

## **DISEÑO DE UNA RED NEURONAL CONVOLUCIONAL ENTRENADA PARA LA CLASIFICACIÓN DE CANCER EPIDERMÓIDE EL CUERPO HUMANO**

### **DESIGN OF A CONVOLUTIONAL NEURAL NETWORK TRAINED FOR THE CLASSIFICATION OF EPIDERMOID CANCER IN THE HUMAN BODY**

Roberto Porto Solano<sup>1</sup>, José Manuel Molina<sup>2</sup>, Fernando Dávila Aguilar<sup>3</sup>, Diego Noriega Izquierdo<sup>4</sup> y Javier de Jesús García<sup>4</sup>

<sup>1</sup> MSc en ingeniería de sistemas, Universidad Politécnica Costa Atlántica, Grupo de Investigación GIGETIC

<sup>2</sup> Doctor en ciencias de la informática, UC3M, Grupo de investigación GIAA

<sup>3</sup> Estudiante, Tecnológico de Estudios Superiores de Jocotitlán

<sup>4</sup> Estudiante del programa de ingeniería de sistemas, Universidad Politécnica Costa Atlántica

Recibido: septiembre 19 de 2020 Aceptado: noviembre 20 de 2020

---

#### **RESUMEN**

En esta investigación se crearon diferentes modelos de Redes Neuronales Convolucionales variando los parámetros de filtro y épocas con la finalidad de mejorar el aprendizaje sobre las distintas clases del conjunto de imágenes. Así mismo, se subdividió el conjunto de imágenes en imágenes de entrenamiento, prueba y validación, este último para comprobar la eficiencia en la clasificación de del modelo creado el cual presento una eficiencia de 87.5% y el cual se acerca a las mejores encontrados en la literatura.

**Palabras clave:** CNN, Variación de parámetros, Clasificación, Cáncer, epidermoide, Aprendizaje

---

#### **ABSTRACT**

In this research, different models of Convolutional Neural Networks were created, varying the filter parameters and times in order to improve learning about the different classes of the set of images. Likewise, the set of images was subdivided into training, test and validation images, the latter to verify the efficiency in the classification of the created model which presented an efficiency of 87.5% and which is close to the best found in the literature.

Keywords. CNN, Parameter Variation, Classification, Cancer, Squamous, Learning

---

## **1. INTRODUCCIÓN**

Según la Organización Mundial de la Salud, el cáncer es un proceso de crecimiento incontrolado de células (tumor) que pueden crecer prácticamente en cualquier parte de cuerpo y es capaz de extenderse a puntos distintos del organismo. Existen diversos tipos de cáncer que se pueden curar mediante cirugías, radioterapias o quimioterapias, especialmente si se detectan a tiempo. Cada tipo de cáncer posee características particulares, que en algunos casos son completamente diferentes, tanto en síntomas como en tratamientos. Entre los más comunes, en cuando a su índice de mortalidad se refiere, está el Cáncer de Pulmón, Cáncer Hepático, Colorrectal, Gástrico y Mamario.

El cáncer es la principal causa de muerte en el mundo por enfermedad; En el 2015, ocasionó 8,8 millones de defunciones, casi una de cada seis defunciones que se producen

el mundo es debido a esta enfermedad (OMS, 2018). Las causas de esta enfermedad se le atribuyen a factores genéticos y tres categorías de agentes externos, como los carcinógenos físicos, como las radiaciones ultravioletas e ionizantes; carcinógenos químicos, como el amianto, los componentes del humo de tabaco, las aflatoxinas (e.g., contaminantes de los alimentos) y el arsénico (e.g., contaminante del agua de bebida), y carcinógenos biológicos, como determinados virus, bacterias y parásitos (OMS, 2018).

A pesar de que los anteriores son los tipos de cáncer más comunes en cuanto mortalidad se refiere, en este trabajo se va a delimitar al cáncer de piel que es por mucho el más común (pero no la más mortal) entre todos los tipos de cáncer. El principal factor ambiental para sufrir cáncer de piel es la Radiación Ultravioleta, bien sea que provenga de la exposición solar o de una fuente artificial como las cámaras de bronceo. Así, cualquier persona que recibe diariamente su influencia, sin protegerse, estará en riesgo de desarrollar la enfermedad.

