

## Aplicación del aprendizaje automático en Arqueología: ¿Un cambio de paradigma?

*The Application of Machine Learning to Archaeology: A Paradigm Shift?*

Olga Palacios Martínez  
Universidad Autónoma de Barcelona  
<https://orcid.org/0000-0002-8580-6315>  
olga.palacios@uab.cat

Enviado: 13/07/2022; Revisado: 30/11/2022; Aceptado: 22/12/2022

### Resumen

Aunque las primeras aplicaciones de aprendizaje automático en arqueología datan de finales de los años 90, no ha sido hasta el año 2019 cuando su uso se ha empezado a extender. ¿Qué ventajas tiene esta metodología respecto a otros métodos con una trayectoria más larga en arqueología? ¿Se puede aplicar en todos los ámbitos de estudio? La presente contribución tiene el objetivo de dar respuesta a estas cuestiones a través de una exhaustiva revisión de los estudios arqueológicos realizados con esta metodología y desarrollando un modelo con un algoritmo concreto, las redes bayesianas, para explorar sus beneficios y limitaciones.

**Palabras clave:** Aprendizaje automático, arqueología, metodología, redes bayesianas, beneficios y limitaciones.

### Abstract

Despite initial attempts to apply machine learning to archaeology dating back to the late 1990s, it was not until 2019 that its use began to become widespread. What advantages does this methodology have over previous methods? Can it be applied to all relevant fields of study? This article aims to answer these questions through an exhaustive review of archaeological studies that employ this methodology and by developing a model with a specific algorithm, based on Bayesian networks, to explore its benefits and limitations.

**Keywords:** Machine Learning, Archaeology, Methodology, Bayesian Networks, Benefits and Limitations.

## 1. INTRODUCCIÓN

Entender el pasado es el objetivo de la ciencia arqueológica. ¿Por qué una sociedad vivió en un sitio y no en otro? ¿Qué comía y por qué prefería unos recursos a otros? ¿Cuánta gente vivía en un poblado y cómo se organizaban? Estas cuestiones son tan solo algunas de las múltiples preguntas a las que se intenta dar respuesta a partir del registro arqueológico. Partiendo de la premisa que para comprender un sistema social es necesario considerar sus dinámicas socioeconómicas y su entorno ecológico, en los años 50 se desarrolló la Teoría de los Sistemas Complejos (TSC) (VON BERTALANFFY, 1950) que proponía investigar a las sociedades como sistemas complejos con diferentes variables y relaciones no lineales. Esta innovación representó un cambio radical en la investigación arqueológica, puesto que TSC aportó una nueva manera de entender el dinamismo en el pasado a partir del concepto de sistemas socioecológicos.

La estructura de un sistema socioecológico está definida por la interacción entre comportamientos sociales (ej., tipo de dieta, organización doméstica y del trabajo) con aspectos ecológicos definidos por la localización dónde se llevó a cabo la acción social (ej., productividad del suelo, temperatura media). Esta nueva conceptualización representó un progreso en la modelización del comportamiento social como un sistema influenciado por muchas variables diferentes y con distinta intensidad (ej., NETO *et al.*, 2018; ZEDER, 2017; SMITH, 2015). Para modelar esta estructura, podemos dividir el sistema en tres elementos distintos: los *inputs* (los datos conocidos), los *outputs* (lo que queremos descubrir, la cuestión investigada) y el/los *mecanismo/s* (los procesos y estructura de relaciones a través de los cuales interactúan los inputs y los outputs). Pongamos el caso que queremos comprender por qué las sociedades neolíticas practicaban la agricultura y la ganadería en lugar de la caza, la recolección o la pesca (*output*). Una manera de explorar esta cuestión sería a partir de los datos de las variables climáticas o topográficas (*inputs*). Esta aproximación se basa en la idea de que los diferentes elementos están relacionados entre sí y, por tanto, estudiando la fuerza de estas relaciones y su organización (*mecanismo*), podremos comprender cómo funcionaron en el pasado.

Tomando en cuenta esta aproximación teórica, los métodos cuantitativos y computacionales permiten explorar estas relaciones entre elementos y predecir información desconocida o no observada de los sistemas a partir de la que sí que tenemos registrada (TEWARI *et al.*, 2020).

Con este objetivo, en arqueología hay principalmente dos líneas de estudio: los métodos matemáticos tradicionales (tienen mayormente una función descriptiva) y, los computacionales, (con mayor capacidad interpretativa y exploratorio) (BARCELÓ, 2008). Concretamente, dentro de los métodos computacionales se encuentra la simulación, que permite experimentar con diferentes escenarios *in silico* (desarrollados vía simulación computacional) y evaluar sus resultados para compararlos, finalmente, con el registro arqueológico. Esta clase de modelos se pueden clasificar en dos categorías: los modelos basados en agentes (*agent-based modelling*) y los modelos dinámicos (*dynamic modelling*). Se diferencian por la metodología que utilizan, ya que los modelos basados en agentes se construyen

a través de un software específico como NetLogo (WILENSKY, 1999), mientras que en los modelos dinámicos se utilizan ecuaciones diferenciales. Algunos ejemplos paradigmáticos de modelos basados en agentes centrados en la investigación de sistemas socioecológicos del pasado son «The Village Ecodynamics» (KOHLER y VARIEN, 2012), «WELASSIMO» (BAUM *et al.*, 2016; BAUM, 2016), «The Mediterranean Landscape Project» (BARTON *et al.*, 2012; BARTON *et al.*, 2010; ULLAH, 2011; ULLAH y BERGIN, 2012). Asimismo, los modelos dinámicos más representativos de dinámicas sociales son el modelo «Prey-Predator» (LOTKA, 1920; VOLTERRA, 1926), «Wave of advance» (AMMERMAN y CAVALLI-SFORZA, 1979, 2014), a partir de los cuales se han planteado otras propuestas modelando la expansión neolítica (ISERN *et al.*, 2017; FORT, 2022).

Por otro lado, los métodos computacionales también incluyen la metodología del aprendizaje automático (*machine learning*), AA, es una rama de la Inteligencia artificial basada en la utilización de una «máquina» (ordenador) para aprender automáticamente nueva información a partir de escenarios anteriores ya conocidos. Emplea el mismo razonamiento que el método inductivo tradicional, por ejemplo, para interpretar un yacimiento: el arqueólogo lo compara con otros yacimientos del mismo contexto con características similares y, basándose en su propio criterio (el cual está modelado por su educación, experiencia o convicciones), propone la interpretación más probable. Estos métodos computacionales pueden generar modelos predictivos, es decir, que sus resultados se pueden utilizar para predecir eventos desconocidos o no observados (TEWARI *et al.*, 2020), pero la diferencia es que en el aprendizaje automático, este proceso de aprendizaje es realizado por el ordenador a través de un algoritmo que explora la base de datos, identifica las tendencias y, basándose en estas, predice los casos futuros (o los pasados, como en arqueología). Por lo tanto, en AA no se necesitan hipótesis previas sobre las relaciones entre las variables porque el modelo se aprende a partir de los datos conocidos. Por contra, en los modelos estadísticos y de simulación, las relaciones entre las variables se tienen que conocer de antemano para definir su estructura.

Pese a los múltiples beneficios de la metodología de AA, su aplicación en arqueología todavía es reducida dado que hay pocos estudios realizados que hagan una recopilación de los campos de análisis dónde se ha aplicado, el tipo de algoritmos utilizados o desarrollen un análisis crítico sobre sus puntos fuertes y debilidades. En este sentido, contrasta con otras áreas de investigación dónde sí que ha habido esfuerzos para sistematizar su aplicación y definir su aplicabilidad (ej., EDEH *et al.*, 2021). Concretamente, desde otras ciencias sociales se han llevado a cabo diversos estudios identificando las limitaciones del método y se han definido propuestas para superarlas (ej., RADFORD y JOSEPH, 2020; CROWFORD *et al.*, 2019; JACOBS y WALLACH, 2019; LAZER y RADFORD, 2017).

Para la modelización de sistemas socioecológicos en arqueología, es más común emplear las simulaciones basadas en agentes, dónde se han implementado numerosos estudios explorando su capacidad de adecuación para aplicarlo en arqueología y se han desarrollado pautas de buenas prácticas (por ejemplo, GRIMM y RAILSBACK, 2012; MÜLLER *et al.*, 2014). A nivel de AA en arqueología, hay sobre todo estudios de introducción del método (por ejemplo, BICKLER, 2021; DAVIS, 2020a,

2020b; RAMAZZOTTI, 2020; MACKENZIE, 2017) pero no hay ninguna publicación que resuma los algoritmos disponibles, para qué sirven, cómo han sido aplicados en arqueología (o no) y evalúe su idoneidad para investigar sistemas socioecológicos. En consecuencia, la presente contribución tiene los objetivos siguientes:

- Caracterizar la aplicación de la metodología del aprendizaje automático en arqueología y, más específicamente, en el ámbito de estudio de sistemas socioecológicos.
- Definir los beneficios y limitaciones del método en este ámbito de investigación.

Para abordar estos objetivos, se ha empleado una doble metodología combinando una detallada revisión bibliográfica de los trabajos desarrollados en el ámbito arqueológico empleando AA, especialmente centrado en su aplicación para explorar sistemas socioecológicos. Adicionalmente, se ha realizado una aplicación práctica con un método de AA, las redes Bayesianas, para evaluar la idoneidad de aplicación de este método en este ámbito de estudio.

## 2. METODOLOGÍA

### 2.1. Principios del aprendizaje automático

Para la construcción de un modelo de aprendizaje automático es muy importante tener disponible una base de datos con un gran número de casos para poder clasificar y predecir los casos desconocidos. En función del tipo de datos y la cuestión planteada, un algoritmo puede que funcione mejor que otros. Hay diversos tipos de algoritmos en AA que sirven para distintas finalidades y se agrupan en dos clases principales: métodos *no supervisados* y *supervisados* (ALLOGHANI *et al.*, 2020) (Tabla 1). Los métodos *no supervisados* se emplean para identificar patrones, estructuras y distribuciones con datos sin etiquetar (es decir, no diferenciados); se utilizan para descubrir patrones en los datos sin que el/la investigador/a intervenga, por este motivo se llaman «no supervisados» (DHALL *et al.*, 2020). El objetivo es desarrollar un modelo para identificar la estructura subyacente o distribución de los datos para aprender nuevos casos o escenarios. Es un método especialmente adecuado para desarrollar análisis exploratorios y descriptivos de grandes bases de datos. Esta aproximación permite agrupar objetos «parecidos» pero sin seguir unas normas (ver KOHONEN, 2001; ENGEL y VAN DER BROECK, 2001 para una descripción de los mecanismos de agrupación), a diferencia de la clasificación que sigue una normal preestablecida y permite diferenciar los objetos en clases.

