natural del conjunto de imágenes. Este proceso consistió en recortar las imágenes en distintos tamaños. Finalmente, todas las imágenes fueron redimensionadas a 224x224x3 píxeles. Este conjunto de imágenes pertenece a DFUC2021. Es importante señalar que, en esta investigación solamente se utilizará una porción del conjunto de entrenamiento proporcionado para el DFUC2021, pues hasta el momento este conjunto es el único que contiene la clase a la que pertenece cada imagen. Es decir, el conjunto de validación y prueba aún no ha sido liberado. La Tabla 1 muestra el contenido del conjunto de imágenes utilizado en este trabajo. Se dividió aleatoriamente las imágenes por clase en aproximadamente un 80% para el entrenamiento y un 20% para la prueba. De esta forma, se utilizó como hold out estrategia para la evaluación de los clasificadores. El conjunto de imágenes contiene las mismas particiones que las utilizadas en (López-Cabrera et al., 2021).

Tabla 1- Descripción de los conjuntos por clase usados en el entrenamiento y prueba.

	clases				Total de imágenes
	ambas	infección	isquemia	normal	
Conjunto de entrenamiento	267	1036	98	792	2193
Conjunto de prueba	69	262	29	201	561

Técnicas de extracción y codificación de rasgos

En este estudio se utilizan tres estrategias para la extracción de rasgos, las cuales coinciden con el trabajo de (López-Cabrera et al., 2021). La primera se basa en el color, pues en los trabajos de (Goyal, Reeves, Rajbhandari, et al., 2020; Goyal, Reeves, Davison, et al., 2020) se han usado con éxito variantes de conversión entre espacios de color como rasgos para realizar la clasificación. La segunda variante se basa en la extracción de rasgos locales. Para ello se utilizó el método SURF (Bay, Tuytelaars y Van Gool, 2006), el cual es uno de las más ampliamente usado en tareas de clasificación de imágenes (Arora et al., 2020). Estas dos primeras variantes se basan en rasgos diseñados a mano (handcrafted), mientras la tercera variante se basa en la CNN, DenseNet201 (Huang et al., 2019).

Las dos primeras variantes de extracción de rasgos poseen alta dimensionalidad. Una de las técnicas para abordar este problema que ha mostrado aumentar los índices de desempeño en las tareas de visión por computadora es Bag of Word (BoW) (Fei-Fei, Fergus y Perona, 2006). En este estudio se utilizó un vocabulario visual de 1000 palabras, el cual arrojó los mejores resultados luego de un pequeño experimento variando las palabras entre 500 y 1500.

Algoritmos de clasificación y medidas de desempeño.

En la etapa final de este estudio se realiza la clasificación automática de las imágenes. Para ello se evalúan tres variantes del clasificador SVM los cuales han mostrado buenos resultados en tareas genéricas de clasificación (López-Cabrera y Pereira-Toledo, 2018), así como en tareas similares de clasificación de imágenes de DFU (López-Cabrera et al., 2021). Es decir, se utilizaron tres kernel, el cuadrático, el gaussiano y el lineal.

El conjunto de imágenes que se utiliza en la investigación tanto para entrenamiento como para validación, está desbalanceado. Por tanto, para determinar la efectividad de los clasificadores se deben usar medidas de

desempeño que tengan en cuenta este problema y poder realizar un análisis por clases. En aras de comparar nuestros resultados con los obtenidos en (Yap et al., 2021; López-Cabrera et al., 2021), se decidió utilizar algunas de las mismas medidas usadas en estos estudio. Por tanto, se utilizó el F1score por clase, así como su promedio, llamado macroF1score. Además, se utiliza el macroAccuracy como métrica global.