El cáncer de piel suele aparecer sobre las zonas de la piel que no están cubiertas por la ropa ni protegida con bloqueador solar y que diariamente reciben la influencia de la radiación Ultravioleta: la cara, las orejas, cuero cabelludo (en los hombres con alopecia) el cuello, los brazos y las piernas. Pueden ir desde lunares de aspecto inusual, manchas negras, heridas espontáneas en la cara que no sanan, verrugas de crecimiento progresivo, lunares inflamados o la aparición de tumores sobre la piel.

Los tres tipos de cáncer piel más frecuentes son carcinoma basocelular, carcinoma escamo-celular y melanoma, este último es el más agresivo y que con mayor frecuencia produce metástasis (reproducción o extensión de una enfermedad o de un tumor a otra parte del cuerpo). El melanoma conforma solo 1% de los casos de cáncer de piel, pero es causa de la gran mayoría de muertes por este tipo de cáncer (ACS, 2016)

Existen diversas maneras de predecir Cáncer de Piel en los pacientes. Por lo general, el doctor obtendrá su historial médico y hará preguntas sobre cambios de tonalidad en la piel. También se pueden realizar variaciones de biopsias con muestras de la piel, así como estudios por imágenes como: Radiografía de Tórax, Tomografía Computarizada, Resonancia Magnética y Tomografía por emisión de positrones (ACS, 2016)]. Los estudios por imágenes no son necesarios para personas con melanoma en etapa muy temprana, el cual es muy poco probable que se haya propagado.

## 2. MARCO TEÓRICO

El término Visión por Computadora ha sido muy utilizado en los últimos años y tiende a ser confundido con otros conceptos. Algunos de ellos son, Ciencia que desarrolla las bases teóricas y algorítmicas para obtener información sobre el mundo real a partir de una o varias imágenes (Shapiro, 1992). Este dice que es la disciplina que desarrolla sistemas capaces de interpretar el contenido de escenas naturales (Castleman, 1996).

Gracias a que el área del cerebro responsable de la visión es una de las zonas más estudiadas y que más se conoce; se sabe que la corteza visual contiene una disposición jerárquica compleja de neuronas. La corteza visual de los animales es el más potente sistema de procesamiento visual que se conoce, por lo que suena lógico inspirarse en ella

para crear una variante de redes neuronales artificiales que ayude a identificar imágenes; es así como surgen las redes neuronales convolucionales (CNN). En pocas palabras, son redes neurales capaces de construir funciones completas a partir de otras menos complejas (Developer, 2018).

Durante los últimos años se han desarrollado diversas investigaciones en el tema Visión por computadora para diversos propósitos o con alguna tarea en específico.

Amirreza (2018), realizó una clasificación del Cáncer de Piel utilizando diferentes Algoritmos de Redes Neuronales de Aprendizaje Profundo, en el que se estudió la efectividad y capacidad de las Redes Neuronales Convolucionales en la clasificación de ocho enfermedades de la piel utilizando diferentes arquitecturas pre entrenadas como DenseNet y ResNet con el objetivo de comparar la capacidad del Deep Learning con el rendimiento de dermatólogos altamente capacitados. Los mejores valores para el melanoma y el carcinoma de células de base son 94.40% con ResNet 152 y 99.30% con DenseNet 201 contra 82.26% y 88.82 de dermatólogos, respectivamente.

Lee et al (2018), diseñaron un modelo, que vuelve a muestrear las imágenes de lesiones cutáneas pre procesadas, además construye una arquitectura de red neuronal afinada con datos segmentación, y utiliza un método conjunto para clasificar las siete enfermedades de la piel. Logrando una precisión de la 0.899 y 0.785 en el conjunto de validación y prueba, respectivamente.

Li and Li (2018),] muestran un diseño, experimentos y resultado de una solución presentada en el desafío de la ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection. Se diseña un modelo utilizando Redes Neuronales Convolucionales (CNN) para pruebas de segmentación y diagnóstico de lesiones.

Pierluigi, et al (2018), utilizaron una Red Neuronal Convolucional profunda basada en la arquitectura DenseNet junto con una metodología de aprendizaje altamente discriminativa, para clasificar siete tipos de lesiones cutáneas. El sistema propuesto realizó una puntuación global de 89.2% en la fase de validación del desafío (Challenge, 2018).

