  
**CASEIB**  
**2022**

XL Congreso  
Anual de la  
Sociedad  
Española de  
Ingeniería  
Biomédica


**40** AÑOS UNIENDO FUERZAS  
PARA IMPULSAR LA  
INGENIERÍA BIOMÉDICA  
23-25 NOVIEMBRE 2022 | VALLADOLID

# LIBRO DE ACTAS



GRUPO DE  
INGENIERÍA  
BIOMÉDICA  
UNIVERSIDAD DE VALLADOLID





**CASEIB  
2 0 2 2**

**XL Congreso Anual  
de la Sociedad  
Española de  
Ingeniería  
Biomédica**

**23-25 NOVIEMBRE 2022 | VALLADOLID**

*XL Congreso Anual de la Sociedad Española de Ingeniería Biomédica CASEIB 2022*

Los trabajos incluidos en esta publicación han sido evaluados por el Comité Científico que en ella se relaciona y según el procedimiento que se recoge en [www.caseib.es/2022/](http://www.caseib.es/2022/)

**Presidente del Comité Organizador:**

Roberto Hornero Sánchez

**Secretarios del Comité Organizador:**

Jesús Poza Crespo

Carlos Gómez Peña

**Editores:**

Roberto Hornero Sánchez

Jesús Poza Crespo

Carlos Gómez Peña

María García Gadañón

**Maquetación:**

Aarón Maturana Candelas

Carlos Gómez Peña

**Diseño de portada:**

Sandra Martínez Cagigal

Víctor Martínez Cagigal

ISBN: 978-84-09-45972-8



*Libro de Actas del XL Congreso Anual de la Sociedad Española de Ingeniería Biomédica*

Se distribuye bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional.

## ÍNDICE DE SESIONES CIENTÍFICAS

Miércoles, 23 de noviembre de 2022, a las 9:30

---

### Sesión oral: Imágenes Biomédicas

**Moderadores:** M<sup>a</sup> Gloria Bueno García y María García Gadañón

Breast cancer classification based on hyperspectral imaging .....	2
Metodologías de cuantificación de imágenes [ <sup>18</sup> F]FDG PET/CT para la detección de infiltración medular en pacientes con linfoma folicular .....	6
Corrección automática del contraste en imagen radiográfica mediante aprendizaje profundo ..	10
Mecanismo de atención y <i>deep learning</i> en la evaluación automática de la calidad de las retinografías .....	14
Uso de la Termografía para el Análisis y Seguimiento de los Hemangiomas Infantiles .....	18
Análisis textural de imágenes [ <sup>18</sup> F]FDG PET/CT para la predicción de enfermedad mínima residual en pacientes con sintomatología de mieloma múltiple .....	22

### Sesión oral: Señales Biomédicas I

**Moderadores:** Raimon Jané y Gonzalo César Gutiérrez Tobal

Análisis de los cambios en la conectividad funcional tras un entrenamiento cognitivo mediante Neurofeedback .....	27
Metodología Robusta Basada en los Fundamentos del Machine Learning Para la Clasificación de Señales Biomédicas. Aplicación a 3 Desafíos de la Ingeniería Biomédica Moderna .....	31
Analysis of surface electromyographic parameters for the assessment of muscle fatigue during moderate exercises .....	35
Estimación de la severidad de apnea del sueño pediátrica a partir de la señal de flujo aéreo usando redes neuronales convolucionales.....	39
Medición automática del "jitter" en registros electromiográficos patológicos .....	43
Impacto de la expresión del gen <i>MAPT</i> en las relaciones inter-banda de la actividad eléctrica cerebral .....	47

# Imágenes Biomédicas

---

Miércoles, 23 de noviembre de 2022

# Mecanismo de atención y *deep learning* en la evaluación automática de la calidad de las retinografías

R. Romero-Oraá<sup>1,2</sup>, M. García<sup>1,2</sup>, M. I. López Gálvez<sup>1,2,3,4</sup>, M. Herrero<sup>1</sup>, R. Hornero Sánchez<sup>1,2,5</sup>

<sup>1</sup> Grupo de Ingeniería Biomédica, Universidad de Valladolid, Valladolid, España, roberto.romero@gib.tel.uva.es, {margar,robhor}@tel.uva.es

<sup>2</sup> Centro de Investigación Biomédica en Red en Bioingeniería, Biomateriales y Nanomedicina (CIBER-BBN), España

<sup>3</sup> IOBA (Instituto de Oftalmobiología Aplicada), Universidad de Valladolid, España

<sup>4</sup> Hospital Clínico Universitario de Valladolid, Valladolid, España, maribel@ioba.med.uva.es

<sup>5</sup> IMUVA, Instituto de Investigación en Matemáticas de la Universidad de Valladolid, Valladolid, España