Estrategias de fusión y métodos de selección de rasgos

En este estudio se investigan dos estrategias de fusión, a nivel de rasgos y a nivel de decisión. La primera variante de fusión es una de las más usadas en tareas de clasificación de imágenes (Pereira et al., 2020). Esta consiste en agrupar diferentes técnicas de extracción de rasgos en un solo conjunto, el cual se utiliza como entrada a un algoritmo de clasificación. Sin embargo, esta estrategia puede presentar como desventaja que al combinar múltiples conjuntos de distinta naturaleza (color, textura, etc) se presenten incompatibilidades al generar un espacio de rasgos altamente no lineal., Asimismo, al realizar la unión de varios conjuntos de rasgos, el conjunto final aumenta su cardinalidad. La alta dimensionalidad en los conjuntos de rasgos deteriora la efectividad de los clasificadores (Keogh y Mueen, 2017), así como eleva el costo computacional del mismo en la etapa de entrenamiento.

Para contrarrestar este efecto, se analiza el efecto de dos métodos de selección de rasgos (FSM). Estos métodos pretenden de forma general, seleccionar un subconjunto de los rasgos pertenecientes al conjunto original, que logre el máximo rendimiento con el mínimo esfuerzo en las tareas de clasificación. Uno de los principales problemas al aplicar FSM es seleccionar un método apropiado para un problema dado. Cada FSM tiene sus fortalezas y debilidades, siendo su desempeño dependiente de los datos y de restricciones propias relacionadas con el escenario donde serán usados (exactitud, tiempo, costo). No obstante, a pesar de la disponibilidad y el incremento de estos métodos, los investigadores concuerdan que no existe uno ideal para todos los escenarios. Por tanto, en este estudio se seleccionan dos de los métodos que reportan muy buenos resultados en la literatura científica (Bolón-Canedo y Remeseiro, 2019).

El primer FSM usado fue ReliefF (Kononenko, 1994). Este evalúa la calidad del atributo muestreando repetidamente casos y determinando el valor del atributo dado usando los vecinos más cercanos de su clase y de otras clases. A partir de esto se le asigna un peso a cada rasgo. De esta forma, un rasgo útil debe diferenciar entre casos de diferentes clases y tener valores similares para casos de la misma clase. La segunda variante de FSM fue MRMR (Minimum Redundancy Maximum Relevance) (Peng, Long y Ding, 2005). El método se basa seleccionar rasgos que tengan alta relevancia con respecto a su clase y sean mínimamente redundantes. Se seleccionan los rasgos que sean lo más disimilares posible entre ellos. Para realizar la optimización del conjunto con máxima relevancia y mínima redundancia se utiliza información mutua.

Ambos FSM devuelven un peso para cada rasgo, que indica su relevancia. Es decir, los rasgos aparecen ordenados en dependencia del criterio utilizado. Por tanto, es necesario establecer un umbral para determinar la cardinalidad del conjunto final., Encontrar este valor no es trivial y varias han sido las heurísticas estudiadas por distintos autores que abordan el tema, sin que exista un consenso (Bolón-Canedo y Alonso-Betanzos 2018). Por tanto, en este estudio se evaluarán conjuntos de rasgos que incrementen su cardinalidad de 100 en 100.