Tabla 1

*Clasificación de los principales algoritmos de aprendizaje automático.*

	MÉTODOS NO SUPERVISADOS	MÉTODOS SEMI-SUPERVISADOS	MÉTODOS SUPERVISADOS
<i>Tipo de datos</i>	No etiquetados	No etiquetados	Etiquetados
<i>Función</i>	<p>(a) Reducir la dimensionalidad de los datos</p> <p>(b) Detección de outliers</p> <p>(c) Agrupación de casos</p>	<p>Construir etiquetas a partir de los casos anteriores</p> <p>Para realizar funciones supervisadas, pero con datos no supervisados</p>	<p>Clasificación de nuevos casos a partir de una norma general</p> <p>Regresión para predecir nuevos casos a partir de los conocidos</p>
<i>Algoritmos principales</i>	<p>(a) Principal component analysis, Independent component analysis, Manifold learning, Autoencoders</p> <p>(b) Isolation forest, Local outlier factor, Minimum covariance determinant</p> <p>(c) K-means, Hierarchical and Spectral clustering, DBSCAN y OPTICS, Affinity propagation, Mean shift y BIRCH, Gaussian mixture models, Self-organising map, Discriminant Analysis</p>	Active learning	<p>Support vector machine</p> <p>K-nearest neighbour</p> <p>Deep learning (Neural networks, Convolutional neural networks, Deep belief networks, Deep reinforcement learning)</p> <p>Decision trees</p> <p>Regression trees</p> <p>Classification and regression trees (CART)</p> <p>Logistic regression</p> <p>Random forest</p> <p>Bayesian networks</p>

Fuente: Elaboración propia.

Sin embargo, los métodos no supervisados no pueden realizar funciones de clasificación dado que se necesitan datos etiquetados y con sus valores agrupados en clases (requisito que marca la distinción entre ambos métodos). Es así como esta función se realiza con *métodos supervisados*, los cuales tienen el objetivo de identificar la interpretación más probable considerando todas las posibles explicaciones conocidas. Si bien los métodos no supervisados están limitados a analizar y agrupar datos sin etiquetar, los métodos supervisados se aplican a datos etiquetados y usan algoritmos específicos para predecir modelos a partir de los datos (esto también se emplea para validar los modelos) y hacer nuevas predicciones. Los métodos supervisados no solamente permiten clasificar y organizar los datos en categorías, sino que permiten aprender nuevos datos a partir de los ya conocidos para, finalmente, desarrollar interpretaciones más robustas (BICKLER, 2021). Algunos autores proponen también los métodos semi-supervisados (KLASSEN *et al.*, 2018), empleados cuando los datos no están etiquetados, pero se quieren realizar funciones supervisadas.

Independientemente del método, la metodología de AA se caracteriza por necesitar un gran volumen de casos para poder computar el modelo, puesto que el modelo se aprende a partir de los casos anteriores. Este aspecto puede representar una desventaja en arqueología porque los datos obtenidos son a veces difíciles de cuantificar y no se suelen tener muchos casos con las mismas características, calculados de la misma manera, bien documentados, para crear modelos. Por otra

parte, en la última década se ha extendido la práctica de publicar las bases de datos en abierto y, así, datos que en sí son lentos de generar e interpretar, se han democratizado, proporcionando la oportunidad de ampliar los estudios a través de la reutilización de estos datos (FANIEL *et al.*, 2013).

La principal crítica del AA es que genera modelos difíciles de interpretar (ej., RADFORD y JOSEPH, 2020; JACOBS y WALLACH, 2019) porque suelen ser cajas negras (*black boxes*), lo que significa que desconocemos los mecanismos internos o procesos a través de los cuales se diseña el modelo. En algunos casos, puede que para el/la investigador/a no sea relevante conocer cómo se ha diseñado el modelo, pero en otros, a lo mejor tener un control total del desarrollo del modelo sea crucial para interpretar cómo se han obtenido los resultados de los outputs.

## 2.2. Aplicación del aprendizaje automático en arqueología

Con el fin de cuantificar la aplicación de esta metodología en el campo arqueológico, se ha realizado una búsqueda de artículos en dos bases de datos bibliográficas, Scopus (ELSEVIER, 2004) y Web of Science (CLARIVATE ANALYTICS, 2022), de trabajos que tratan de «machine learning» (campo «all fields») y «archaeology» (campo «article title, abstract, keywords») en «English/Spanish/French». Dado que es un método bastante reciente, la búsqueda no se restringió por año de publicación. En Scopus se obtuvieron 808 resultados y en Web of Science 87. A continuación, se analizó exhaustivamente cada artículo y las referencias a otros casos de estudios en la bibliografía con la finalidad de obtener un registro más completo. Los criterios de selección de los artículos han sido los siguientes:

- Utilizan un algoritmo de AA (individualmente o en conjunción con otros algoritmos o métodos fuera de AA) para investigar una cuestión arqueológica.
- Se han excluido los artículos de análisis metodológico o teórico.
- Se han excluido los artículos que mencionaban AA, pero utilizaban otro método para desarrollar la investigación.
- Se han excluido los artículos que mencionaba la arqueología como una posible aplicación de AA, pero el caso de estudio era de otro tema no relacionado.

Seguidamente, se construyó la base de datos con los artículos seleccionados y se agruparon según (i) la cuestión arqueológica que exploraba (por ejemplo, si tratan sobre la gestión socioeconómica del pasado o sobre el reconocimiento de patrones de materiales arqueológicos) y (ii) el algoritmo o algoritmos de AA que utilizan. En total, se han seleccionado 91 artículos (Apéndice Tabla 1). La razón de este bajo índice es debido a que las grandes bases de datos bibliográficas también habían considerado los artículos que mencionaban la arqueología como una aplicación más en AA, pero el estudio trataba sobre otro tema, o artículos arqueológicos que mencionaban la posibilidad de llevar a cabo el análisis con AA, pero finalmente empleaban otro método cuantitativo o computacional. Adicionalmente, cabe mencionar que, en diversos casos, los modelos se construyen principalmente para probar el método más que para explorar preguntas arqueológicas. Así mismo, hay

algunos estudios que no son replicables porque el algoritmo no se especifica, solo se dice que utilizan «un algoritmo de aprendizaje automático». En este caso, no se han considerado en la base de datos. También hay muchos modelos que están contruidos desde el «conocimiento experto» y, por lo tanto, no son modelos de AA.


A partir de la recopilación bibliográfica, se han diferenciado cuatro temáticas principales dentro de arqueología que emplean AA. Cada grupo engloba aplicaciones con objetivos diferentes, pero que tratan del mismo tema o trabajan con el mismo tipo de material. En primer lugar, los análisis de materiales y estructuras incluyen el procesamiento de imágenes (ej. COLMENERO-FERNÁNDEZ y FEITO, 2021), afiliación cultural (ej. GROVE y BLINCKHORN, 2020), estructuras (ej. MONNA *et al.*, 2020), arte (TSIGKAS *et al.*, 2020), cerámica (GUALANDI *et al.*, 2021) o marcas de procesamiento (ej. CIFUENTES-ALCOBERAS y DOMÍNGUEZ-RODRIGO, 2019; COURTNEY *et al.*, 2019). En segundo lugar, las aplicaciones para los análisis espaciales se centran en predecir la ubicación de asentamientos desconocidos (ej. BONHAGE *et al.*, 2021; REICH *et al.*, 2021) y la posible localización de estructuras específicas como, por ejemplo, de enterramiento (ej. BERGANZO-BESGA *et al.*, 2021; CHEN *et al.*, 2021; CASPARI y CRESPO, 2019). También se emplea en estudios espaciales con el objetivo de diseñar estrategias para la prevención, protección y gestión del patrimonio arqueológico (ej., FRIGGENS *et al.*, 2021; DAVIS *et al.*, 2021; XU *et al.*, 2019; CASTIELLO y TONINI, 2019). En tercer lugar, los estudios de sistemas socioecológicos utilizan AA para explorar diversas temáticas como los movimientos migratorios (VAHDATI *et al.*, 2019), la gestión de los recursos sociales y económicos (ej. DAVIS y DOUGLAS, 2021; AHEDO *et al.*, 2021, 2019; BURRY *et al.*, 2018; BARCELÓ *et al.*, 2015; ALBERTI, 2014) y las dinámicas culturales (HYAFIL y BAUMARD, 2022). Finalmente, también se emplea para analizar documentación escrita, concretamente para clasificar caracteres y palabras (ej. HALIASSOS *et al.*, 2020; RAMYA *et al.*, 2019; BRANDSEN *et al.*, 2020), traducir textos (SANDERS, 2018) y para crear aplicaciones patrimoniales para difundir la documentación escrita (FABRICIUS, 2022).

Las primeras aplicaciones de AA en arqueología datan de inicios del 2000 con su aplicación para clasificar materiales arqueológicos, principalmente cerámica, y para identificar la ubicación de asentamientos (Gráfico 1). En 2014 se publicaron los primeros estudios abordando el análisis de dinámicas socioecológicas, pero de forma muy minoritaria, tendencia que se conserva actualmente. Los estudios con AA para analizar documentación escrita siguen una dinámica parecida, debido a que sus primeras aplicaciones datan en 2018, pero actualmente su aplicación es todavía limitada. Por otro lado, el número de estudios de análisis de materiales y estructuras y estudios espaciales aumentaron considerablemente en 2019 y esta dinámica se ha mantenido hasta la fecha. A nivel de importancia relativa, el mayor número de estudios publicados utilizando AA son los estudios de materiales y estructuras (49,45%), seguidos por los estudios espaciales (29,67%), de sistemas socioecológicos (14,29%) y de documentación escrita (6,59%).



GRÁFICO 1

Cuantificación de los estudios realizados en arqueología, empleando aprendizaje automático, divididos por año y por campo de estudio.




Se observa un incremento exponencial de publicaciones en el año 2019, sobre todo en las áreas de investigación espacial y de reconocimiento de estructuras y materiales.

Fuente: Elaboración propia.

Respecto a qué métodos de AA son los más comunes en arqueología, el 90% de los estudios analizados utilizan métodos supervisados, siendo los algoritmos más utilizados el *deep learning* (incluye *neural networks*, *convolutional neural networks*, *deep belief networks* y *deep reinforcement learning*) y el *random forest* (Gráfico 2). Los métodos no supervisados y semi-supervisados exclusivamente se emplean para analizar materiales y estudiar sistemas socioecológicos. Normalmente, se emplean este tipo de algoritmos en combinación con un algoritmo supervisado. En algunos casos, como por ejemplo MONNA *et al.*, 2020 y COURTNEY *et al.*, 2019, se exploran diferentes algoritmos con el objetivo de evaluar cuál es el que produce mejores resultados.



GRÁFICO 2  
 Algoritmos supervisados, no supervisados y semi-supervisados divididos por cada ámbito de investigación.



Fuente: Elaboración propia.

En el caso de los modelos socioecológicos, observamos que su uso es muy minoritario y emplea diversos algoritmos supervisados (*logistic regression*, *deep learning*, *regression tree*, *support vector machine*, *bayesian networks*, *random forest* y *k-nearest neighbour*) y no supervisados (solamente el algoritmo de *principal component analysis*). Para poder interpretar esta diversidad en los algoritmos empleados para explorar este ámbito de la investigación, sería necesario identificar y calcular qué métodos son los más comunes para abordar estas cuestiones e identificar posibles diferencias. En vista de que sería muy costoso aplicar todos los algoritmos de AA para compararlos, en el presente estudio se ha optado por aplicar las redes bayesianas (KOLLER y FRIEDMAN, 2009; NEAPOLITAN, 2004), un algoritmo probabilístico de AA supervisado que se caracteriza por ser un modelo de *caja blanca* (*white box*). Aparte de producir modelos predictivos (como todos los algoritmos supervisados), también son explicativos, dado que a través de su representación se obtiene información sobre cómo las variables se relacionan; y estas relaciones indican correlaciones. Por otro lado, las redes bayesianas se representan en forma de *modelo directo acíclico* que permiten obtener la distribución de probabilidad de las variables del modelo y, por tanto, obtener la probabilidad a partir de las probabilidades condicionales de los nodos con los que está relacionado (Fig. 1).