## Resumen

*La evaluación de la calidad de las retinografías es una etapa fundamental en los sistemas automáticos de cribado de distintas patologías oculares, como son la retinopatía diabética, el glaucoma, las cataratas o la degeneración macular asociada a la edad. El objetivo de este trabajo fue desarrollar un método basado en deep learning y un mecanismo de atención para clasificar las retinografías en dos clases según su nivel de calidad. Se empleó la arquitectura InceptionResNetV2 como modelo base en combinación con transfer learning, fine-tuning y data augmentation. El método se entrenó con 2348 retinografías de una base de datos privada y se evaluó con 425 imágenes de la misma base de datos, alcanzando 96.00% de precisión. También se utilizó la base de datos DRIMDB, compuesta por 194 imágenes, para validar el método, obteniendo una precisión del 99.48%. Finalmente, se estudió la interpretación del método, en el contexto de Explainable Artificial Intelligence, obteniendo mapas de atención.*

## 1. Introducción

En el campo de la oftalmología, la retinografía o imagen de fondo de ojo es la modalidad de imagen retiniana más establecida. Su uso se extiende al diagnóstico precoz y mejorado de múltiples patologías oculares, como son la retinopatía diabética, el glaucoma, las cataratas o la degeneración macular asociada a la edad [1]. Este diagnóstico se lleva a cabo analizando los cambios morfológicos del fondo de ojo. Sin embargo, la inspección manual de estas imágenes requiere mucho tiempo, esfuerzo y costes [2]. La escasez de oftalmólogos y el gran número de pacientes evidencian la necesidad de sistemas automáticos de cribado para asistir a los médicos [1]. De esta manera, sería posible aliviar su carga de trabajo y los costes asociados ofreciendo un diagnóstico rápido y objetivo [3].

Sin embargo, la fiabilidad del diagnóstico depende completamente de la calidad de las retinografías [1]. Si la imagen de entrada no presenta una calidad adecuada, podrían darse diagnósticos erróneos [3]. La realidad es que, en entornos clínicos, un elevado porcentaje de las imágenes carece de suficiente calidad para su análisis [4]. La presencia de polvo en la cámara, los parpadeos o la oclusión por pestañas son algunos de los factores que producen distorsiones en la imagen tales como iluminación

desigual, bajo contraste, desenfoque o destellos de luz. Por este motivo, la evaluación de la calidad de la imagen es una etapa esencial en los sistemas automáticos de cribado y ha recibido mucha atención por parte de la comunidad científica en los últimos años [1].

En este contexto, pueden encontrarse en la literatura varios métodos para determinar de forma automática la calidad de las retinografías. Algunas propuestas se basan en extraer características globales de la imagen [5], [6] mientras que otras se basan en un análisis estructural para identificar puntos de referencia [3], [7]. En los últimos años, las arquitecturas *deep learning*, como las redes neuronales convolucionales (CNN), se han empleado en multitud de problemas de visión artificial, incluida la evaluación de la calidad de las retinografías [1]. En este sentido, se han explorado distintas arquitecturas CNN: Alexnet, VGG19, ResNet18, ResNet50, DenseNet121 y Inception v3 [2], [4], [8]–[10]. En uno de nuestros trabajos previos comprobamos que la arquitectura InceptionResNetV2, junto con *transfer learning* y *fine-tuning*, ofrece resultados muy prometedores para nuestro propósito [11]. Asimismo, los mecanismos de atención han supuesto un avance significativo en las arquitecturas *deep learning* [12]. En un intento de imitar a los humanos, estos mecanismos permiten encontrar las regiones más significativas de la imagen y optimizar la tarea de clasificación centrando la atención del modelo en los píxeles relevantes. Además de esta optimización, los mecanismos de atención proporcionan un mapa de atención que permite interpretar los resultados obtenidos y explicar el comportamiento del modelo, contribuyendo así en el campo de *Explainable Artificial Intelligence* (XAI) [12].

En este trabajo partimos de la hipótesis de que los mecanismos de atención pueden mejorar la evaluación automática de la calidad de las retinografías. El objetivo fue desarrollar un modelo basado en *deep learning* y un mecanismo de atención para clasificar las retinografías en dos clases: calidad adecuada y calidad inadecuada. Se utilizó la arquitectura InceptionResNetV2 como modelo base en combinación con *transfer learning*, *fine-tuning* y *data augmentation*. Hasta donde sabemos, esta solución nunca ha sido explorada. Otra contribución del trabajo son los mapas de atención obtenidos, que permiten señalar las

regiones concretas de la imagen donde la calidad es insuficiente. Para desarrollar el método se utilizó una base de datos privada y se validó posteriormente con la base de datos pública DRIMDB [13].

## 2. Bases de datos de retinografías

En este estudio se utilizó una base de datos privada para la configuración del modelo. Estaba formada por 2773 retinografías proporcionadas por el Instituto de Oftalmobiología Aplicada (IOBA) de la Universidad de Valladolid y el Hospital Clínico Universitario de Valladolid. Estas imágenes se capturaron con el retinógrafo no midriático Topcon TRC-NW400, con un campo de visión de 45°, a 1956×1934 píxeles de resolución y en formato JPEG de 24 bits. Un especialista determinó, para cada una, si tenían o no calidad suficiente para su análisis. Se dividieron en dos conjuntos. El conjunto de entrenamiento (2348 imágenes, 85%) contenía 1778 imágenes de calidad adecuada y 570 imágenes de calidad inadecuada. El conjunto de test (425 imágenes, 15%) contenía 314 imágenes de calidad adecuada y 111 imágenes de calidad inadecuada. Asimismo, se empleó la base de datos pública DRIMDB [13] (194 imágenes de 760×570 píxeles de resolución) para validar la robustez del modelo. Esta base de datos está formada por 125 imágenes de calidad adecuada y 69 imágenes de calidad inadecuada.