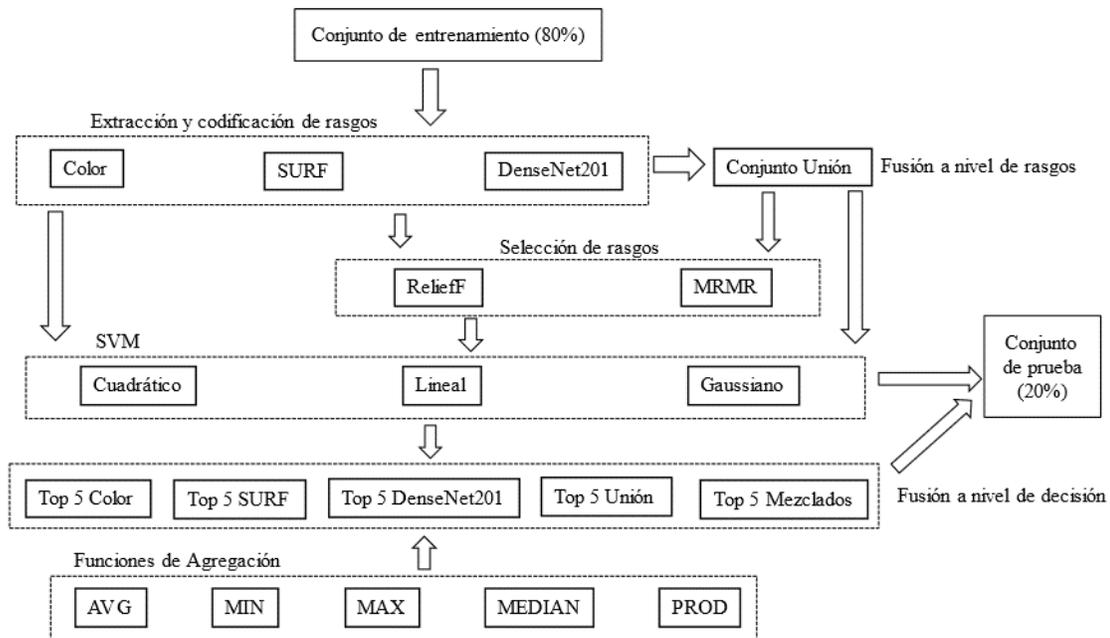


Fig. 1- Estrategia de reconocimiento de patrones seguida en la investigación.

Por otro lado, la fusión a nivel de decisión se realiza sobre los resultados probabilísticos de cada proceso de clasificación individual y combina las distintas decisiones en una final (Snoek, Worring y Smeulders 2005). Esta estrategia puede lograr resultados prometedores en escenarios en los que hay complementariedad entre las salidas (Kittler et al., 1998). En estos casos, los clasificadores no hacen la misma clasificación errónea y, por lo tanto, cuando se combinan, pueden ayudarse mutuamente para mejorar la predicción. En este estudio se hace uso de cinco funciones de agregación simple, ampliamente utilizadas en la literatura científica (Kuncheva 2014). Estas fueron, promedio (AVG), mínimo (MIN), máximo (MAX), mediana (MED) y producto (PROD). El cálculo de estas medidas se realiza a partir de los valores de probabilidad a posteriori que devuelven los clasificadores y que se interpretan como la pertenencia de una imagen a una clase. El proceso general de la estrategia de reconocimiento de patrones seguida en la investigación aparece en la figura 1.

Resultados y discusión

En esta sección se presentan los resultados alcanzados para las mejores variantes de métodos de extracción de rasgos.

Rasgos basados en CNN

La Figura 2 presenta los resultados obtenidos usando como método de extracción de rasgos a DenseNet201. Esta red devuelve un total de 1920 rasgos. En el eje de las abscisas se muestra el número de rasgos usados para realizar la clasificación. Los mejores resultados se obtienen para el conjunto de 800 rasgos seleccionados por ReliefF y usando el kernel Gaussiano con 0.7314 de macroF1score. Por otro lado, al usar el FSM MRMR se alcanzan también mejores resultados que al usar el conjunto completo de rasgos. Para este FSM el mejor valor de macroF1score aparece para el clasificador SVM Gaussiano con 0.7221 con 500 rasgos.

Fusión a nivel de rasgos

En esta etapa se realiza la unión de los conjuntos de rasgos. Ahora se cuenta con un nuevo conjunto de rasgos que posee 3920 rasgos. De ellos 1000 pertenecen a los rasgos de color, 1000 a los rasgos SURF y 1920 a los rasgos de DenseNet201. La Figura 3 presenta los índices de desempeños alcanzados para los tres clasificadores al realizar la selección de los mejores rasgos usando las dos variantes de FSM. El mejor valor de macroF1score fue de 0.7326 usando el FSM ReliefF y el clasificador SVM con kernel Cuadrático con 3400 rasgos. Nótese que para el clasificador SVM Gaussiano aparecen conjuntos de rasgos para los cuales está indefinida la medida macroF1score (espacios en blanco en la Figura 3). Esto se debe a que la medida F1score se indefine, al tener en el denominador a precision y recall.