Se logró un proceso considerable en el uso de aplicaciones automatizadas para la clasificación precisa de las lesiones cutáneas a partir de imágenes digitales. Se formó una red neuronal convolucional basada en la arquitectura ResNet 50 para clasificar con precisión las imágenes de dermatoscopia de las lesiones de la piel en una de las siete categorías de enfermedades, obteniendo una precisión equilibrada de 91% en el conjunto de datos de validación.

La formación de Redes Neuronales para el diagnóstico automatizado de lesiones cutáneas pigmentadas se ve obstaculizado por el pequeño tamaño y falta de diversidad de los conjuntos de datos disponibles de imágenes dermatoscopias. Tschandl et al (2018) abordaron el tema lanzando el conjunto de datos HAM10000 (Human Against Machine con 10000 imágenes de entrenamiento). Las imágenes se recolectaron de diferentes poblaciones y modalidades. Dada esta diversidad, se tuvo que aplicar diferentes métodos de adquisición y limpieza y desarrollamos flujos de trabajo semiautomáticos utilizando redes neuronales específicamente capacitadas.

Codella et al (2018), describieron el diseño, la implementación y los resultados de la última entrega del desafío de referencia de análisis de imágenes dermatoscópicas. El desafío se dividió en 3 tareas: segmentación de lesiones, detección de características y clasificación de enfermedades. Los conjuntos de datos utilizados durante el desafío están disponibles para futuras investigaciones y desarrollos, tal como el data set HAM10000 utilizado en este trabajo.

Estudios recientes han demostrado el uso de Redes Neuronales Convolucionales (CNN) para clasificar imágenes de melanoma con precisiones comparables a las logradas por dermatólogos certificados. Sin embargo, el rendimiento de una CNN entrenada exclusivamente con imágenes dermatoscópicas en una tarea de clasificación de imágenes clínicas en competencia directa con un gran número de dermatólogos no se ha medido hasta la fecha. Brinker et al (2019) compararon el rendimiento de una Red Neuronal Convolutiva entrenada con imágenes dermatoscópicas exclusivamente para identificar el melanoma en fotografías clínicas con la clasificación manual de las mismas imágenes por dermatólogos.

Motsch et al (2018), explicaron el método utilizado en el desafío de segmentación en el desafío de detección de lesiones cutáneas de International Skin Imaging Collaboration (I Kechyn, SIC) en 2018. Se entrenó una red U-Net para realizar la segmentación.

Kechyn, (2018), aborda el problema de la detección automática del límite de lesiones dermatoscópicas, utilizando Redes Neuronales Profundas basadas en la adaptación de la CNN U-Net con conexiones de omisión para la tarea de segmentación del límite de lesión. El mejor modelo logró resultados con 0.752. Otros experimentos con diferentes arquitecturas y modelos únicos lograron resultados entre 0.700 y 0.750.

Lu et al (2018) resumen los métodos utilizados en el concurso ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection, donde se utilizó un modelo de CNN llamado GrassNet y una combinación de U-Net y ResNet entre otros modelos, obteniendo una puntuación de 0.781 en la primera presentación de validación, después de 280 épocas de entrenamiento (11 minutos por época), en una PC con una tarjeta gráfica GTX 1070.

Ray, (2018), propone una técnica de clasificación para las imágenes de lesiones de la piel como parte su presentación en (Challenge, 2018), donde se utilizó una CNN ResNet50 así como DeepFores con capas en cascada para clasificar las imágenes. Se dividió el dataset en un conjunto de entrenamiento y un conjunto de pruebas con una relación de división de 0.1. La precisión de entrenamiento obtenida fue del 97.15%. La precisión de prueba fue del 80.04%

Ebenezer y Rajapakse. (2018), utilizaron un método totalmente automático para segmentar con precisión los límites de las lesiones a partir de imágenes dermatoscópicas usando una Red U-Net. En las presentaciones se obtuvieron índices Jaccard de 0.756, 0.750 y 0.746 en el conjunto de validación de 100 imágenes. (Challenge, 2018).