Figura 1. Ejemplo de una red bayesiana simple. C es el padre de X<sub>1</sub> y X<sub>2</sub>, las cuales computan las probabilidades teniendo en cuenta C. Fuente: Elaboración propia.

### 2.3. Construcción de un modelo socioecológico con redes bayesianas

El objetivo del modelo construido para explorar la aplicación de AA y, concretamente, el algoritmo de redes bayesianas es definir si el tipo de subsistencia de las comunidades agroganaderas de pequeña escala están influenciadas por las condiciones ecológicas de su entorno. El modelo se ha construido en cinco fases: (i) Creación de la base de datos; (ii) Preprocesamiento de los datos; (iii) Construcción del modelo; (iv) Validación del modelo; (v) Aplicación del modelo y obtención de los resultados (Fig. 2).

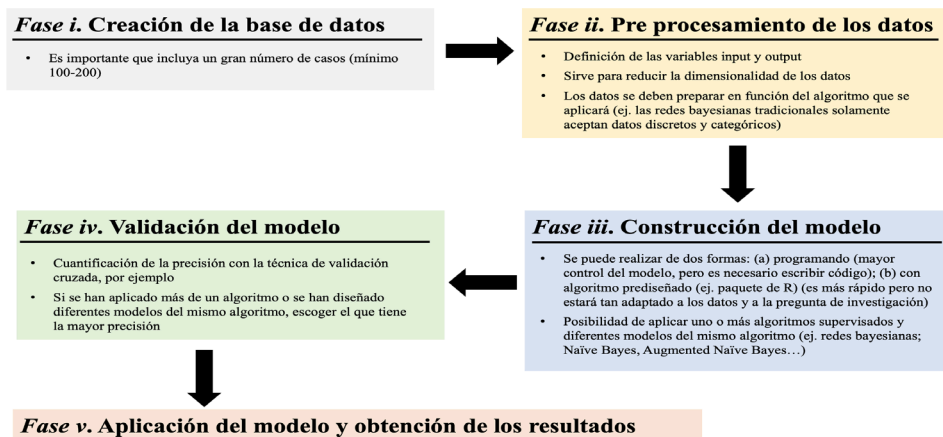


Figura 2. Esquema de proceso de modelización. Fuente: Elaboración propia.

**Fase i. Creación de la base de datos:** para estudiar esta cuestión, se ha seguido la línea de investigación de estudios interdisciplinarios que emplean los datos históricos y etnográficos para comprender las dinámicas socioeconómicas del pasado (ej., PEREGRINE, 1996; GANTLEY *et al.*, 2018; FERRARO *et al.*, 2019; DESMOND, 2014; WATTS *et al.*, 2022; ATKINSON y WHITEHOUSE, 2011). No se implica que a partir de la etnografía podamos inferir procesos de las comunidades del pasado, pero sí se utiliza esta disciplina para sugerir y cuantificar la viabilidad de algunas prácticas que no son observables en el registro arqueológico porque no son materiales (ej. preferencias, decisiones, prácticas sociales, etc.). En total, se recopiló 265 sociedades etnográficas de pequeña escala (menos de 1000 habitantes) y agroganaderas (al menos el 50% de su subsistencia debe estar basada en recursos agrícolas y/o ganaderos) de la base de datos D-PLACE (KIRBY *et al.*, 2016) (Apéndice Tabla 2).

**Fase ii. Preprocesamiento de los datos:** todo el procesamiento, creación del modelo, validación y obtención de los resultados se ha desarrollado con R (R CORE TEAM, 2022) y el script está disponible en Apéndice Script 1. Una vez los datos de las sociedades estaban recopilados, se procedió a su procesamiento. Las redes bayesianas estándares no procesan los datos continuos, de manera que se han discretizado todas las variables con la función *discretize* del paquete *arules*, estableciendo las categorías a partir de su distribución ideal en dos, tres o cuatro clases (Tabla 2). En el proceso de discretización se ha tenido en cuenta agrupar los valores de cada variable en número reducido de clases porque las redes calculan la probabilidad de cada valor condicionada a las probabilidades de los valores de las otras variables y, consecuentemente, el modelo aumenta su complejidad computacional a medida que aumentamos las clases. También es necesario tener en cuenta que, si las clases están igualmente representadas, es decir, que tienen el mismo número de casos en cada una, el modelo tendrá la misma capacidad de predicción para todos los valores y evitar que priorice los valores más representados. En consecuencia, variables de caza, recolección o pesca, por ejemplo, tienen agrupados todos los casos de intensidades entre el 15 - 100 % en una única categoría que se llama '>150', mientras que agricultura, que tiene muchos más casos de intensidades superiores al 15%, tiene más categorías para representar este intervalo.

TABLA 2  
Variables de la base de datos con sus categorías discretizadas

Variables	Categorías		
Distancia a la costa	<140	140-600	≥600
Elevación	<300	300-800	≥800
Pendiente	<0,75	0,75-2,5	≥2,5
Temperatura media anual	<5	5-20	≥20
Variación de la temperatura media	<1,3	1,3-20	≥20
Constancia de la temperatura	<0,5	0,5-0,7	≥0,7
Contingencia de la temperatura	<0,12	0,12-0,2	≥0,2
Precipitación media mensual	<1,06e+05	1,06e+05-1,67e+05	≥1,67e+05
Variación de la precipitación media	<7,86e+09	7,86e+09-1,49e+10	≥1,49e+10
Constancia de la precipitación	<0,4	0,4-0,5	≥0,5
Contingencia de la precipitación	<0,2	0,2-0,3	≥0,3
Producción primaria neta media mensual	<1	1-3	≥3
Constancia de la producción primaria neta	<0,2	0,2-0,3	≥0,3
Contingencia de la producción primaria neta	<0,2	0,2-0,3	≥0,3
Agricultura	<45	45-75	≥75
Ganadería	<15	15-45	≥45
Caza	<15	≥15	
Recolección	<15	≥15	
Pesca	<15	≥15	

Las variables se han discretizado según su distribución ideal para asegurar una representación homogénea de todas sus clases. Fuente: Elaboración propia.

**Fase iii. Construcción de los modelos:** los estudios anteriores de redes bayesianas para modelar sistemas socioecológicos empleaban la estructura de Naïve Bayes (NB), que es un algoritmo que tiene una estructura predeterminada en la cual únicamente hay un output y todos los inputs están relacionados con este. Es así como NB se asume que los inputs no están relacionados entre ellos (por ejemplo, que las variables ecológicas como la temperatura y la precipitación no están relacionadas) y que todos los inputs están relacionados con el output (por ejemplo, que la elevación está igual de relacionada que la temperatura con la agricultura). Dado que Teoría de los Sistemas Complejos argumenta que las variables de un sistema están interrelacionadas de manera compleja y no lineal, en este estudio, se ha optado por modelar el mismo sistema con otras estructuras más complejas como el Augmented Naïve Bayes (ANB) (permite las interrelaciones entre inputs) y sin restricciones (permite más de un output y también incluye las interrelaciones entre outputs) para establecer comparaciones con el modelo NB (en la Tabla 3 están más detalladas las diferencias entre los tres modelos).

TABLA 3  
Principales características de los tres modelos de las redes bayesianas

Características	Modelo Naïve Bayes	Modelo Augmented Naïve Bayes	Modelo sin restricciones
<i>Algoritmo de aprendizaje de la estructura</i>	Estructura fija con relación de un output a los inputs (caja negra)	Hill-climbing con el criterio AIC o BIC. Relaciones de un output a inputs, las relaciones entre inputs están permitidas (caja blanca)	Hill-climbing con el criterio AIC o BIC. Relaciones entre outputs a inputs a la vez, interrelaciones entre outputs e interrelaciones entre inputs están permitidas (caja blanca)
<i>Objetivo</i>	Predicción	Predicción y explicativa (relaciones entre inputs)	Predicción y explicativa (relaciones output - input, entre inputs y entre outputs)
<i>Beneficios</i>	Simple y buen equilibrio entre capacidad predictiva y simplicidad  Relaciones binarias (un input y un output)	Permite relaciones entre los inputs, pero sólo un output a la vez  Relaciones binarias	Representa las relaciones entre todos los outputs y todos los inputs a la vez
<i>Limitaciones</i>	Ignora las relaciones entre inputs y entre outputs	Ignora las relaciones entre inputs y entre outputs	Más complejo que los otros modelos y, por lo tanto, es necesaria más potencia computacional

Fuente: Elaboración propia.

Los modelos se han aprendido con el *paquete bnlearn* (SCUTARI y DENIS, 2021) que implementa la estructura y el aprendizaje paramétrico. Esta estructura ha sido definida siguiendo los criterios y parámetros más comunes en la implementación de redes bayesianas en los diferentes ámbitos de investigación (ej., ATIENZA *et al.*, 2022; PALACIOS *et al.*, 2022; FAN *et al.*, 2022; CHOBTHAM y CONSTANTINOU, 2020). Se ha utilizado el algoritmo hill-climbing del *paquete gRain* (HØJSGAARD, 2012) para aprender la estructura de búsqueda y puntuación de la representación ya que lo hace a partir de la combinación que maximiza la función de puntuación. Se tienen en cuenta dos funciones de puntuación, el Bayesian Information Criterion (BIC) y el Akaike Information Criterion (AIC). Ambos criterios son logaritmos de probabilidad, pero AIC penaliza menos y, por lo tanto, crea grafos con más conexiones. Los parámetros se han establecido siguiendo el criterio de máxima verosimilitud, que representa el procedimiento más común.

**Fase iv. Validación de los modelos:** para calcular la precisión del modelo se utilizó la técnica de validación cruzada donde  $k=5$ , es decir, se emplearon cuatro casos para predecir el quinto y, comparando la predicción con el resultado original, se obtiene el valor de precisión. Este proceso se lleva a cabo cinco veces para cada modelo. Se ha seleccionado  $k=5$  porque estudios recientes indican que este número es suficiente para validar la robustez del modelo y, además, tiene la ventaja de ahorrar tiempo y capacidad computacional (MARCOT y HANEA, 2020).

A continuación, para seleccionar el modelo que produjera resultados con mayor precisión, se empleó la prueba t-test para comparar primero el modelo NB con el modelo ANB y, el que tenía el valor más alto, se contrastó con el

modelo sin restricciones. Por otro lado, en todos los casos se utilizó el modelo sin restricciones para obtener la información explicativa debido a que es el único que permite relaciones entre las variables de subsistencia (outputs) y las variables ecológicas (inputs).