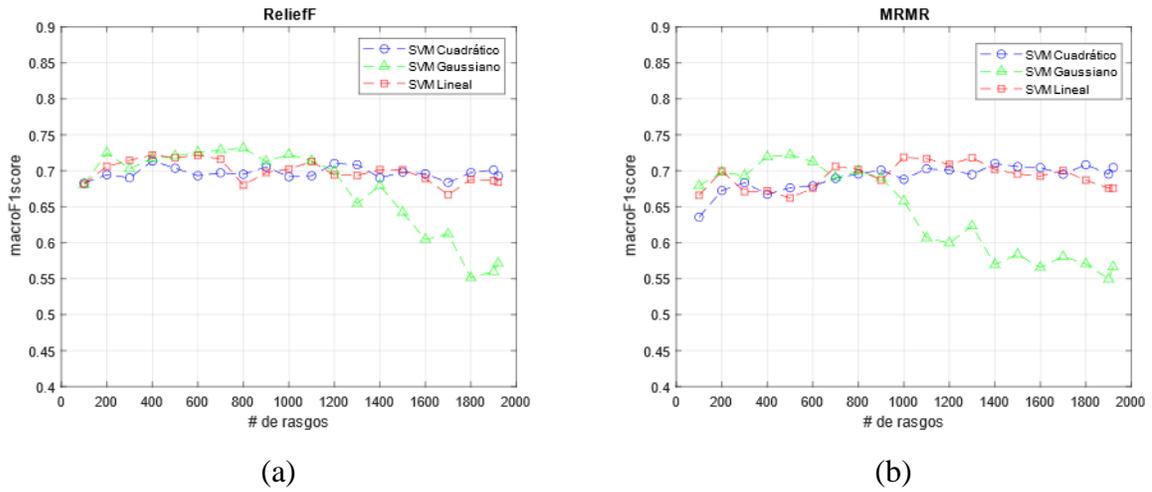


Fig. 2- Resultados para las tres variantes de SVM usando conjuntos de rasgos basados en DenseNet201. En (a) utilizando el FSM ReliefF y en (b) MRMR.

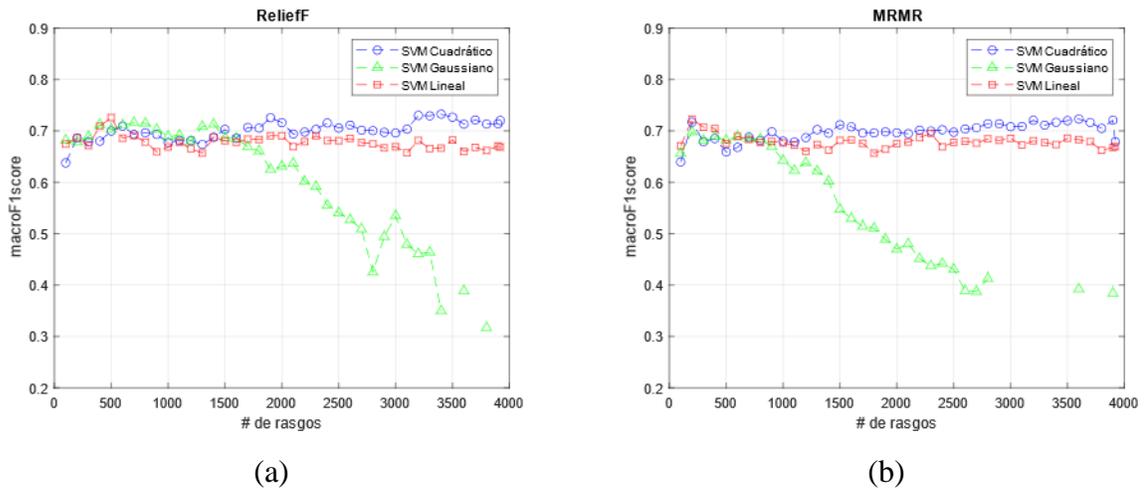


Fig. 3 - Resultados para las tres variantes de SVM usando conjuntos de rasgos basados en la unión de los rasgos de color, SURF y DenseNet201. En (a) utilizando el FSM ReliefF y en (b) MRMR.