## 3. Métodos

En esta sección se describe, en primer lugar, la etapa de preprocesado inicial. A continuación, se explican las técnicas *data augmentation*, *transfer learning* y *fine-tuning*. Después se detalla la arquitectura CNN utilizada, que incluye el mecanismo de atención propuesto. Finalmente, se especifica la fase de entrenamiento.

### 3.1. Preprocesado

En esta etapa, se redimensionaron, en primer lugar, todas las imágenes a una resolución de 512×512 píxeles [2]. Por tanto, la resolución original de las imágenes es irrelevante. Después, las imágenes se normalizaron en el intervalo [-1,1] para facilitar el aprendizaje de la red [2].

### 3.2. Data augmentation

Las redes neuronales profundas requieren un elevado número de datos de entrenamiento [2]. Para aumentar el número de imágenes con las que entrenar la CNN de este trabajo, se empleó la técnica de aumentación de datos en tiempo real. Esta técnica permite generar nuevas imágenes

aleatorias exclusivas para cada época de entrenamiento [2]. De esta manera, el modelo se entrenó con un conjunto diferente de 2348 imágenes para cada época, generadas a partir del conjunto de entrenamiento original. Estas retinografías sintéticas se obtuvieron aplicando transformaciones simples [2]:

- Rotaciones aleatorias en el rango [-20, +20] grados.
- Desplazamientos verticales y horizontales hasta un máximo de un 7% de la anchura de la imagen.
- Volteos verticales y horizontales aleatorios.
- Escalado entre 0.85 y 1.15.

Disponer de una mayor base de datos para entrenar ofrece mejores resultados y aumenta la capacidad de generalización del método [2].

### 3.3. Transfer learning y fine-tuning

*Transfer learning* consiste en resolver un problema de *machine learning* en un dominio de interés particular con el conocimiento aprendido de los datos de entrenamiento de otro dominio de interés [14]. De esta manera, no es necesario disponer de un conjunto de imágenes tan amplio como si se tuviera que entrenar la red desde cero. Para aplicar esta técnica, se utilizó un modelo base preentrenado con las imágenes del proyecto ImageNet [15]. Esta base de datos se compone de más de 14 millones de imágenes pertenecientes a más de 20000 clases distintas.

A continuación, se aplicó la técnica *fine-tuning*, que consiste en reentrenar la red preentrenada utilizando un conjunto de imágenes de entrenamiento adaptado al problema bajo estudio. De esta manera, los pesos se adaptan mejor a cada caso particular. En nuestro caso, se entrenaron todas las capas de nuestra CNN.

### 3.4. Arquitectura CNN

Las CNN son redes neuronales compuestas por capas convolucionales y, opcionalmente, capas de *pooling* y *fully-connected*, entre otras. Son capaces de extraer de forma optimizada características representativas de un gran conjunto de imágenes en crudo [2], [4]. En este trabajo se desarrolló una arquitectura CNN compuesta por 3 bloques: un modelo base, un mecanismo de atención y un conjunto de capas *fully-connected* a la salida de la red. La Figura 1 muestra el esquema de esta arquitectura. Como modelo base se empleó la arquitectura InceptionResNetV2, que actúa de extractor de características. Esta arquitectura híbrida es una combinación de Inception [16] y ResNet

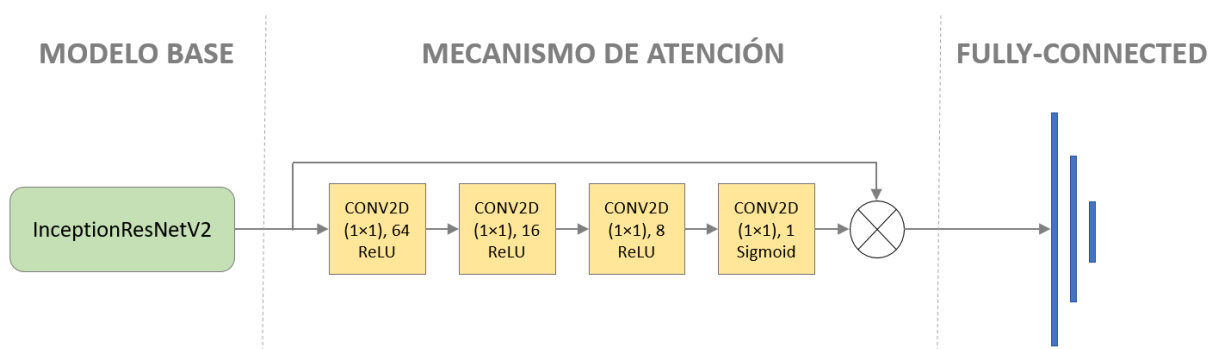


Figura 1. Esquema de la arquitectura CNN propuesta.