**Fase v. Aplicación del modelo y obtención de los resultados:** como se ha mencionado en la sección 2.2, las redes bayesianas producen dos tipos de información:

- *Información explicativa:* a partir del cálculo de la fuerza de las relaciones con la función `arc.strength`, implementada en el paquete `bnlearn`, podemos calcular la fuerza de las relaciones entre los outputs y los inputs e identificar aquellas significativas en forma de p-valor. Además, las redes son ilustradas mediante grafos directos acíclicos donde se representan las relaciones y las distribuciones de las variables dentro del sistema. Es importante apuntar que esta información es solamente observable en los modelos ANB y el Modelo sin restricciones. En cambio, en el caso del modelo de NB, las relaciones entre inputs y entre outputs están restringidas y, en consecuencia, su gráfico no es informativo porque fuerza la relación bilineal entre cada output y cada input, aunque realmente no estén relacionadas o lo estén de forma no lineal.
- *Información predictiva:* a partir del modelo construido podemos predecir las clases de los outputs en función de los valores de los inputs. Por lo tanto, el modelo también puede ser utilizado para predecir escenarios que queramos conocer y no estén registrados en la base de datos que hemos empleado para crear el modelo.

### 3. RESULTADOS

En el proceso de validación de los resultados solamente se encontró un caso, cuando se predice la ganadería, en el que uno de los modelos, el NB tuviera una precisión superior a los otros modelos (p-valor: 0,03058). Únicamente en este caso se ha explorado con un modelo, en cambio, en todos los otros casos se han tenido en cuenta los tres modelos (NB, ANB y sin restricciones).

#### 3.1. Información explicativa

En la Tabla 4 se muestran las correlaciones positivas entre el tipo de subsistencia y el medio dónde viven las comunidades. Podemos observar un mayor número de correlaciones positivas en el modelo de NB, hecho que indica que cuando más complejo es el modelo porque más interrelaciones son permitidas, los outputs están menos determinados por los inputs. Por otro lado, las estrategias de subsistencia más correlacionadas con el medio son la ganadería, con la media y constancia de producción primaria neta del suelo y la precipitación media mensual, y la caza con la distancia a la costa y la constancia y contingencia de la producción primaria neta del suelo. Es así como se evidencia la relevancia de la productividad del suelo para definir la intensidad en la que se practican estas dos estrategias.

TABLA 4  
Relaciones significativas identificadas a partir de los tres modelos. Clasificación p-valores: 0.05-0.01=\*; 0.01-0.001=\*\*; <0.001=\*\*\*

Output	Modelo	Relación significativa	p-value
<b>Ganadería</b>	NB	Ganadería - Producción primaria neta media mensual	1,49E-02 *
	NB	Ganadería – Constancia en la producción primaria neta	2,15E-02 *
	ANB	Ganadería – Precipitación media mensual	4,53E-06 ***
	ANB	Ganadería - Producción primaria neta media mensual	1,49E-02 *
	ANB	Ganadería - Constancia de la producción primaria neta	2,15E-02 *
<b>Caza</b>	NB	Caza – Distancia a la costa	2,15E-02 *
	NB	Caza - Constancia de la producción primaria neta	7,23E-03 **
	NB	Caza - Contingencia de la producción primaria neta	1,41E-04 ***
<b>Recolección</b>	NB	Recolección – Constancia en la precipitación	9,66E-03 *
<b>Agricultura</b>	Sin	Ganadería – Agricultura	3,59E-11 ***
<b>Ganadería</b>	restricciones		
<b>Caza</b>			
<b>Recolección</b>			
<b>Pesca</b>			

Fuente: Elaboración propia.

En cuanto a la interrelación entre las variables de subsistencia, la ganadería ejecuta la función de nexo entre el grupo caza – recolección, la agricultura y la pesca (Fig. 3). Es interesante el hecho que la caza y la recolección están muy interrelacionadas entre ellas, así como la ganadería con la recolección. Por otro lado, las variables ecológicas también están fuertemente relacionadas entre ellas. De hecho, podemos dividir las en dos grupos: variables topográficas y temperatura media (relación de elevación con la temperatura media, pendiente y distancia a la costa), variables del clima y productividad del suelo. Un aspecto interesante que destacar es el rol de la pesca en el modelo ya que conecta las variables de subsistencia con las del medio, aunque no se ha identificado ninguna relación estadísticamente significativa de la pesca con las otras variables. Una posible interpretación al rol de la pesca sería la propuesta en el estudio de AHEDO *et al.* (2021), dónde se argumenta que la pesca no está directamente determinada por el medio sino por las dinámicas internas de la comunidad como estrategia para diversificar los recursos cuando estos son limitados. Siguiendo esta explicación, la pesca estaría relacionada con las otras estrategias de subsistencia y entorno, pero no limitada por estas. No obstante, necesitaríamos más datos y evidencia para confirmar esta hipótesis.





Figura 3. Modelo sin restricciones representando la relación entre el tipo de subsistencia (outputs, rojo) con las variables ecológicas (inputs, negro). Las flechas del modelo parten de los outputs a los inputs porque el modelo está construido de manera que los valores más probables de los inputs se calculan a partir de los valores de los outputs. También sería posible aprender el modelo de los inputs a los outputs, hay diversos modos de construir las redes y en este caso se ha optado por esta configuración. Fuente: Elaboración propia.

### 3.2. Información predictiva

Para explorar en más detalle hasta qué punto las variables ecológicas definen el tipo de subsistencia de las sociedades analizadas, se han hecho dos predicciones de tres contextos ambientales diferentes con valores completamente contrarios: contexto con valores mínimos, medios y máximos (definidos en la Tabla 5). El objetivo de este ejercicio de predicción era explorar hasta qué punto las variables el medio determinen el tipo de estrategias económicas de las comunidades estudiadas.

TABLA 5  
Definición de los contextos para predecir el tipo de intensidad de estrategias de subsistencia

Outputs	Inputs	Contexto 1	Contexto 2	Contexto 3
Agricultura	Distancia a la costa	<140	140-600	≥600
Ganadería	Elevación	<300	300-800	≥800
Caza	Pendiente	<0,75	0,75-2,5	≥2,5
Recolección	Temperatura media anual	<5	5-20	≥20
Pesca	Variación de la temperatura media	<1,3	1,3-20	≥20
	Constancia de la temperatura	<0,5	0,5-0,7	≥0,7
	Contingencia de la temperatura	<0,12	0,12-0,2	≥0,2
	Precipitación media mensual	<1,06e+05	1,06e+05-1,67e+05	≥1,67e+05
	Variación de la precipitación media	<7,86e+09	7,86e+09-1,49e+10	≥1,49e+10
	Constancia de la precipitación	<0,4	0,4-0,5	≥0,5
	Contingencia de la precipitación	<0,2	0,2-0,3	≥0,3
	Producción primaria neta media mensual	<1	1-3	≥3
	Constancia de la producción primaria neta	<0,2	0,2-0,3	≥0,3
	Contingencia de la producción primaria neta	<0,2	0,2-0,3	≥0,3

En el contexto 1, los inputs tienen los valores mínimos, en el 2 los valores medios y en el 3 los máximos. Fuente: Elaboración propia.

Los resultados están definidos en la Tabla 6 y podemos observar el mismo resultado para los contextos de valores mínimos y medios de las variables del ambiente: las comunidades basaran entre el 46-75% de su dieta en la agricultura y complementaran su dieta con las otras estrategias (con intensidades inferiores al 15%). En cambio, cuando los valores de todas las variables ecológicas tienen valores máximos, la agricultura seguirá siendo practicada con una intensidad entre el 46-75%, pero en lugar de tener una dieta mixta con otras estrategias, se consumirán los recursos ganaderos con más intensidad (entre el 16-45%).

Tabla 6  
Resultados de las predicciones

Contextos	Subsistencia	Modelo Naïve Bayes		Modelo Augmented Naïve Bayes		Modelo sin restricciones	
		Predicción	Nivel de confianza	Predicción	Nivel de confianza	Predicción	Nivel de confianza
Contexto 1	Agricultura	45-75	0,82381	45-75	0,82015	45-75	0,75252
	Ganadería	<15	0,83324	<15	0,76175	<15	0,61077
	Caza	<15	0,77294	<15	0,78386	<15	0,76981
	Recolección	<15	0,87198	<15	0,87556	<15	0,89811
	Pesca	<15	0,53892	<15	0,51947	<15	0,6415
Contexto 2	Agricultura	45-75	0,77688	45-75	0,75084	45-75	0,74809
	Ganadería	15-45	0,58672	15-45	0,54897	<15	0,58035
	Caza	<15	0,80788	<15	0,81424	<15	0,76981
	Recolección	<15	0,92169	<15	0,92555	<15	0,89811
	Pesca	<15	0,83286	<15	0,8624	<15	0,72968
Contexto 3	Agricultura	45-75	0,6219	45-75	0,62195	45-75	0,74817
	Ganadería	15-45	0,39024	15-45	0,39024	<15	0,58089
	Caza	<15	0,82927	<15	0,84139	<15	0,76981
	Recolección	<15	0,89024	<15	0,89922	<15	0,89811
	Pesca	<15	0,80488	<15	0,80271	<15	0,72813

Los mismos contextos se han explorado con los tres modelos de redes bayesianas, se ha recopilado el tipo de predicción y su nivel de confianza que define la probabilidad de acierto (siendo 1 el máximo). Fuente: Elaboración propia.

#### 4. DISCUSIÓN Y CONCLUSIONES

Al inicio de este estudio, nos planteábamos caracterizar la aplicación de la metodología de aprendizaje automático en Arqueología en general y, más específicamente, en el ámbito de estudio de sistemas socioecológicos. A través del análisis bibliométrico de los artículos publicados empleando AA en Arqueología, se ha comprobado que realmente esta metodología ha empezado a aplicarse de manera más consistente a partir del 2019. Identificar el/los motivo/s por los cuales esta metodología se ha vuelto más común requiere un estudio en más profundidad de este fenómeno metodológico, donde se contraste el número de artículos publicados en AA con otras metodologías computacionales, por ejemplo. No obstante, podría ser debido a las potencialidades del método, de predecir información desconocida, que puede ser muy atractivo en el ámbito arqueológico a causa de las propias limitaciones del registro. También podría ser por la democratización de los datos que se ha dado en los últimos años, donde se está volviendo una práctica común publicar en abierto los datos arqueológicos para poder reutilizar estos datos en otras investigaciones, como, por ejemplo, se ha hecho en este estudio con los datos etnográficos recogidos de una base de datos en abierto. Esta práctica de «reciclaje» favorece al desarrollo de estudios con dimensionalidad macro, más allá de la dimensionalidad de un asentamiento (ej.,

VANVALKENBURGH y DUFTON, 2020; HUGGETT, 2018).

Al inicio de este estudio, se planteaba que no había demasiados estudios de AA ni se había explorado su aplicabilidad en la ciencia arqueológica. Así mismo, en esta investigación se ha evidenciado que esta metodología aún se encuentra en su primera fase de aplicación, se ha implementado para explorar diversos casos de estudio, cuestiones y tipo de materiales, pero aún no se ha hecho el esfuerzo de integrarla como una metodología más como sí que se ha dado con otros métodos computacionales como la simulación, por ejemplo. Actualmente, nos encontramos en un estadio de aplicación del método, con mucha diversidad de aplicaciones y técnicas, pero aún no ha habido un diálogo y discusión sobre como AA se puede integrar en los estudios arqueológicos.