Fusión a nivel de decisión

La Tabla 2 presenta los resultados alcanzados para las distintas estrategias de fusión a nivel de decisión. En esta etapa se seleccionaron los 5 mejores clasificadores para cada una de las distintas estrategias de evaluadas en las secciones anteriores, usando como medida el macroF1score.

Tabla 2- Resultados alcanzados para las distintas estrategias de fusión a nivel de clasificación.

Estrategia de selección de rasgos	Función de agregación	F1score por clases				macroF1score	macroAcc
		ambas	infección	isquemia	normal		
Top 5 color	AVG	0.4928	0.6219	0.6552	0.5056	0.5688	0.5681
	MIN	0.4507	0.6143	0.6786	0.4843	0.557	0.5534
	MAX	0.48	0.6022	0.623	0.4816	0.5467	0.5603
	MEDIAN	0.4857	0.6256	0.6667	0.4824	0.5651	0.5636
	PROD	0.5072	0.6186	0.6667	0.4972	0.5724	0.5692
Top 5 SURF	AVG	0.0851	0.6072	0.3889	0.4759	0.3893	0.3644
	MIN	0.0879	0.6038	0.3333	0.4791	0.376	0.3564
	MAX	0.098	0.6166	0.3158	0.542	0.3931	0.3746
	MEDIAN	0.1031	0.6139	0.3889	0.5098	0.4039	0.3768
	PROD	0.086	0.6063	0.3889	0.4759	0.3893	0.3644
Top 5 DenseNet201	AVG	0.7564	0.7486	0.7018	0.6648	0.7179	0.7313
	MIN	0.7468	0.7481	0.7143	0.6793	0.7222	0.7344
	MAX	0.7564	0.7519	0.7018	0.6775	0.7219	0.7354
	MEDIAN	0.7564	0.7661	0.7018	0.6831	0.7268	0.7401
	PROD	0.7564	0.7486	0.7018	0.6648	0.7179	0.7313
Top 5 unión	AVG	0.7755	0.7491	0.7869	0.6648	0.7441	0.7605
	MIN	0.7862	0.7478	0.8	0.648	0.7455	0.7571
	MAX	0.7808	0.7518	0.8	0.6556	0.747	0.7596
	MEDIAN	0.7397	0.7445	0.7931	0.6703	0.7369	0.7428
	PROD	0.7671	0.7491	0.7869	0.6685	0.7429	0.7581
Top 5 mezclados	AVG	0.7333	0.7532	0.7797	0.6648	0.7327	0.745
	MIN	0.6479	0.7513	0.6182	0.6433	0.6652	0.659
	MAX	0.6849	0.7434	0.8065	0.6476	0.7206	0.7376
	MEDIAN	0.7552	0.7684	0.7797	0.6832	0.7466	0.7524
	PROD	0.7383	0.7504	0.7797	0.6555	0.731	0.7425

Desde el punto de vista de los tipos de rasgos usados se observa que los de mejores resultados se reportan en este orden, Top 5 unión, Top 5 mezclados, Top 5 DenseNet201, Top 5 color y Top 5 SURF (ver Figura 4).

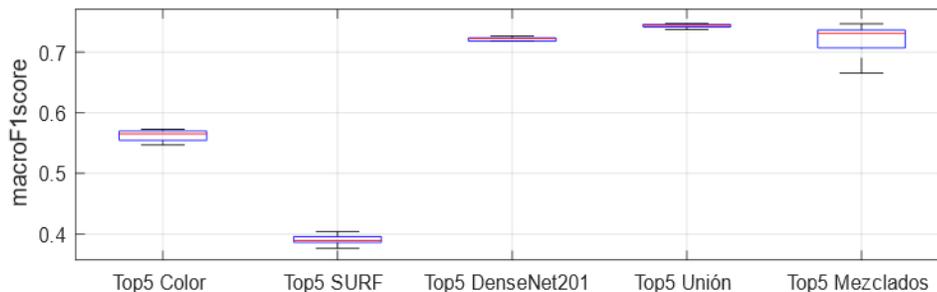


Fig. 4 - Resultados de la clasificación a nivel de decisión para las cinco variantes de función de agregación y separados por los conjuntos de rasgos usados.