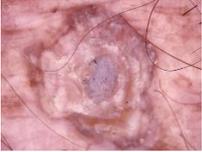
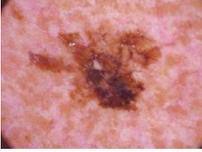
Goyal y Rajapakse (2018), usaron una arquitectura de una Red Neuronal Profunda (DNN) que puede clasificar eficazmente las lesiones cutáneas mediante el uso de la recopilación de datos y el embolsado para abordar la escasez de datos y evitar el exceso de información. El conjunto está compuesto por dos arquitecturas DNN: Inception-v4 e Inception Resnet-v2.

Kitada y Iyatomi (2018), perfeccionaron múltiples modelos de Redes Neuronales previamente entrenadas basadas en redes de compresión y excitación (SENet) que logran resultados de vanguardia en el campo del reconocimiento de imágenes. Además, se utilizan algunas estrategias de aumento de datos especialmente diseñadas para el análisis de lesiones de la piel con un 87.2% de precisión.

### 3. METODOLOGÍA

Para el desarrollo de esta investigación se utilizaron las imágenes de lesiones dermatoscópicas, las cuales se adquirieron a partir del conjunto de datos HAM10000 a través de varias instituciones (Codella et al., 2018). El conjunto de datos de entrenamiento consiste en 10,015 imágenes (327 de Queratosis actínica y carcinoma intraepitelial AKIEC, 514 de Carcinoma de células basales BCC, 1099 de Queratosis benigna BKL, 115 de Dermatofibroma DF, 1.113 de Melanoma MEL, 6,705 de Nevos melanocíticos NV y 142 de muestras de Lesiones vasculares VASC) con la etiqueta de enfermedad correspondiente y un conjunto de validación con 1,167 muestras. Las enfermedades correspondientes a cada etiqueta se muestran en la Tabla 1.

Tabla 1 Etiquetas del conjunto de Datos

Etiqueta	Enfermedad	Imagen
AKIEC	Queratosis actínica y carcinoma intraepitelial	
BCC	Carcinoma de células basales	
BKL	Queratosis benigna	
DF	Dermatofibroma	
MEL	Melanoma	

<b>NV</b>	Nuevos melanocíticos	
<b>VASC</b>	Lesiones vasculares	

Con el conjunto de imágenes se creó una de Red Neuronal Convolutiva (CNN) utilizando Keras y Tensor Flow, en donde se dividió el conjunto de imágenes en 3 partes: entrenamiento 80%, prueba 10 y validación 10%. Dichas imágenes que serán clasificadas a partir de los diferentes tipos de cáncer como se muestra en la Tabla 1. Los parámetros definidos en este estudio para la creación de los distintos modelos CNN. Los parámetros definidos son: Anchura de la imagen, Altura de la imagen, # de ejemplos de entrenamiento, # de pasos, # de épocas, # de características de la primera capa Conv1, # de características de la segunda capa Conv2 y Filtro. En donde se fue ajustando los pesos de a partir de la variación de los filtros en cada Kernel, la variación de las épocas, los pasos, la longitud de altura y los filtros en la primera capa de la red y la segunda con la finalidad de que el modelo fuera aprendiendo a partir de cada convolución. Por otro lado, se fueron dejando fijos los parámetros que generaron mejores resultados con respecto a la convolución anterior.

### 3.1 Experimentación con las variables del algoritmo de entrenamiento

En esta sección se muestran los resultados obtenidos de cada entrenamiento con diferentes valores de las variables de los diferentes modelos. Los resultados se observan en la Tabla 2.