En este contexto, en el ámbito espacial sí que parece que se empieza a consolidar la práctica de combinar métodos propios de los sistemas de información geográfica (SIG) con algoritmos AA, sobre todo de *deep learning*. Sin embargo, no parece que la elección de algoritmo esté relacionada con el tipo de datos, sino que hay la tendencia en los distintos ámbitos de emplear reiteradamente el mismo tipo de algoritmo. En cambio, en el ámbito de estudio de sistemas socioecológicos y de dinámicas sociales, hay una gran diversidad de algoritmos empleados y también se ha observado que en algunos casos los modelos se utilizan para conceptualizar los sistemas desde el conocimiento experto (ej., BARCELÓ, 2008). Este aspecto es sobre todo patente en el caso de las redes Bayesianas con el algoritmo de NB. Estas tendencias pueden ser debidas a las propias tradiciones de investigación que hay en cada ámbito y sería interesante explorar en el futuro otras combinaciones de métodos que podrían ser perfectamente complementarias, como serían los métodos de AA y la simulación.

Por otro lado, el presente estudio también pretendía definir los beneficios y limitaciones de AA para el estudio de sistemas socioecológicos en arqueología mediante su aplicación de un caso concreto. En el caso de estudio se ha modelado un sistema social y económico complejo teniendo en cuenta las características ecológicas de su ubicación. A partir de los resultados, se ha observado la existencia de estrategias de subsistencia, sobre todo la agricultura, ganadería y la caza, que están influenciadas por algunas variables ecológicas, especialmente por el clima. En este sentido, se han obtenido resultados inesperados como el hecho que la productividad del suelo determina en mayor medida la intensidad que se practica la ganadería que la agricultura, contrariamente a lo sugerido en otros estudios (NENDEL *et al.*, 2011; VAN ITTERSUM *et al.*, 2008). Siguiendo a PALACIOS *et al.* (2022), la reducida importancia de la productividad del suelo en la agricultura estaría relacionada con la fuerza de trabajo, organización social y desarrollo tecnológico, aspectos que compensarían una baja productividad.

Mediante las redes bayesianas se ha modelado el sistema investigado de forma compleja y no-lineal, cuantificando las relaciones más significativas entre variables y prediciendo hipotéticos escenarios. No obstante, es importante matizar hasta qué punto estos resultados son fiables. Con respecto a la validez del modelo, este se ha validado y cuantificado su precisión, pero, el modelo es tan bueno como lo son sus datos. En la recogida de datos, el/la investigador/a recopila aquellos

que considera que son importantes, los procesa y categoriza (según el algoritmo empleado). En función de la agrupación de clases que se realice, los resultados pueden variar y, por lo tanto, son decisiones que el/la investigador/a toman y que determinan el resultado. Así mismo, los modelos se construyen a partir de los datos, pero también están modelados por restricciones que se determinan durante el diseño del modelo en función del tipo de estructura, cómo se ha detallado en la sección 2.3. con la construcción de tres modelos de redes bayesianas diferentes.

Por otro lado, cabe mencionar que en los modelos de AA identificamos patrones, las tendencias a partir de los datos conocidos. Los *outliers* o valores menos comunes del sistema no se pueden identificar en el modelo y otros métodos computacionales como la simulación, por ejemplo, serían más apropiados. En esta misma línea, los modelos AA son potentes a nivel predictivo, pero a nivel explicativo son difíciles de interpretar y es necesario contextualizar los resultados a partir de una aproximación teórica. Cabe destacar que esta limitación es compartida con otros métodos cuantitativos, puesto que estamos calculando las relaciones entre las variables. Es por este motivo que una opción para superar esta limitación sería combinar AA con modelos computacionales, por ejemplo. Sería interesante combinar el AA con otras metodologías como las computacionales para contrastar los resultados y enriquecerlos a nivel explicativo; concretamente, con el modelo basado en agentes, puesto que tiene un gran potencial a nivel explicativo y desarrollo de hipótesis que sería muy positivo en este caso para comprender los resultados que se han obtenido. No obstante, a partir del análisis de la trayectoria de AA en arqueología, hemos constatado que cuando se combinan métodos, suele ser entre diferentes algoritmos de AA o con SIG, pero no con modelos computacionales. A partir del estudio realizado, se podría explorar la utilidad de complementar los diferentes métodos y, en el futuro, sería interesante contrastar los resultados que hemos obtenido en la presente contribución desarrollando un modelo basado en agentes que explore la relación entre las variables ecológicas y el tipo de subsistencia de las comunidades agroganaderas para obtener información que nos ayude a interpretar los resultados obtenidos.

Para concluir este artículo, nos volvemos a plantear, ¿se ha producido en Arqueología un cambio de paradigma con la aplicación del aprendizaje automático? Podemos decir que todavía no. La eclosión de esta metodología es muy reciente, su aplicación muy diversa y aún su aplicación no está sistematizada. De hecho, la mayoría de las veces se utiliza como un método computacional para producir modelos predictivos, pero la singularidad del método, que sería su construcción a partir de los datos, aún no es una práctica recurrente en la ciencia arqueológica.

## 5. AGRADECIMIENTOS

Me gustaría agradecer a los dos revisores anónimos por sus sugerencias que, sin duda, han contribuido a mejorar el presente artículo. La presente contribución ha sido realizada gracias al soporte de la Generalitat de Catalunya y el Fondo

social europeo a través de la ayuda FI.

## 6. REFERENCIAS

- ABITBOL, R.; SHIMSHONI, I.; BEN-DOV, J. (2021): «Machine Learning Based Assembly of Fragments of Ancient Papyrus», *Journal on Computing and Cultural Heritage (JOCCH)*, 14 (3): 1-21.
- AGAPIOU, A.; VIONIS, A.; PAPANTONIOU, G. (2021): «Detection of Archaeological Surface Ceramics Using Deep Learning Image-Based Methods and Very High-Resolution UAV Imageries», *Land*, 10 (12): 1365.
- AHEDO, V.; ZURRO, D.; CARO, J.; GALÁN, J.M. (2021): «Let's go fishing: A quantitative analysis of subsistence choices with a special focus on mixed economies among small-scale societies», *PLoS ONE*, 16 (8): e0254539.
- AHEDO, V.; CARO, J.; BORTOLINI, E.; ZURRO, D.; MADELLA, M.; GALÁN, J.M. (2019): «Quantifying the relationship between food sharing practices and socio-ecological variables in small-scale societies: A cross-cultural multi-methodological approach», *PLoS ONE*, 14 (5): e0216302.
- ALBERTI, G. (2014): «Modeling group size and scalar stress by logistic regression from an archaeological perspective», *PLoS ONE*, 9 (3): e91510.
- ALBRECHT, C.M.; FISHER, C.; FREITAG, M.; HAMANN, H.F.; PANKANTL, S.; PEZZUTTI, F.; ROSSI, F. (2019): «Learning and Recognizing Archeological Features from LiDAR Data», en Proceedings IEEE International Conference on Big Data, Los Angeles: 5630-5636.
- ALLOGHANI, M.; AL-JUMEILY, D.; MUSTAFINA, J.; HUSSAIN, A.; ALJAAF, A.J. (2020). «A Systematic Review on Supervised and Unsupervised Machine Learning Algorithms for Data Science», en M. BERRY; A. MOHAMED y B. YAP (eds.), *Supervised and Unsupervised Learning for Data Science. Unsupervised and Semi-Supervised Learning*, Springer, Cham. [https://doi.org/10.1007/978-3-030-22475-2\\_1](https://doi.org/10.1007/978-3-030-22475-2_1)
- AMMERMAN, A.J.; CAVALLI-SFORZA, L.L. (1979): «The wave of advance model for the spread of agriculture in Europe», en C. RENDREW y K.L. COOKE (eds.), *Transformations: Mathematical Approaches to Culture Change*, Academic Press: 275-293. <https://doi.org/10.1016/C2013-0-11358-X>
- AMMERMAN, A.J.; CAVALLI-SFORZA, L.L. (2014): *The Neolithic transition and the genetics of populations in Europe*, vol. 836, Princeton University Press.
- ANZANO, J.; SANGÜESA, S.; CASAS-GONZÁLEZ, J.; MAGALLÓN, M.Á.; ESCUDERO, M.; ANWAR, J.; SHAFIQUE, U. (2015): «Analysis of Roman-Hispanic archaeological ceramics using laser-induced breakdown spectroscopy», *Analytical Letters*, 48 (10): 1638-1643.
- ALTAWHEEL, M.; KHELIFI, A.; LI, Z.; SQUITIERI, A.; BASMAJI, T.; GHAZAL, M. (2022): «Automated Archaeological Feature Detection Using Deep Learning on Optical UAV Imagery: Preliminary Results», *Remote Sensing*, 14 (3): 553.
- ARNAY, R.; HERNÁNDEZ-ACEITUNO, J.; MALLOL, C. (2021): «Soil micromorphological image classification using deep learning: The porosity parameter», *Applied*

- Soft Computing*, 102: 107093.
- ASSAEL, Y.; SOMMERSCHIED, T.; SHILLINGFORD, B.; BORDBAR, M.; PAVLOPOULOS, J.; CHATZIPANAGIOTOU, M.; ANDROUTSOPOULOS, I.; PRAG, J.; DE FREITAS, N. (2022): «Restoring and attributing ancient texts using deep neural networks», *Nature*, 603 (7900): 280-283.
- ATIENZA, D.; BIELZA, C.; LARRAÑAGA, P. (2022): «Semiparametric Bayesian networks», *Information Sciences*, 584: 564-582. <https://doi.org/10.1016/j.ins.2021.10.074>
- ATKINSON, Q.D.; WHITEHOUSE, H. (2011): «The cultural morphospace of ritual form», *Evolution and Human Behavior*, 32: 50-62. <https://doi.org/10.1016/j.evolhumbehav.2010.09.002>.
- BARCELO, J.A. (2008): *Computational intelligence in archaeology*, IGI Global, Hershey, New York.
- BARCELÓ, J.A.; DEL CASTILLO, M.F.; MAMELI, L. (2015): «The probabilities of prehistoric events: a Bayesian network approach», en J.A. BARCELÓ y I. BOGDANOVIC (eds.), *Mathematics and Archaeology*, CRC Press: 464-484.
- BARTON, C.M.; ULLAH, I.I.T.; BERGIN, S.M.; MITASOVA, H.; SARJOUGHIAN, H. (2012): «Looking for the future in the past: Long-term change in socioecological systems», *Ecological Modelling*, 241: 42-53.
- BARTON, C.M.; ULLAH, I.; MITASOVA, H. (2010): «Computational Modeling and Neolithic Socioecological Dynamics: A Case Study from Southwest Asia», *American Antiquity*, 75(2): 364-386.
- BAUM, T. (2016): «Simulating Land Use of Prehistoric Wetland Settlements: Did Excessive Resource Use Necessitate a Highly Dynamic Settlement System?», en J.A. BARCELÓ y F. DEL CASTILLO (eds.), *Simulating Prehistoric and Ancient Worlds*, Springer International Publishing: Cham: 255-279.
- BAUM, T.; NENDEL, C.; JACOMET, S.; COLOBRAN, M.; EBERSBACH, R. (2016): «“Slash and burn” or “weed and manure”? A modelling approach to explore hypotheses of late Neolithic crop cultivation in pre-alpine wetland sites», *Vegetation History Archaeobotany*, 25 (6): 611-27.
- BELL, S.; CROSON, C. (1998): «Artificial neural networks as a tool for archaeological data analysis», *Archaeometry*, 40 (1): 139-151.
- BERGANZO-BESGA, I.; ORENCO, H.A.; LUMBRERAS, F.; CARRERO-PAZOS, M.; FONTE, J.; VILAS-ESTÉVEZ, B. (2021): «Hybrid MSRM-based deep learning and multitemporal sentinel 2-based machine learning algorithm detects near 10k archaeological tumuli in North-Western Iberia», *Remote Sensing*, 13: 41-81.
- BICKLER, S.H. (2021): «Machine Learning Arrives in Archaeology», *Advances in Archaeological Practice*, 9 (2): 186-191.
- BICKLER, S.H. (2018): «Machine learning identification and classification of historic ceramics», en B. PETCHEY; K. HIL; S. KINASTON y A. KELLY (eds.), *Archaeology in New Zealand*, *New Zealand Archaeological Association*, 61 (2): 20-32.
- BONHAGE, A.; ELTAHER, M.; RAAB, T.; BREUSS, M.; RAAB, A.; SCHNEIDER, A. (2021): «A modified Mask region-based convolutional neural network approach for the automated detection of archaeological sites on high-resolution light detection and ranging-derived digital elevation models in the North German