Comparación con los métodos reportados en la literatura

La Figura 5 presenta una comparación con los trabajos reportados en la literatura (López-Cabrera et al., 2021; Yap et al., 2021) y la mejor variante reportada en esta investigación. Se aprecia que, el método propuesto supera tanto en F1score por clases como en macroF1score a los resultados reportados en trabajos anteriores. Esto demuestra que la combinación de la estrategia de fusión a nivel de rasgos y luego a nivel de decisión dotan a este modelo de mejor desempeño en la tarea de clasificación automática de imágenes DFU.

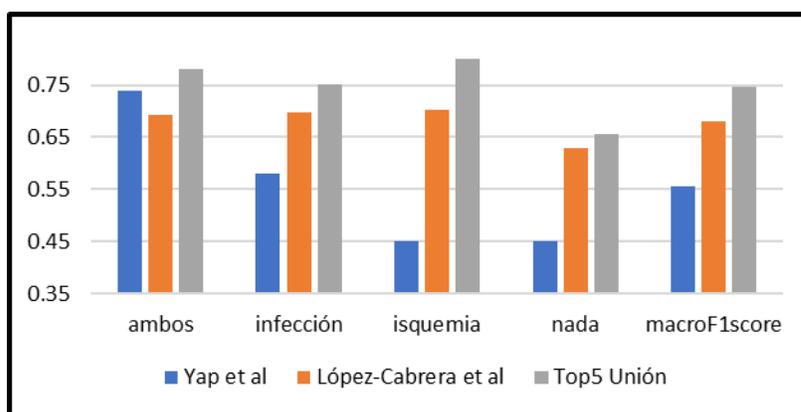


Fig. 5 - Comparación de trabajos existentes en la clasificación de imágenes DFU con la mejor variante obtenida en esta investigación.

Conclusiones

En este estudio se realizó el análisis de varias estrategias de fusión de rasgos para aumentar los índices de desempeño en la clasificación automática de imágenes DFU. Se demostró que el uso de los FSM en todos los casos aumentó el desempeño de los clasificadores. Asimismo, la estrategia de fusión a nivel de rasgos logró aumentar los índices de desempeño comparada con las estrategias individuales y combinadas con los FSM. Por otro lado, los mejores resultados se obtuvieron para la estrategia de fusión a nivel de decisión. Específicamente la combinación de clasificadores basados en la estrategia de fusión a nivel de rasgos fue la de mejores resultados. Este resultado sobrepasa los resultados reportados hasta el momento en tareas similares a esta.

Referencias

- Armstrong, D.G., Boulton, A.J.M. Y Bus, S.A., 2017. Diabetic Foot Ulcers And Their Recurrence. *New England Journal Of Medicine*, Vol. 376, No. 24, Pp. 2367-2375. Issn 0028-4793. Doi 10.1056/Nejmra1615439.
- Arora, G., Dubey, A.K., Jaffery, Z.A. Y Rocha, A., 2020. Bag Of Feature And Support Vector Machine Based Early Diagnosis Of Skin Cancer. *Neural Computing And Applications* [En Línea], [Consulta: 14 Junio 2021]. Issn 1433-3058. Doi 10.1007/S00521-020-05212-Y. Disponible En: <https://doi.org/10.1007/S00521-020-05212-Y>.
- Bay, H., Tuytelaars, T. Y Van Gool, L., 2006. Surf: Speeded Up Robust Features. En: A. Leonardis, H. Bischof Y A. Pinz (Eds.), *Computer Vision – Eccv 2006*. Berlin, Heidelberg: Springer, Pp. 404-417. Isbn 978-3-540-33833-8. Doi 10.1007/11744023_32.
- Bolón-Canedo, V. Y Alonso-Betanzos, A., 2018. Feature Selection. *Recent Advances In Ensembles For Feature Selection* [En Línea]. S.L.: Springer, Cham, Intelligent Systems Reference Library, Pp. 13-37. [Consulta: 10 Mayo 2018]. Isbn 978-3-319-90079-7. Disponible En: https://link.springer.com/chapter/10.1007/978-3-319-90080-3_2.