[17] y ha demostrado un gran rendimiento para evaluar la calidad de las retinografías [11]. El mecanismo de atención toma la matriz de características obtenida por el modelo base y se compone de 4 capas convolucionales 1x1 en serie, de 64, 16, 8 y 1 filtros cada una. Las 3 primeras capas tenían la función de activación ReLu y la última capa la función de activación sigmoide, de manera que su salida produce un mapa de atención cuyos píxeles representan el grado de relevancia en el rango [0-1] [12]. Para aplicar este mapa de atención a las características extraídas por el modelo base se utilizó la multiplicación elemento a elemento [12]. A continuación, se aplicó la operación *global average pooling* y, después, la técnica *dropout* para evitar el sobreentrenamiento [1]. Finalmente, la arquitectura CNN se cerró con 3 capas *fully-connected* de 1024, 512 y 1 neuronas cada una. Las dos primeras contaban con una función de activación ReLU [2]. Para la última, se empleó una función de activación sigmoide, que proporciona una salida entre 0 y 1 y puede interpretarse como una probabilidad a posteriori en nuestro problema de clasificación binaria [11].

### 3.5. Entrenamiento

Se entrenó el modelo CNN propuesto durante 100 épocas [10]. Se aplicó la entropía cruzada binaria como función de pérdidas y el descenso de gradiente estocástico como algoritmo de optimización [2], [4], [10]. La tasa de aprendizaje se fijó en 0.001 y el valor de *momentum* en 0.9 [2], [18]. Para evitar sobreentrenamiento en épocas avanzadas, se redujo la tasa de aprendizaje en un factor de 10 cada vez que el error de validación alcanzase un mínimo y se mantuviese constante [2], [18]. Además, se estableció un tamaño de *batch* de 16 imágenes [2].

## 4. Resultados

El entrenamiento de la CNN se llevó a cabo con las 2348 imágenes del conjunto de entrenamiento de la base de datos privada. Se utilizó un Workstation con procesador Intel Xeon CPU E5-1620 v4 @ 3.5GHz × 8, 32GB de RAM y dos tarjetas gráficas NVIDIA TITAN X (Pascal).

El método se evaluó sobre el conjunto de test de la base de datos privada y el total de imágenes de la base de datos pública DRIMDB [13]. La Tabla 1 recoge los resultados en términos de precisión (PR), sensibilidad (SE), especificidad (ES), F1-score y área bajo la curva ROC (AUC). Asimismo, en la siguiente sección se discuten algunos de los mapas de atención obtenidos.

## 5. Discusión

En este trabajo se ha propuesto un nuevo método basado en *deep learning* para evaluar la calidad de las retinografías. Como principal contribución, hemos incluido un mecanismo de atención como parte de la arquitectura. Este tipo de mecanismos se ha utilizado

Base de datos	PR (%)	SE (%)	ES (%)	F1	AUC
Privada	96.00	98.09	90.09	0.9224	0.9438
DRIMDB	99.48	99.20	100.00	0.9928	0.9960

**Tabla 1.** Resultados sobre el conjunto de test de la base de datos privada y sobre la base de datos pública DRIMDB.

previamente en el análisis de retinografías pero, hasta donde sabemos, no se ha utilizado en el contexto de calidad de la imagen. El método se ha desarrollado utilizando exclusivamente retinografías de una base de datos privada. Sin embargo, se ha obtenido una alta precisión con imágenes distintas procedentes de una base de datos pública, lo que demuestra su robustez. Los resultados de la Tabla 1 indican que el método propuesto ofrece un gran rendimiento para evaluar la calidad de las retinografías.

Estos resultados son similares a los obtenidos en estudios previos, como se muestra en la Tabla 2. Al considerar la base de datos privada, el método propuesto (PR=96.24%; SE=98.09%; ES=90.09%) supera nuestro antiguo trabajo en términos de precisión (95.29%) y sensibilidad (96.82%) pero no de especificidad (91.00%). Al comparar nuestros resultados para la base de datos DRIMDB con los obtenidos en otros estudios para la misma base de datos, observamos que nuestro método iguala nuestro antiguo trabajo (PR=99.48%; SE=99.20%; ES:100%) y supera al resto de trabajos de la literatura [2], [6], [18]–[20]. En otros trabajos se han utilizado bases de datos distintas, lo que influye sobre los resultados obtenidos y dificulta la comparación directa entre estudios. Destaca el trabajo de Saha et ál. [2], donde se obtuvo un 100% de precisión. Sin embargo, descartaron para el estudio las imágenes de calidad ambigua, que son las más propensas a error.

Otra contribución importante, en el contexto de XAI, son los mapas de atención generados, que se validaron de forma cualitativa. Estos mapas representan la relevancia de cada zona de la imagen para la toma de decisión del modelo. La Figura 2 muestra algunos ejemplos de estos mapas. En el primer ejemplo se aprecia que el modelo identifica correctamente la mancha negra. En el segundo ejemplo, se puede observar que el modelo encuentra relevante el borde superior, que carece de contraste.