- Lowland», *Archaeological Prospection*, 28 (2): 177-186.
- BRANDSEN, A.; VERBERNE, S.; WANSLEEBEN, M.; LAMBERS, K. (2020): «Creating a dataset for named entity recognition in the archaeology domain», en *Conference Proceedings LREC 2020*, The European Language Resources Association: 4573-4577.
- BROZOU, A.; FULLER, B.T.; GRIMES, V.; VAN BIESEN, G.; MA, Y.; BOLDSSEN, J.L.; MANNINO, M.A. (2022): «Aquatic resource consumption at the Odense leprosarium: Advancing the limits of palaeodiet reconstruction with amino acid  $\delta^{13}\text{C}$  measurements», *Journal of Archaeological Science*, 141: 105578.
- BUCHANAN, B.; WALKER, R.S.; HAMILTON, M.J.; STORY, B.; BEBBER, M.; WILCOX, D.; EREN, M.I. (2022): «Experimental assessment of lanceolate projectile point and haft robustness», *Journal of Archaeological Science: Reports*, 42: 103399.
- BUNDZEL, M.; JAŠČUR, M.; KOVÁČ, M.; LIESKOVSKÝ, T.; SINČÁK, P.; TKÁČIK, T. (2020): «Semantic segmentation of airborne lidar data in maya archaeology», *Remote Sensing*, 12: 3685.
- BURRY, L.S.; MARCONETTO, B.; SOMOZA, M.; PALACIO, P.; TRIVI, M.; D'ANTONI, H. (2018): «Ecosystem modeling using artificial neural networks: An archaeological tool», *Journal of Archaeological Science: Reports*, 18: 739-746.
- BYEON, W.; DOMÍNGUEZ-RODRIGO, M.; ARAMPATZIS, G.; BAQUEDANO, E.; YRAVEDRA, J.; MATÉ-GONZÁLEZ, M.A.; KOUMOUTSAKOS, P. (2019): «Automated identification and deep classification of cut marks on bones and its paleoanthropological implications», *Journal of Computational Science*, 32: 36-43.
- CASPARI, G. y CRESPO, P. (2019): «Convolutional neural networks for archaeological site detection-Finding "princely" tombs», *Journal of Archaeological Science*, 110: 104998.
- CASTIELLO, M.E.; TONINI, M. (2019): «An innovative approach for risk assessment in archaeology based on machine learning. A Swiss case study. Quantitative approaches, spatial statistics and socioecological modelling», en *International Colloquium on Digital Archaeology in Bern (DAB)*, University of Bern, Switzerland.
- CHARACTER, L.; ORTIZ JR, A.; BEACH, T.; LUZZADDER-BEACH, S. (2021): «Archaeologic machine learning for shipwreck detection using lidar and sonar», *Remote Sensing*, 13 (9): 1759.
- CHEN, F.; ZHOU, R.; VAN DE VOORDE, T.; CHEN, X.; BOURGEOIS, J.; GHEYLE, W.; GOOSSENS, R.; YANG, J.; XU, W. (2021): «Automatic detection of burial mounds (kurgans) in the Altai Mountains», *ISPRS Journal of Photogrammetry and Remote Sensing*, 177: 217-237.
- CHETOUANI, A.; TREUILLET, S.; EXBRAYAT, M.; JESSET, S. (2020): «Classification of engraved pottery sherds mixing deep-learning features by compact bilinear pooling», *Pattern Recognition Letters*, 131: 1-7.
- CHOBTHAM, K.; CONSTANTINO, A.C. (2020): «Bayesian network structure learning with causal effects in the presence of latent variables», en *International Conference on Probabilistic Graphical Models*, PMLR: 101-112.
- CHOWDHURY, M.P.; CHOUDHURY, K.D.; BOUCHARD, G.P.; RIEL-SALVATORE, J.; NEGRINO, F.; BENAZZI, S.; SLIMAK, L.; FRASIER, B.; SZABO, V.; HARRISON, R.; HAMBRECHT, G.;

- KITCHENER, A.C.; WOGELIUS, R.A.; BUCKLEY, M. (2021): «Machine learning ATR-FTIR spectroscopy data for the screening of collagen for ZooMS analysis and mtDNA in archaeological bone», *Journal of Archaeological Science*, 126: 105311.
- CIFUENTES-ALCOBENDAS, G.; DOMÍNGUEZ-RODRIGO, M. (2019): «Deep learning and taphonomy: high accuracy in the classification of cut marks made on fleshed and defleshed bones using convolutional neural networks», *Scientific reports*, 9 (1): 1-12.
- CINTAS, C.; LUCENA, M.; FUERTES, J.M.; DELRIEUX, C.; NAVARRO, P.; GONZÁLEZ-JOSÉ, R.; MOLINOS, M. (2020): «Automatic feature extraction and classification of Iberian ceramics based on deep convolutional networks», *Journal of Cultural Heritage*, 41: 106-112.
- CLARIVATE ANALYTICS (2022). Web of Science. [<https://www-webofscience-com>]
- COLMENERO-FERNÁNDEZ, A.; FEITO, F. (2021): «Image processing for graphic normalisation of the ceramic profile in archaeological sketches making use of deep neuronal net (DNN)», *Digital Applications in Archaeology and Cultural Heritage*, 22: e00196.
- COURTENAY, L.A.; YRAVEDRA, J.; HUGUET, R.; ARAMENDI, J.; MATÉ-GONZÁLEZ, M.Á.; GONZÁLEZ-AGUILERA, D.; ARRIAZA, M.C. (2019): «Combining machine learning algorithms and geometric morphometrics: a study of carnivore tooth marks», *Palaeogeography, Palaeoclimatology, Palaeoecology*, 522: 28-39.
- CRAWFORD, K.; DOBBE, R.; DRYER, T.; FRIED, F.; GREEN, B.; KAZIUNAS, E.; KAK, A.; MATHUR, V.; MCELROY, E.; NILL SÁNCHEZ, A.; RAJI, D.; RANKIN, J. L.; RICHARDSON, R.; SCHULTZ, J.; WEST, S.M.; WHITTAKER, M. (2019): *AI now 2019 report*, AI Now Institute, New York.
- DAVIS, D.S. (2020a): «Defining what we study: The contribution of machine automation in archaeological research», *Digital Applications in Archaeology and Cultural Heritage*, 18: e00152.
- DAVIS, D.S. (2020b): «Studying human responses to environmental change: Trends and trajectories of archaeological research», *Environmental Archaeology*, 25 (4): 367-380.
- DAVIS, D.S.; CASPARI, G.; LIPO, C.P.; SANGER, M.C. (2021): «Deep learning reveals extent of Archaic Native American shell-ring building practices», *Journal of Archaeological Science*, 132: 105433.
- DAVIS, D.; DOUGLASS, K. (2021): «Remote Sensing Reveals Lasting Legacies of Land-Use by Small-Scale Foraging Societies», *Frontiers in Ecology and Evolution*, 9: 689399. <https://doi.org/10.26207/zmsr-tc92>.
- DESMOND, M. (2014): «Relational ethnography», *Theory and Society*, 43: 547-579.
- DHALL, D.; KAUR, R.; JUNEJA, M. (2020): «Machine learning: a review of the algorithms and its applications», en *Proceedings of ICRIC*, 2019: 47-63.
- DIA, K.; COLI, V.; BLANC-FÉRAUD, L.; LEBLOND, J.; GOMART, L.; BINDER, D. (2021): «Applications of Learning Methods to Imaging Issues in Archaeology, Regarding Ancient Ceramic Manufacturing», en *International Conference on Deep Learning Theory and Applications*, SCITEPRESS-Science and Technology Publications: 109-116.
- DOMÍNGUEZ-RODRIGO, M.; BAQUEDANO, E. (2018): «Distinguishing butchery cut

- marks from crocodile bite marks through machine learning methods», *Scientific Reports*, 8: 5786. <https://doi.org/10.1038/s41598-018-24071-1>.
- DUCKE, B. (2003): «Archaeological predictive modelling in intelligent network structures», en *Proceedings of the 29th CAA Conference*, Loughborough University: 267-272.
- EDEH, M.O.; UGORJI, C.C.; NDUANYA, U.I.; ONYEWUCHI, C.; OHWO, S.O.; IKEDILO, O.E. (2021): «Prospects and Limitations of Machine Learning in Computer Science Education» *Benin Journal of Educational Studies*, 27 (1): 48-62.
- ELSEVIER. (2004): Scopus [<https://www.elsevier.com/scopus>]
- ENGEL, A.; VAN DEN BROECK, C. (2001): *Statistical mechanics of learning*, Cambridge University Press.
- FABRICIUS TEAM (2022). *Arts experiments* [<https://artsexperiments.withgoogle.com/fabricius/en/about>].
- FAN, L.; ZHANG, M.; YIN, J.; ZHANG, J. (2022). «Impacts of dynamic inspection records on port state control efficiency using Bayesian network analysis», *Reliability Engineering & System Safety*, 228: 108753. <https://doi.org/10.1016/j.res.2022.108753>
- FANIEL, I.; KANSA, E.; WHITCHER KANSA, S.; BARRERA-GOMEZ, J.; YAKEL, E. (2013): «The challenges of digging data: a study of context in archaeological data reuse», en *Proceedings of the 13th ACM/IEEE-CS joint conference on Digital libraries*, New York: 295-304.
- FERRARO, P.J.; SANCHIRICO, J.N.; SMITH, M.D. (2019): «Causal inference in coupled human and natural systems», *PNAS*, 116: 5311-8. <https://doi.org/10.1073/pnas.1805563115>.
- FORT, J. (2022): «Dispersal distances and cultural effects in the spread of the Neolithic along the northern Mediterranean coast», *Archaeological and Anthropological Sciences*, 14: 153. <https://doi.org/10.1007/s12520-022-01619-x>
- FRIGGENS, M.M.; LOEHMAN, R.A.; CONSTAN, C.I.; KNEIFEL, R.R. (2021): «Predicting wildfire impacts on the prehistoric archaeological record of the Jemez Mountains, New Mexico, USA», *Fire Ecology*, 17 (1): 1-19.
- GANDHI, I.R.; PONNAVAIKKO, M. (2020): «Copper plate image character recognition system using complex extreme deep learning machine», *International Journal of Advanced Science and Technology*, 29 (7): 359-268.
- GANTLEY, M.; WHITEHOUSE, H.; BOGAARD, A. (2018): «Material correlates analysis (MCA): An innovative way of examining questions in archaeology using ethnographic data», *Advances in Archaeological Practice*, 6: 328-341.
- GINAU, A.; STEINIGER, D.; HARTMANN, R.; HARTUNG, U.; SCHIESTL, R.; ALTMAYER, M.; WUNDERLICH, J. (2020): «What settlements leave behind – pXRF compositional data analysis of archaeological layers from Tell el-Fara'in (Buto, Egypt) using machine learning», *Palaeogeography, Palaeoclimatology, Palaeoecology*, 546: 109666.
- GRIMM, V.; RAILSBACK, S.F. (2011): «Designing, formulating, and communicating agent-based models», en A.J. HEPPENSTALL; L.M. SEE y M. BATTY (eds.), *Agent-based models of geographical Systems*, Springer Science & Business Media, Dordrecht: 361-377.