- Bolón-Canedo, V. Y Remeseiro, B., 2019. Feature Selection In Image Analysis: A Survey. *Artificial Intelligence Review*, Pp. 1-27. Issn 0269-2821, 1573-7462. Doi 10.1007/S10462-019-09750-3.
- Cassidy, B., Reeves, N.D., Joseph, P., Gillespie, D., O'shea, C., Rajbhandari, S., Maiya, A.G., Frank, E., Boulton, A., Armstrong, D., Najafi, B., Wu, J. Y Yap, M.H., 2021. Dfuc2020: Analysis Towards Diabetic Foot Ulcer Detection. En: Arxiv: 2004.11853, *European Endocrinology*, Vol. 1, No. 1, Pp. 5. Issn 1758-3772. Doi 10.17925/Ee.2021.1.1.5.
- Cho, N.H., Shaw, J.E., Karuranga, S., Huang, Y., Da Rocha Fernandes, J.D., Ohlrogge, A.W. Y Malanda, B., 2018. Idf Diabetes Atlas: Global Estimates Of Diabetes Prevalence For 2017 And Projections For 2045. *Diabetes Research And Clinical Practice*, Vol. 138, Pp. 271-281. Issn 0168-8227. Doi 10.1016/J.Diabres.2018.02.023.
- Fei-Fei, L., Fergus, R. Y Perona, P., 2006. One-Shot Learning Of Object Categories. *Ieee Transactions On Pattern Analysis And Machine Intelligence*, Vol. 28, No. 4, Pp. 594-611. Issn 1939-3539. Doi 10.1109/Tpami.2006.79.
- Goyal, M., Reeves, N.D., Davison, A.K., Rajbhandari, S., Spragg, J. Y Yap, M.H., 2020. Dfunet: Convolutional Neural Networks For Diabetic Foot Ulcer Classification. *Ieee Transactions On Emerging Topics In Computational Intelligence*, Vol. 4, No. 5, Pp. 728-739. Issn 2471-285x. Doi 10.1109/Tetci.2018.2866254.
- Goyal, M., Reeves, N.D., Rajbhandari, S., Ahmad, N., Wang, C. Y Yap, M.H., 2020. Recognition Of Ischaemia And Infection In Diabetic Foot Ulcers: Dataset And Techniques. *Computers In Biology And Medicine*, Vol. 117, Pp. 103616. Issn 0010-4825. Doi 10.1016/J.Combiomed.2020.103616.
- Goyal, M., Reeves, N.D., Rajbhandari, S. Y Yap, M.H., 2019. Robust Methods For Real-Time Diabetic Foot Ulcer Detection And Localization On Mobile Devices. *Ieee Journal Of Biomedical And Health Informatics*, Vol. 23, No. 4, Pp. 1730-1741. Issn 2168-2208. Doi 10.1109/Jbhi.2018.2868656.
- Huang, G., Liu, Z., Pleiss, G., Van Der Maaten, L. Y Weinberger, K., 2019. Convolutional Networks With Dense Connectivity. *Ieee Transactions On Pattern Analysis And Machine Intelligence*, Pp. 1-1. Issn 1939-3539. Doi 10.1109/Tpami.2019.2918284.
- Keogh, E.J. Y Mueen, A., 2017. Curse Of Dimensionality. *Encyclopedia Of Machine Learning And Data Mining*, Vol. 2017, Pp. 314-315.

Kittler, J., Hatef, M., Duin, R.P.W. Y Matas, J., 1998. On Combining Classifiers. *Ieee Transactions On Pattern Analysis And Machine Intelligence*, Vol. 20, No. 3, Pp. 226-239. Issn 1939-3539. Doi 10.1109/34.667881.

Kononenko, I., 1994. Estimating Attributes: Analysis And Extensions Of Relief. *European Conference On Machine Learning* [En Línea]. S.L.: Springer, Pp. 171-182. [Consulta: 26 Enero 2017]. Disponible En: Http://Link.Springer.Com/Chapter/10.1007/3-540-57868-4_57.