Este estudio también presenta algunas limitaciones. En primer lugar, se ha llevado a cabo la validación del método con un número relativamente pequeño de imágenes. En el futuro sería deseable ampliar el número de imágenes de test. En segundo lugar, la sensibilidad y la especificidad han resultado desbalanceadas. Sería deseable aplicar estrategias como la función de pérdidas focal o la ponderación de clases para balancear esas métricas. Por último, el mecanismo de atención aplicado puede verse

Estudio	Base de datos	PR (%)	SE (%)	ES (%)
Yu et al. 2017 [8]	EyePACS	95.42	96.63	93.10
Saha et al. 2018 [4]	EyePACS	100	100	100
Zago et al. [2]	DRIMDB	98.55	97.10	100
Shao et al. [6]	DRIMDB	89.10	89.30	94.10
Chalakkal et al. [18]	DRIMDB	97.77	97.60	97.80
Karlsson et al. [19]	DRIMDB	98.10	99.30	95.80
Abramovich et al. [20]	DRIMDB	99.00	98.40	100
Romero-Oraá et al. [11]	Privada	95.29	96.82	91.00
Romero-Oraá et al. [11]	DRIMDB	99.48	99.20	100
<b>Método propuesto</b>	<b>Privada</b>	<b>96.00</b>	<b>98.09</b>	<b>90.09</b>
<b>Método propuesto</b>	<b>DRIMDB</b>	<b>99.48</b>	<b>99.20</b>	<b>100</b>

**Tabla 2.** Comparación de los resultados con otros estudios.






Figura 2. Ejemplos de algunos mapas de atención generados.

como una primera aproximación. En líneas futuras se estudiarán mecanismos de atención más avanzados y se analizarán los mapas generados de forma cuantitativa.

## 6. Conclusiones

En este trabajo se ha propuesto un método basado en *deep learning* y un mecanismo de atención para evaluar de la calidad de retinografías con un gran rendimiento. Los resultados obtenidos indican que método propuesto podría ser de utilidad en un entorno clínico como primera etapa en los sistemas de ayuda al diagnóstico de patologías como la retinopatía diabética, el glaucoma, las cataratas y la degeneración macular asociada a la edad.

## Agradecimientos

Esta investigación se ha desarrollado en el marco de las ayudas PID2020-115468RB-I00 y PGC2018-098214-A-I00 financiadas por el 'Ministerio de Ciencia e Innovación/Agencia Estatal de Investigación/10.13039/501100011033/' y el Fondo Europeo de Desarrollo Regional (FEDER). Una forma de hacer Europa; y por el 'CIBER en Bioingeniería, Biomateriales y Nanomedicina (CIBER-BBN)' a través del 'Instituto de Salud Carlos III' cofinanciado con fondos FEDER. R. Romero-Oraá disfruta de un contrato predoctoral cofinanciado por el Fondo Social Europeo, el Programa Operativo de Castilla y León, y la Junta de Castilla y León, a través de la Consejería de Educación.

## Referencias

- [1] A. Raj, A. K. Tiwari, and M. G. Martini, "Fundus image quality assessment: survey, challenges, and future scope," *IET Image Process.*, vol. 13, no. 8, pp. 1211–1224, Jun. 2019.
- [2] G. T. Zago, R. V. Andreão, B. Dorizzi, and E. O. Teatini Salles, "Retinal image quality assessment using deep learning," *Comput. Biol. Med.*, vol. 103, pp. 64–70, 2018.
- [3] J. Lin, L. Yu, Q. Weng, and X. Zheng, "Retinal image quality assessment for diabetic retinopathy screening: A survey," *Multimed. Tools Appl.*, 2019.
- [4] S. K. Saha, B. Fernando, J. Cuadros, D. Xiao, and Y. Kanagasigam, "Automated Quality Assessment of Colour Fundus Images for Diabetic Retinopathy Screening in Telemedicine," *J. Digit. Imaging*, vol. 31, no. 6, pp. 869–878, Dec. 2018.
- [5] J. M. Pires Dias, C. M. Oliveira, and L. A. Da Silva Cruz, "Retinal image quality assessment using generic image quality indicators," *Inf. Fusion*, vol. 19, no. 1, pp. 73–90, 2014.
- [6] F. Shao, Y. Yang, Q. Jiang, G. Jiang, and Y. S. Ho, "Automated Quality Assessment of Fundus Images via Analysis of Illumination, Naturalness and Structure," *IEEE Access*, vol. 6, pp. 806–817, Nov. 2017.
- [7] R. A. Welikala *et al.*, "Automated retinal image quality assessment on the UK Biobank dataset for epidemiological studies," *Comput. Biol. Med.*, vol. 71, pp. 67–76, 2016.
- [8] F. Yu, J. Sun, A. Li, J. Cheng, C. Wan, and J. Liu, "Image quality classification for DR screening using deep learning," in *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2017, pp. 664–667.
- [9] R. Tennakoon, D. Mahapatra, P. Roy, S. Sedai, and R. Garnavi, "Image Quality Classification for DR Screening Using Convolutional Neural Networks," in *Proceedings of the Ophthalmic Medical Image Analysis Third International Workshop*, 2016, pp. 113–120.
- [10] A. S. Coyner *et al.*, "Deep Learning for Image Quality Assessment of Fundus Images in Retinopathy of Prematurity," *AMIA ... Annu. Symp. proceedings. AMIA Symp.*, vol. 2018, pp. 1224–1232, 2018.
- [11] R. Romero-Oraá, M. García, J. Oraá-Pérez, M. I. López, and R. Hornero, "Transfer learning para evaluar de forma automática la calidad en imágenes de fondo de ojo," in *XXXVII Congreso Anual de la Sociedad Española de Ingeniería Biomédica (CASEIB 2019)*, 2019, pp. 175–178.
- [12] M. H. Guo *et al.*, "Attention mechanisms in computer vision: A survey," *Computational Visual Media*, vol. 8, no. 3. Springer, pp. 331–368, 15-Mar-2022.
- [13] U. Sevik, "DRIMDB (Diabetic Retinopathy Images Database) Database for Quality Testing of Retinal Images." 2014.
- [14] S. J. Pan and Q. Yang, "A Survey on Transfer Learning," *IEEE Trans. Knowl. Data Eng.*, vol. 22, no. 10, pp. 1345–1359, Oct. 2010.
- [15] Jia Deng, Wei Dong, R. Socher, Li-Jia Li, Kai Li, and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database," in *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 2009, pp. 248–255.
- [16] C. Szegedy *et al.*, "Going deeper with convolutions," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2015, vol. 07-12-June, pp. 1–9.
- [17] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016, vol. 2016-Decem, pp. 770–778.
- [18] R. J. Chalakkal, W. H. Abdulla, and S. S. Thulaseedharan, "Quality and content analysis of fundus images using deep learning," *Comput. Biol. Med.*, 2019.
- [19] R. A. Karlsson, B. A. Jonsson, S. H. Hardarson, O. B. Olafsdottir, G. H. Halldorsson, and E. Stefansson, "Automatic fundus image quality assessment on a continuous scale," *Comput. Biol. Med.*, vol. 129, Feb. 2021.
- [20] O. Abramovich, H. Pizem, J. Van Eijgen, I. Stalmans, E. Blumenthal, and J. A. Behar, "FundusQ-Net: a Regression Quality Assessment Deep Learning Algorithm for Fundus Images Quality Grading," *ArXiv Prepr.*, May 2022.