- GROVE, M.; BLINKHORN, J. (2020): «Neural networks differentiate between Middle and Later Stone Age lithic assemblages in eastern Africa», *PLoS ONE*, 15(8): e0237528.
- GUALANDI, M.L.; GATTIGLIA, G.; ANICHINI, F. (2021): «An Open System for collection and automatic recognition of pottery through Neural Network Algorithms», *Heritage*, 4 (1): 140-159.
- GUYOT, A.; HUBERT-MOY, L.; LORHO, T. (2018): «Detecting Neolithic burial mounds from LiDAR-derived elevation data using a multi-scale approach and machine learning techniques», *Remote Sensing*, 10 (2):225.
- GUYOT, A.; LENNON, M.; HUBERT-MOY, L. (2021): «Objective comparison of relief visualization techniques with deep CNN for archaeology», *Journal of Archaeological Science: Reports*, 38: 103027.
- HALIASSOS, A.; BARMPOUTIS, P.; STATHAKI, T.; QUIRKE, S.; CONSTANTINIDES, A. (2020): «Classification and detection of symbols in ancient papyri», en F. LIAROKAPIS; A. VOULODIMOS; N. DOULAMIS; A. DOULAMIS, *Visual computing for cultural heritage*, Springer: 121-140.
- HANSEN, J.; NEBEL, M. (2020): «Prioritizing Archaeological Inventory and Protection with Predictive Probability Models at Glen Canyon National Recreation Area, USA», *Journal of Southwestern Anthropology and History*, 86 (1): 1-23.
- HEIN, I.; ROJAS-DOMÍNGUEZ, A.; ORNELAS, M.; D'ERCOLE, G.; PELOSCHKE, L. (2018): «Automated classification of archaeological ceramic materials by means of texture measures», *Journal of Archaeological Science: Reports*, 21: 921-928.
- HLAD, M.; VESELKA, B.; STEADMAN, D.W.; HERREGODS, B.; ELSKENS, M.; ANNAERT, R.; BOUDIN, M.; CAPUZZO, G.; DALLE, S.; DE MULDER, G.; SABAU, C.; SALESSE, K. SENGELØV, A.; STAMATAKI, E.; VERCAUTEREN, M.; WARMENBOL, E.; TYS, D.; SNOECK, C. (2021): «Revisiting metric sex estimation of burnt human remains via supervised learning using a reference collection of modern identified cremated individuals (Knoxville, USA)», *American Journal of Physical Anthropology*, 175 (4): 777-793.
- HØJSGAARD, S. (2012): «Graphical Independence Networks with the gRain Package for R», *Journal of Statistical Software*, 46 (10): 1-26.
- HORN, C.; IVARSSON, O.; LINDHÉ, C.; POTTER, R.; GREEN, A.; LING, J. (2022): «Artificial Intelligence, 3D Documentation, and Rock Art – Approaching and Reflecting on the Automation of Identification and Classification of Rock Art Images», *Journal of Archaeological Method and Theory*, 29: 188-213. <https://doi.org/10.1007/s10816-021-09518-6>
- HÖRR, C.; LINDINGER, E.; BRUNNETT, G. (2014): «Machine learning based typology development in archaeology», *Journal on Computing and Cultural Heritage*, 7 (1): 1-23.
- HUFFER, D.; GRAHAM, S. (2018): «Fleshing out the bones: Studying the human remains trade with Tensorflow and Inception», *Journal of Computer Applications in Archaeology*, 1 (1): 55-63.
- HUGGETT, J. (2018): «Reuse Remix Recycle: Repurposing Archaeological Digital Data», *Advances in Archaeological Practice*, 6 (2): 93-104. <https://doi.org/doi:10.1017/aap.2018.1>

- HYAFIL, A.; BAUMARD, N. (2022): «Evoked and Transmitted Culture models: Using bayesian methods to infer the evolution of cultural traits in history», *PLoS ONE*, 17 (4): e0264509.
- ISERN, N.; ZILHÃO, J.; FORT, J.; AMMERMAN, A.J. (2017): «Modeling the role of voyaging in the coastal spread of the Early Neolithic in the West Mediterranean», *Proceedings of the National Academy of Sciences*, 114 (5): 897-902.
- JEPSON, P.L.; MUSCHIO, G.; LEVIN, J. (2019): «Computational Science, Convergence Culture, and the Creation of Archaeological Knowledge and Understanding», en J.H. JAMESON y S. MUSTEATA (eds.), *Transforming Heritage Practice in the 21st Century*, Springer International Publishing: 431-446.
- KIRBY, K.R.; GRAY, R.D.; GREENHILL, S.J.; JORDAN, F.M.; GOMES-NG, S.; BIBIKO, H.J.; BLASI, D. E.; BOTERO, C. A.; BOWERN, C.; EMBER, C. R.; LEEHR, D.; LOW, B. S.; MCCARTER, J.; DIVALE, W.; GAVIN, M. C. (2016): «D-PLACE: A global database of cultural, linguistic and environmental diversity», *PLoS ONE*, 11 (7): e0158391.
- KOGOU, S.; SHAHTAHMASSEBI, G.; LUCIAN, A.; LIANG, H.; SHUI, B.; ZHANG, W.; SU, B.; VAN SCHAIK, S. (2020): «From remote sensing and machine learning to the history of the Silk Road: large scale material identification on wall paintings», *Scientific Reports*, 10 (1): 1-14.
- KOHLER, T.A.; VARIEN, M.D. (2012): *Emergence and collapse of early villages: models of Central Mesa Verde archaeology*, University of California Press.
- KOHONEN, T. (2001): *Self-Organizing Maps* (Third Edition), Springer, Berlin.
- KOLLER, D.; FRIEDMAN, N. (2009): *Probabilistic graphical models: principles and techniques*, MIT Press.
- KLASSEN, S.; WEED, J.; EVANS, D. (2018): «Semi-supervised machine learning approaches for predicting the chronology of archaeological sites: A case study of temples from medieval Angkor, Cambodia», *PLoS ONE*, 13 (11): e0205649.
- LAMBERS, K.; VERSCHOOF-VAN DER VAART, W.B.; BOURGEOIS, Q.P. (2019): «Integrating remote sensing, machine learning, and citizen science in Dutch archaeological prospection», *Remote Sensing*, 11 (7): 794.
- LEATHWICK, J.R. (2000): *Predictive models of archaeological site distributions in New Zealand*, Department of Conservation.
- LOTKA, A.J. (1920): «Analytical note on certain rhythmic relations in organic systems», *Proceedings of the National Academy of Sciences*, 6 (7): 410-415.
- MA, Y.; GRIMES, V.; VAN BIESEN, G.; SHI, L.; CHEN, K.; MANNINO, M.A.; FULLER, B.T. (2021): «Aminoisoscapes and palaeodiet reconstruction: new perspectives on millet-based diets in China using amino acid  $\delta^{13}\text{C}$  values», *Journal of Archaeological Science*, 125: 105289
- MACKENZIE, A. (2017): *Machine learners: Archaeology of a data practice*, MIT Press.
- MACLEOD, N. (2018): «The quantitative assessment of archaeological artifact groups: Beyond geometric morphometrics», *Quaternary Science Reviews*, 201: 319-348.
- MARCOT, B.G.; HANEA, A.M. (2021): «What is an optimal value of k in k-fold cross-validation in discrete Bayesian network analysis?», *Computational Statistics*, 36: 2009-2031. <https://doi.org/10.1007/s00180-020-00999-9>
- MESANZA-MORAZA, A.; GARCÍA-GÓMEZ, I.; AZKARATE, A. (2020): «Machine learning



- for the built heritage archaeological study», *Journal on Computing and Cultural Heritage*, 14 (1): 1-21.
- MONNA, F.; MAGAIL, J.; ROLLAND, T.; NAVARRO, N.; WILCZEK, J.; GANTULGA, J.O.; Gantulga, J.-O.; Esin, Y.; Granjon, L.; Allard, A.-C.; Chateau-Smith, C. (2020): «Machine learning for rapid mapping of archaeological structures made of dry stones –Example of burial monuments from the Khirgisuur culture, Mongolia–», *Journal of Cultural Heritage*, 43: 118-128.
- MÜLLER, B.; BALBI, S.; BUCHMANN, C.M.; DE SOUSA, L.; DRESSLER, G.; GROENEVELD, J.; WEISE, H. (2014): «Standardised and transparent model descriptions for agent-based models: Current status and prospects», *Environmental Modelling & Software*, 55: 156-163.
- NASH, B.S.; Prewitt, E.R. (2016): «The use of artificial neural networks in projectile point typology», *Lithic Technology*, 41 (3): 194-211.
- NAVARRO, P.; CINTAS, C.; LUCENA, M.; FUERTES, J.M.; DELRIEUX, C.; MOLINOS, M. (2021): «Learning feature representation of Iberian ceramics with automatic classification models», *Journal of Cultural Heritage*, 48: 65-73.
- NAVEGA, D.; COELHO, C.; VICENTE, R.; FERREIRA, M.T.; WASTERLAIN, S.; CUNHA, E. (2015): «Ancestrees: ancestry estimation with randomized decision trees», *International Journal of Legal Medicine*, 129 (5): 1145-1153.
- NEAPOLITAN, R.E. (2004): *Learning bayesian networks*, vol. 38, Pearson Prentice Hall, Upper Saddle River.
- NENDEL, C.; BERG, M.; KERSEBAUM, K.C.; MIRSCHEL, W.; SPECKA, X.; WEGEHENKEL, M.; WENKEL, K.O.; WIELAND, R. (2011): «The MONICA model: Testing predictability for crop growth, soil moisture and nitrogen dynamics», *Ecological Modelling*. 222: 1614–25. <https://doi.org/10.1016/j.ecolmodel.2011.02.018>.
- NETO, E.M.D.F.L.; ALBUQUERQUE, U. (2018): «Theories of niche construction and optimal foraging: weaknesses and virtues in understanding the early stages of domestication», *Ethnobiology and Conservation*, 7: 7.
- OONK, S.; SPIJKER, J. (2015): «A supervised machine-learning approach towards geochemical predictive modelling in archaeology», *Journal of Archaeological Science*, 59: 80-88.
- ORENGO, H.A.; GARCIA-MOLSOSA, A. (2019): «A brave new world for archaeological survey: Automated machine learning-based potsherd detection using high-resolution drone imagery», *Journal of Archaeological Science*, 112: 105013.
- OSTERTAG, C.; BEURTON-AIMAR, M. (2020): «Matching ostraca fragments using a siamese neural network», *Pattern Recognition Letters*, 131: 336-340.
- PAGNIN, L.; BRUNNBAUER, L.; WIESINGER, R.; LIMBECK, A.; SCHREINER, M. (2020): «Multivariate analysis and laser-induced breakdown spectroscopy (LIBS): a new approach for the spatially resolved classification of modern art materials», *Analytical and Bioanalytical Chemistry*, 412: 3187-3198.
- PALACIOS, O.; BARCELÓ, J.A.; DELGADO, R. (2022): «Exploring the role of ecology and social organisation in agropastoral societies: A Bayesian network approach», *PLoS ONE* 17 (10): e0276088. <https://doi.org/10.1371/journal.pone.0276088>
- PARGETER, J.; KHREISHEH, N.; STOUT, D. (2019): «Understanding stone tool-making skill acquisition: experimental methods and evolutionary implications»,