Tabla 2 Experimentos de entrenamiento

Exp	Épocas	Longitud, altura	Batch_size	Pasos	Val_steps	Conv1	Conv2	Fil1	Fil2	Pool	Loss	acc
CNN1	20	150, 150	32	10000	10015	8	16	(3,3)	(2,2)	(2,2)	-	0.6695
CNN2	20	150, 150	32	10000	10015	16	32	(3,3)	(2,2)	(2,2)	5.3275	0.6695
CNN3	15	200, 200	32	10000	10015	16	32	(3,3)	(2,2)	(2,2)	5.3264	0.6695
CNN4	20	150, 150	32	1000	1000	8	16	(3,3)	(2,2)	(2,2)	1.2834	1.3094
CNN5	30	150, 150	64	10000	1000	16	32	(3,3)	(2,2)	(2,2)	1.1774	0.5652
CNN6	40	150, 150	64	100000	10000	16	32	(3,3)	(2,2)	(2,2)	1.0824	0.5714
CNN7	40	200, 200	32	100000	10000	16	32	(3,3)	(2,2)	(2,2)	10126	0.5714
CNN8	40	150, 150	32	100000	10000	16	64	(3,3)	(2,2)	(2,2)	1.1941	0.5292
CNN9	80	150, 150	32	100000	10000	32	64	(3,3)	(2,2)	(2,2)	0.6081	0.7665
CNN10	80	150, 150	32	1000000	100000	32	64	(3,3)	(2,2)	(2,2)	0.6241	0.7602
CNN11	120	150, 150	32	1000000	100000	32	64	(3,3)	(2,2)	(2,2)	0.3692	0.8745
CNN12	120	150, 150	32	10000	10000	32	64	(3,3)	(2,2)	(2,2)	0.3345	0.8708

La cantidad de imágenes en cada clase de la data set utilizado era diferente, por ello en los primeros tres experimentos la ganancia es la misma sin importar la variación en los valores de las variables. Debido a esto, se balanceo el conjunto de imágenes, dejando 115 imágenes en cada clase y utilizando las imágenes restantes para la predicción, esto del conjunto de entrenamiento. Se realizaron diferentes pruebas con el set de validación, balanceándose con 44 imágenes con cada una de las diferentes clases del modelo.

#### 4. RESULTADOS Y DISCUSIÓN

La precisión del entrenamiento obtenida en los primeros experimentos con el conjunto de datos no balanceado fue del 66.95% como se puede observar en los experimentos 1, 2 y 3 de la Tabla 2 en la Sección 3.1. La mejor precisión de entrenamiento obtenida con el conjunto de datos balanceado fue la del experimento del CNN11 con 87.45%. No obstante, la precisión en el experimento del CNN2 disminuyo levemente con respecto al experimento CNN11 con 87%. Por lo que se notó al realizar una comparación, que la precisión de las convoluciones CNN11 y la convolución CNN12 es poco significativa, manejando el mismo número de épocas, filtros y solo variando la cantidad de pasos.

Una vez obtenido el modelo y pesos del entrenamiento se hicieron pruebas de predicción utilizando las imágenes restantes del balanceo, obteniendo los resultados que se muestran en la Tabla 3.

Tabla 3 Porcentaje de predicción

Clase	Porcentaje
<b>Akiec</b>	29.54%
<b>Bcc</b>	4.54%
<b>Bkl</b>	0%
<b>Df</b>	90.90%
<b>Mel</b>	0%
<b>Nv</b>	79.54%
<b>Vasc</b>	29.54%

Análogamente, los porcentajes en 0% que se presentan en las clases Mel y BKL se puede asociar con la similitud que existe entre las imágenes de dichas clases con la clase Nv. Cuando se ejecuta se prueba el modelo de predicción con imágenes de la clase BKL y Mel, se predice en su mayoría como si fueran Nv. Es posible notar también el alto porcentaje de clasificación de la clase Dermatofibroma (DF) con un 90% seguido de la clase Nuevo melanocitos (Nv) con 79.84%

## 5. CONCLUSIÓN

Con este trabajo se investigó la capacidad de las Redes Neuronales Convolucionales de clasificar las 7 principales lesiones en la piel. Así mismo se crearon distintos modelos variando los diferentes parámetros determinados para el experimento, llevándonos a determinar la importancia del aumento de la época en la capacidad con la que aprende el modelo y el filtro con la eficiencia que lo hace. Así mismo se comprobó la similitud que tienen 3 de las lesiones en la piel, como lo son Nuevos melanocíticos NV, Queratosis benigna (Bkl) y Melanoma (Mel). Esta similitud también puede corresponder a la gran cantidad de imágenes que se tienen de la clase NV con respecto a Bkl y Mel, las cual posiblemente puede que esté llevando a un sesgo. Por otro lado, el modelo CNN11 fue capaz de clasificar las imágenes de las diferentes clases no mencionadas como Bcc, Akiec, Df y Vasc. Comparando con los resultados encontrados en la literatura el porcentaje de nuestro modelo no es el mejor; Mas sin embargo se acerca al resultado de los mejores con conjunto de imágenes privados similares para la predicción de lesiones de la piel. Para un desarrollo futuro sobre esta investigación, dependerá de la reducción de imágenes a por clase de tal manera que se balancee a partir de la clase que menor cantidad de imágenes presente y también a la identificación de características y reducción de estas en los filtros de los Kernel que nos puedan llevar a mejorar el modelo presentado.