## ÍNDICE DE AUTORES

Abad-González, A.	423	Bailón, R.	448
Abella, M.	10, 213	Balastegui García, G.	72
Abellán Rubio, E.	266	Barquero-Pérez, O.	245
Abete, I.	52	Barrenechea Carrasco, M.	345
Acha, B.	18, 415	Barros-Tornay, R.	415
Aginagalde Lopez, A.	217	Barroso García, V.	39
Aguilar-Aguilar, E.	52	Bartrés-Faz, D.	521
Aguilar Paredes, F.	237	Belda Calabuig, A.	142
Aguilar Sabido, C.	486	Bernabéu-Wittel, J.	18
Albaladejo-Belmonte, M.	146, 398	Bernal Benítez, C.	506
Alberola-López, C.	85, 167	Berner-Juhos, K.	510
Alberola-Rubio, J.	146, 398	Berrocoso, E.	130
Albusac, J.	97	Berruezo, A.	461
Alcaraz Martínez, R.	365, 394	Blanco-Velasco, M.	419, 431
Alcon, C.	113	Bocos-Corredor, E.	262
Aldazabal, J.	249	Bonse, J.	217
Alfano, F.	274	Bragulat Arévalo, M.	369
Algaba-Vidoy, M.	101	Buendia Aviles, S.	357
Almendral, J.	477	Bueno, G.	2
Alonso, E.	452	Bueno Zamora, O.	274
Alonso, J. F.	283	Burgaleta Ledesma, A.	117
Alonso-Linaje, G.	180	Burgos Llamo, A.	121
Alonso, R.	22, 490	Buruaga Lamarain, L.	217
Álvarez, D.	39, 411, 427, 448	Cabal-Rodríguez, R.	77
Álvarez Rodríguez, M.	184, 233	Cabezaolías, C.	258
Alves-Ferreira, M.	287, 402	Cabrera-Umpiérrez, M. F.	56, 117
Amaro, S.	525	Cadena Bonfanti, A.	89
André, J. M.	192	Calvillo Arbizu, J.	93
Antón-Rodríguez, M.	270	Calvo, A.	510
Aramendi, E.	155, 175, 444, 452	Calvo Manuel, F.	171
Araujo Rodríguez, H.	525	Cámara-Vázquez, M. A.	245
Arbelo Lainez, E.	369	Campos Añón, F.	381
Arce-Diego, J. L.	469, 494	Cànaves Llabrés, A. I.	201
Arco, A.	510	Candel Cano, P.	473
Arco, H.	510	Candel, M. J.	81
Arias Palomares, M. A.	365	Candela Muries, T.	291
Armañac-Julián, P.	448	Cano del Pozo, M.	109
Armijo Suárez, O.	486	Cano Mayo, P.	105
Arnal, M. L.	81	Cappella, B.	217
Arredondo Waldmeyer, M. T.	117	Carneiro, P.	353
Ayala Fernández, U.	345	Carretero-Calvo, P.	109
Aznar, S. D.	81	Casado, E.	68
Azorín, J. M.	188, 291, 308, 320	Castellanos, E.	477
Bachiller, A.	283, 299	Castells, F.	31, 134, 138, 150
		Castillo-Passi, C.	85, 167
		Castillo Rabazo, J.	266