Kuncheva, L.I., 2014. *Combining Pattern Classifiers: Methods And Algorithms*. S.L.: John Wiley & Sons. Isbn 978-1-118-31523-1.

López-Cabrera, J.D. Y Pereira-Toledo, A., 2018. Análisis Del Comportamiento Del Algoritmo Svm Para Diferentes Kernel En Ambientes Controlados. *Holos*, Vol. 5, Pp. 101-115. Issn 1807-1600. Doi <Https://Doi.Org/10.15628/Holos.2018.5563>.

López-Cabrera, J.D., Ruiz-Gonzalez, Y., Díaz-Amador, R. Y Taboada-Crispi, A., 2021. Automatic Classification Of Diabetic Foot Ulcers Using Computer Vision Techniques. *Progress In Artificial Intelligence And Pattern Recognition*. Habana, Cuba: Springer, Pp. 284-293.

Peng, H., Long, F. Y Ding, C., 2005. Feature Selection Based On Mutual Information Criteria Of Max-Dependency, Max-Relevance, And Min-Redundancy. *Ieee Transactions On Pattern Analysis And Machine Intelligence*, Vol. 27, No. 8, Pp. 1226-1238.

Pereira, R.M., Bertolini, D., Teixeira, L.O., Silla, C.N. Y Costa, Y.M.G., 2020. Covid-19 Identification In Chest X-Ray Images On Flat And Hierarchical Classification Scenarios. *Computer Methods And Programs In Biomedicine*, Pp. 105532. Issn 0169-2607. Doi 10.1016/J.Cmpb.2020.105532.

Snoek, C.G.M., Worring, M. Y Smeulders, A.W.M., 2005. Early Versus Late Fusion In Semantic Video Analysis. *Proceedings Of The 13th Annual Acm International Conference On Multimedia* [En Línea]. New York, Ny, Usa: Association For Computing Machinery, Pp. 399-402. [Consulta: 24 Agosto 2021]. Isbn 978-1-59593-044-6. Doi 10.1145/1101149.1101236. Disponible En: <Https://Doi.Org/10.1145/1101149.1101236>.

Yap, M.H., Cassidy, B., Pappachan, J.M., O'shea, C., Gillespie, D. Y Reeves, N., 2021. Analysis Towards Classification Of Infection And Ischaemia Of Diabetic Foot Ulcers. En: Arxiv: 2104.03068, *Arxiv:2104.03068 [Cs]* [En Línea], [Consulta: 1 Junio 2021]. Disponible En: <Http://Arxiv.Org/Abs/2104.03068>.

Yap, M.H., Hachiuma, R., Alavi, A., Brungel, R., Goyal, M., Zhu, H., Cassidy, B., Ruckert, J., Olshansky, M., Huang, X., Saito, H., Hassanpour, S., Friedrich, C.M., Ascher, D., Song, A., Kajita, H., Gillespie, D., Reeves, N.D., Pappachan, J., O'shea, C. Y Frank, E., 2020. Deep Learning In Diabetic Foot Ulcers Detection: A Comprehensive Evaluation. En: Arxiv: 2010.03341, *Arxiv:2010.03341 [Cs]* [En Línea], [Consulta: 5 Abril 2021]. Disponible En: <Http://Arxiv.Org/Abs/2010.03341>.

Conflicto de interés

Los autores autorizan la distribución y uso de su artículo.

Contribuciones de los autores

1. Conceptualización: José Daniel López-Cabrera
2. Curación de datos: Yusely Ruiz-Gonzalez
3. Análisis formal: José Daniel López-Cabrera, Roberto Diaz-Amador, Alberto Taboada-Crispi
4. Metodología: José Daniel López-Cabrera
5. Software: José Daniel López-Cabrera
6. Visualización: José Daniel López-Cabrera
7. Redacción – borrador original: José Daniel López-Cabrera
8. Redacción – revisión y edición: José Daniel López-Cabrera, Yusely Ruiz-Gonzalez, Roberto Diaz-Amador, Alberto Taboada-Crispi

^a <https://dfu-challenge.github.io/index.html>