## 6. REFERENCIAS BIBLIOGRÁFICAS

- American Cancer Society, 2016. ¿Qué es el cáncer de piel tipo melanoma?.. [En línea]. Available: <https://www.cancer.org/es/cancer/cancer-de-piel-tipo-melanoma/acerca/que-es-melanoma.html>. [Último acceso: 23 Julio 2019].
- Amirreza Rezvantalab H. S. K. S, 2018. «Dermatologist Level Dermoscopy Skin Cancer Classification Using Different Deep Learning Convolutional Neural Networks Algorithms,» p. 15, Castleman K., 1996. Digital Image Processing, New Jersey: Prentice-Hall, Englewood Cliffs,
- Brinker T. J., A. Hekler, A. H. Enk, J. Kloe, A. Hauschild, C. Berking, B. Schilling, S. Haferkamp, D. Schadendorf, S. Fröhling, J. S. Utikal y C. von Kalle, «A convolutional neural network trained with,» European Journal of Cancer, n° 11, pp. 148-154, 2019.
- Codella N. C. F., D. Gutman, M. E. Celebi, B. Helba, M. A. Marchetti, S. W. Dusza, A. Kalloo, K. Liopyris, N. Mishra, H. Kittler y A. Halpern, «Skin lesion analysis toward melanoma detection: A challenge at the 2017 International symposium on biomedical imaging (ISBI), hosted by the international skin imaging collaboration (ISIC),» 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), pp. 168-172, 2018.
- Challenge 2018, ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection, 20 Diciembre 2018. [En línea]. Available: <https://challenge2018.isic-archive.com/>.
- Developer I., 2018.«IBM Developer,» Redes neuronales convolucionales, 17 Diciembre [En línea]. Available: <https://www.ibm.com/developerworks/ssa/library/cc-convolutional-neural-network-vision-recognition/index.html>. [Último acceso: 23 Julio 2019].
- Ebenezer J. P. y J. C. Rajapakse, 2018. «Automatic segmentation of skin lesions using deep learning,» Cornell University,

- Goyal M. y J. C. Rajapakse, «Deep neural network ensemble by data augmentation and bagging for skin lesion classification,» 15 Julio 2018.
- Kitada S. y H. Iyatomi, «Skin lesion classification with ensemble of squeeze-and-excitation networks and semi-supervised learning,» 2018.
- Kechyn G, «Automatic lesion boundary detection in dermoscopy,» Cornell University, 2018.
- Organización Mundial de la Salud. 2018 Cáncer.. [En línea]. Available: <https://www.who.int/es/news-room/fact-sheets/detail/cancer>. [Último acceso: 23 Julio 2019].
- Lee Y. C., S.-H. Jung y H.-H. Won, «WonDerM. 2018. Skin lesion classification with fine-tuned neural networks,»
- Li K. M y E. C. Li, 2018. «Skin Lesion Analysis Towards Melanoma Detection via End-to-end Deep Learning of Convolutional Neural Networks,»
- Lu, Q. H. T. T. H. Nguyen, T. T. N. Nguyen, T. Z. Nguyen y T. Dat Tô, «Skin Lesion Analysis Towards Melanoma Detection for ISIC 2018,» HAL, 2018.
- Motsch, A. S. Motsch y T. Saguet, 2018. Lesion segmentation using U-Net network,» Cornell University, « p. 4,
- Pierluigi, C. A. Cuna y C. Distante, «A Dense CNN approach for skin lesion classification,» 2018
- Shapiro R. H. a. L, 1992..., Computer and robot vision, New York: Publishing Co
- Ray S., 2018. «Disease Classification within Dermoscopic Images Using features extracted by ResNet50 and classification through Deep Forest,» Corell University,
- Tschandl P., C. Rosendahl y H. Kittler, «The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions,» Scientific Data, n° 180161, 2018.