Castro de la Nuez, P.	93	Ferreira-Santos, D.	163
Castro Fernández, M.	529	Ferrer-Montiel, A.	361
Cattaneo, G.	521	Ferreres García, K.	274
Cenarro, R.	22	Ferrero, J. M.	361, 386
Cenis, J. L.	81	Ferrero, L.	308
Ceruelo Abajo, S.	97, 233	Ferrero, V.	320
Chausa, P.	52, 521	Fico, G.	117
Chmarra, M. K.	517	Fraile Marinero, J. C.	180
Chorro, J.	150	Franco Terriza, L.	60
Chushig-Muzo, D.	423	Fuster Palà, A.	221
Cisnal, A.	180	Gabilondo Cuellar, I.	345
Climent, A. M.	245	Galarregui, C.	52
Costa, V.	258, 278, 349	Gallardo, C.	406
Crespo Aguirre, M.	138	Ganoza-Quintana, J. L.	494
Cunill Rodríguez, M.	357	García-Barrio, N.	121
Dankelman, J.	517	García-Blas, J.	10
de Benavides, J.	490	García-Carmona, R.	262
de Ciurana Gay, J.	201	García-Casado, F. J.	142, 146, 398
de los Reyes Guzmán, A.	97, 184, 233	García-Cazorla, A.	299
del-Ama, A. J.	328	García Fernandez, I.	159
del Campo, F.	39, 427	García-García, P.	465
del Cerro, C. F.	10, 213	García-Lizarribar, A.	113
del Riego Gómez, S.	349	García, M.	14, 427
Delgado Atencio, J. A.	357	García-Molina, A.	52
Descó, M.	10, 213	García-Real, M. I.	10
Díaz-Pernas, F. J.	270	García-Rudolph, A.	52
Díaz Rivas, R.	506	García-Sáez, G.	341, 406
Eimil-Suarez, E.	77	García Teruel, M.	365
Elena, M.	60	García-Vicente, C.	423
Elola, A.	155, 444, 452	Garnés Camarena, O.	43
Elorza Fernández, D.	377	Garrido Rubiales, B.	68
Escribano Cano, P.	365	Gavidia Ceballos, L.	506
Espinosa-Salinas, I.	68	Gil-Agudo, A.	184, 233, 328
Esteban Gata, M. J.	60	Gil-Castillo, J.	328
Fabregat-Sanjuan, A.	241	Gil, E.	448
Falagán, S.	68	Gil Simoes, R.	105, 333
Fanjul-Vélez, F.	357, 469, 494	Gilete Preciado, V.	64
Ferencz, A.	510	Giraldo Giraldo, B. F.	456
Fernández-Arias, I.	85, 167	Gjerde, J.-M.	517
Fernández-Linsenbarth, I.	283	Goicolea, J. M.	274
Fernández Moreno, G.	105	Gómez, A.	213
Fernández-Poyatos, M.	411	Gómez, C.	47, 109, 287, 303, 390, 402
Fernández-Rodríguez, A.	192	Gómez, E. J.	6, 22, 52, 68, 225, 353, 377, 465, 486, 490, 517, 521
Ferré López, D.	456	Gómez-García, J. A.	101
		Gómez-Grande, A.	6, 22, 490


Gómez, J. F.	477	Irrarrazaval, P.	85, 167
Gómez-Pilar, J.	163, 287, 402	Isasi, I.	452
Gomis Jimeno, F.	72	Isla-Calvo, A.	469
Gomis Roman, P.	369	Iza, A.	452
Gomis-Tena, J.	35	Jané, R.	237
González-Alonso, J.	270	Jara Muriel, M.	266
González, L.	2	Jarrín Vera, I.	121
González Morcillo, C.	97	Jaureguibeitia, X.	155, 175
González-Navarro, C. J.	52	Jiménez Carrizosa, M.	105, 333
González Nuño, F. M.	266, 514	Jiménez García, J.	427
González-Ortega, D.	270	Jordà Burgos, P.	369
Gorrin, N.	274	Juan, J. V.	188
Gozal, D.	39, 163, 411, 427, 448	Junquera Godoy, I.	35
Gracia Laso, D. I.	291	Jutinico Alarcón, A.	89
Guerrero, A. L.	287, 402	Kamarova, K.	390
Guerrero Pérez, M.	64	Kheirandish-Gozal, L.	39, 427
Guijarro, E.	146, 398	Kontaxakis, G.	337
Guill, A.	138, 150	Kontaxis, S.	448
Guillem, M. S.	245	Kotzki, S.	353
Gutiérrez, A.	406	Lafuente Alcázar, B.	253
Gutiérrez-de Pablo, L.	303	Laguna, P.	436, 448
Gutiérrez-de Pablo, V.	47, 287, 303, 402	Lamata, P.	274
Gutiérrez Delgado, M.	142	Langø, T.	517
Gutiérrez Fernández-Calvillo, M.	245	Lara-Doña, A.	130
Gutiérrez-Tobal, G. C.	39, 163, 411, 427, 448	Lázaro, J.	448
Gutiez-Bravo, B.	225	Lazo, M.	415
Guzmán-García, C.	465, 517	Ledesma Carbayo, M. J.	274
Hernández-Romero, I.	245	Leñero-Bardallo, J. A.	18
Hernando, M. E.	52, 68, 341, 406	León, J.	510
Herráez, D.	444	Liberos, A.	159
Herrera Tirado, V.	97	Lillo Crespo, M.	72
Herrera-Valenzuela, D.	328	Liu, V.	209
Herrero, M.	14	Lizarraga, S.	274
Hingorani-Jai Prakash, S.	361	Llull, L.	525
Holgado-Cuadrado, R.	419, 431	Lobato Gómez, C.	373, 481
Hornero, R.	14, 27, 39, 47, 125, 163, 180, 196, 287, 316, 324, 390, 402, 411, 427, 448	Loidi, A.	386
Hoshi, H.	390	López Gálvez, M. I.	14
Huerta Herraiz, A.	394	López López, S.	278
Iáñez, E.	188, 291, 308, 320	Lopez Martinez, M. J.	113
Ibáñez-Molina, A. J.	295	López-Sánchez, N.	361
Idris, A. H.	175	Lopour, B.	209
Iglesias-Parro, S.	295	Lora-Millán, J. S.	312
Imaz Higera, J.	142	Loria-Kohen, V.	52
Iniesta-Chamorro, J. M.	52, 68	Lovisoló, L.	431

Pérez-Blanco, J. G.	77	Rollano Corroto, M.	229
Pérez, C.	436	Romero-Bascones, D.	345
Pérez-Carrasco, J. A.	18, 415	Romero García, A.	64
Pérez-Gandía, C.	406	Romero, L.	440
Pérez-Rigueiro, J.	81	Romero Mila, B.	209
Pérez Turiel, J.	180	Romero-Oraá, R.	14
Pérez Valdivia, M. A.	93	Romero, P.	159
Pérez-Velasco, S.	27, 125, 196, 303, 316, 324	Romero, S.	283, 299
Pina-de-Paz, J.	328	Romero Zayas, I.	381
Pino Ramirez, A.	506	Romitti, G. S.	159
Pinto, N.	287, 402	Ron-Angevin, R.	192
Pires Louça, L. C.	266	Rubio, F. J.	225, 377, 486
Plaza de Miguel, C.	481, 514	Rufo Rafael de la Cruz, N.	337
Plaza-Seco, C.	419, 431	Ruipérez-Campillo, S.	31, 134, 138, 150
Pose Díez de la Lastra, A.	171	Ruiz, C. R.	477
Poza, J.	47, 109, 303, 390, 402	Ruiz-Díez, S.	101
Prats-Boluda, G.	35, 142	Ruiz Fernández, D.	72
Puche-García, V.	361, 440	Ruiz-Fernández, M. J.	10
Pueyo, E.	436	Ruiz Ordoñez, M.	525
Puig Miquel, T.	201		
		Sahelices, B.	411
Quiles, V.	308, 320	Saiz, J.	35, 440, 498
Quintana, M.	225, 377, 486	Sala Llonch, R.	381
		Samitier, J.	113
Ramírez, A.	52, 68	Sanches, J.	353
Ramirez-Hernández, B.	77	Sánchez-de Madariaga, R.	121
Ramos Hortal, R.	105, 333	Sánchez del Valle, C.	184, 233
Raya, R.	258, 278, 349, 502	Sánchez-González, P.	6, 22, 225, 377, 465, 486, 490, 517, 521
Reglero, G.	52	Sánchez López, A.	171
Regueiro-Gómez, A.	77	Sánchez López de Pablo, C.	278, 349
Reina Tosina, J.	93	Sánchez-Margallo, F. M.	64, 266, 373, 481, 510, 514, 517
Revilla-Vallejo, M.	390	Sánchez-Margallo, J. A.	266, 373, 481, 514, 517
Rieta Ibáñez, J. J.	365, 394	Sánchez-Morillo, D.	130
Rigla, M.	406	Sánchez-Peralta, L. F.	64, 510
Rigo-Vidal, A.	241	Sanderson, D.	10
Roa Romero, L. M.	93	Santamaría-Bustamante, L.	469
Rocon, E.	312	Santamaría-Vázquez, E.	27, 196, 316, 324
Ródenas García, J.	365	Santos, A.	274
Rodrigo, M.	159	Santos-Ceballos, J. C.	77
Rodríguez-Cayetano, M.	85, 167	Santos-Paz, J. A.	262
Rodríguez Falces, J.	43	Santos Virosta, M.	381
Rodríguez-González, V.	109, 287, 303, 402	Sarandeses, P.	6
Rodríguez-Matesanz, M.	225	Schwibbert, K.	217
Rodríguez, R.	353	Sebastian, R.	159
Rojas García, A.	377		
Rojo Agustí, A.	349, 502		
Rojo-Álvarez, J. L.	419		



**CASEIB**  
**2022**

XL Congreso Anual  
de la Sociedad  
Española de  
Ingeniería  
Biomédica



ISBN 978-84-09-45972-8



9 788409 459728