- Journal of Human Evolution*, 133: 146-166.
- PAWLOWICZ, L.M.; DOWNUM, C.E. (2021): «Applications of deep learning to decorated ceramic typology and classification: A case study using Tusayan White Ware from Northeast Arizona», *Journal of Archaeological Science*, 130: 105375.
- PEREGRINE, P.N. (1996): «Ethnology versus ethnographic analogy: A common confusion in archaeological interpretation», *Cross-Cultural Research*, 30: 316-329.
- PRASOMPAN, S.; JUNG, J.E. (2017): «Mobile application for archaeological site image content retrieval and automated generating image descriptions with neural network», *Mobile Networks and Applications*, 22 (4): 642-649.
- R CORE TEAM. (2022): *R: A Language and environment for statistical computing*, R Foundation for Statistical Computing, Wien.
- RADFORD, J.; JOSEPH, K. (2020): «Theory in, theory out: the uses of social theory in machine learning for social science», *Frontiers in Big Data*, 3: 18. <https://www.doi.org/10.3389/fdata.2020.00018>
- RAMAZZOTTI, M. (2020): «Modelling the past: logics, semantics and applications of neural computing in archaeology», *Archeologia e Calcolatori*, 31 (2): 169-180.
- RAMYA, J.; RAJ KUMAR, G.K.; PENIEL, C.J. (2019): «'Agaram' – Web Application of Tamil Characters Using Convolutional Neural Networks and Machine Learning», en *International Conference on Emerging Current Trends in Computing and Expert Technology*, Springer, Cham: 670-680.
- REICH, J.; STEINER, P.; BALLMER, A.; EMMENEGGER, L.; HOSTETTLER, M.; STÄHELI, C.; NAUMOV, G.; TANESKI, B.; TODOROSKA, V.; SCHINDLER, K.; HAFNER, A. (2021): «A novel structure from motion-based approach to underwayer pile field documentation», *Journal of Archaeological Science: Reports*, 39: 103-120.
- RESLER, A.; YESHURUN, R.; NATALIO, F.; GIRYES, R. (2021): «A deep-learning model for predictive archaeology and archaeological community detection», *Humanities and Social Sciences Communications*, 8 (1): 1-10.
- RICHARDS-RISSETTO, H.; NEWTON, D.; AL ZADJALI, A. (2021): «A 3d Point Cloud Deep Learning Approach Using LIDAR to Identify Ancient Maya Archaeological Sites», en *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing: 133-139.
- SANDERS, D.H. (2018): «Neural Networks, AI, Phone-Based VR, Machine Learning, Computer Vision and the CUNAT Automated Translation App – Not Your Father's Archaeological Toolkit», en *3rd Digital Heritage International Congress (DigitalHERITAGE)*, San Francisco: 1-5.
- SCUTARI, M.; DENIS, J.B. (2021): *Bayesian Networks: With Examples in R*, Chapman and Hall/CRC, New York.
- SHARAFI, S.; FOULADVAND, S.; SIMPSON, I.; ALVAREZ, J.A.B. (2016): «Application of pattern recognition in detection of buried archaeological sites based on analysing environmental variables, Khorramabad Plain, West Iran», *Journal of Archaeological Science: Reports*, 8: 206-215.
- SMITH, B.D. (2015): «A comparison of niche construction theory and diet breadth models as explanatory frameworks for the initial domestication of plants and animals», *Journal of Archaeological Research*, 23 (3): 215-262.



- SOROUGH, M.; MEHRTASH, A.; KHAZRAEE, E.; UR, J.A. (2020): «Deep learning in archaeological remote sensing: Automated qanat detection in the kurdistan region of Iraq», *Remote Sensing*, 12 (3): 500.
- STOTT, D.; KRISTIANSEN, S.M.; SINDBÆK, S.M. (2019): «Searching for viking age fortresses with automatic landscape classification and feature detection», *Remote Sensing*, 11: 1881.
- TEWARI, K.; VANDITA, S.; JAIN, S. (2020). «Predictive analysis of absenteeism in MNCs using machine learning algorithm», en *Proceedings of ICRIC 2019*, Springer, Cham: 3-14.
- THABENG, O.L.; MERLO, S.; ADAM, E. (2019): «High-resolution remote sensing and advanced classification techniques for the prospection of archaeological sites' markers: The case of dung deposits in the Shashi-Limpopo Confluence area (southern Africa)», *Journal of Archaeological Science*, 102: 48-60.
- TRIER, Ø.D.; COWLEY, D.C.; WALDELAND, A.U. (2019): «Using deep neural networks on airborne laser scanning data: Results from a case study of semi-automatic mapping of archaeological topography on Arran, Scotland», *Archaeological Prospection*, 26 (2): 165-175.
- TSIGKAS, G.; SFIKAS, G.; PASIALIS, A.; VLACHOPOULOS, A.; NIKOU, C. (2020): «Markerless detection of ancient rock carvings in the wild: rock art in Vathy, Astypalaia», *Pattern Recognition Letters*, 135: 337-345.
- ULLAH I.I.T. (2011): «A GIS method for assessing the zone of human-environmental impact around archaeological sites: a test case from the Late Neolithic of Wadi Ziqlâb, Jordan», *Journal of Archaeological Science*, 38 (3): 623-32.
- ULLAH, I.I.T.; BERGIN, S.M. (2012): «Modeling the consequences of village site location: Least cost path modeling in a coupled GIS and agent-based model of village agropastoralism in eastern Spain», en D.A. WHITE y S.L. SURFACE-EVANS (eds.), *Least cost analysis of social landscapes: Archaeological case studies*, University of Utah Press: 155-173.
- USHIZIMA, D.; XU, K.; MONTEIRO, P.J. (2020): «Materials data science for microstructural characterization of archaeological concrete», *MRS Advances*, 5 (7): 305-318.
- VAHDATI, A.R.; WEISSMANN, J.D.; TIMMERMANN, A.; DE LEÓN, M.S.P.; ZOLLIKOFER, C.P. (2019): «Drivers of Late Pleistocene human survival and dispersal: an agent-based modeling and machine learning approach», *Quaternary Science Reviews*, 221: 105867.
- VAN ITTERSUM M.K.; EWERT, F.; HECKELEI, T.; WERY, J.; ALKAN OLSSON, J.; ANDERSEN, E.; BEZLEPKINA, I.; BROUWER, F.; DONATELLI, M.; FLICHMAN, G.; OLSSON, L.; RIZZOLI, A. E.; VAN DER WAL, T.; WIEN, J. E.; WOLF, J. (2008): «Integrated assessment of agricultural systems—A component-based framework for the European Union (SEAMLESS)», *Agricultural Systems*, 96: 150-165. <https://doi.org/10.1016/j.agsy.2007.07.009>.
- VANVALKENBURGH, P.; DUFTON, J.A. (2020): «Big archaeology: Horizons and blindspots», *Journal of Field Archaeology*, 45: S1-S7. <https://doi.org/10.1080/00934690.2020.1714307>
- VAUGHN, S.; CRAWFORD, T. (2009) «A predictive model of archaeological potential:

- An example from northwestern Belize», *Applied Geography*, 29 (4): 542-555.
- VERSCHOOF-VAN DER VAART, W.B.; LAMBERS, K.; KOWALCZYK, W.; BOURGEOIS, Q.P. (2020): «Combining deep learning and location-based ranking for large-scale archaeological prospection of LiDAR data from the Netherlands», *ISPRS International Journal of Geo-Information*, 9 (5): 293.
- VOLTERRA, V. (1926): «Fluctuations in the abundance of a species considered mathematically», *Nature*, 118(2972): 558-560.
- VON BERTALANFFY, L. (1950): «An outline of general system theory», *British Journal for the Philosophy of Science*, 1 (2): 134-165.
- VOS, D.; STAFFORD, R.; JENKINS, E.L.; GARRARD, A. (2021): «A model based on Bayesian confirmation and machine learning algorithms to aid archaeological interpretation by integrating incompatible data», *PLoS ONE*, 16 (3): e0248261.
- WÄRMLÄNDER, S.K.; VARUL, L.; KOSKINEN, J.; SAAGE, R.; SCHLAGER, S. (2019): «Estimating the temperature of heat-exposed bone via machine learning analysis of SCI color values: A pilot study», *Journal of Forensic Sciences*, 64 (1): 190-195.
- WATTS, J.; JACKSON, J.C.; ARNISON, C.M.; HAMERSLAG, E.M.; SHAVER, J.; PURZYCKI, B.G. (2022): «Building Quantitative Cross-Cultural Databases From Ethnographic Records: Promise, Problems and Principles», *Cross-Cultural Research*, 56: 62-94. <https://doi.org/10.1177/106939712111065720>.
- WILENSKY, U. (1999): *NetLogo*, Center for Connected Learning and Computer-Based Modeling, Northwestern University.
- XU, L.; WANG, X.; WANG, X. (2019): «Shipwrecks detection based on deep generation network and transfer learning with small amount of sonar images», en *IEEE 8th Data Driven Control and Learning Systems Conference (DDCLS)*, IEEE, Dali: 638-643.
- YAWORSKY, P.M.; VERNON, K.B.; SPANGLER, J.D.; BREWER, S.C.; CODDING, B.F. (2020): «Advancing predictive modeling in archaeology: An evaluation of regression and machine learning methods on the Grand Staircase-Escalante National Monument», *PLOS ONE*, 15 (10): e0239424.
- ZEDER, M.A. (2017): «Domestication as a model system for the extended evolutionary synthesis», *Interface Focus*, 7 (5): 20160133
- ZHENG, M.; TANG, W.; OGUNDIRAN, A.; YANG, J. (2020): «Spatial simulation modeling of settlement distribution driven by random forest: consideration of landscape visibility», *Sustainability*, 12 (11): 4748.
- ZHU, B.; WANG, X.; CHU, Z.; YANG, Y.; SHI, J. (2019): «Active learning for recognition of shipwreck target in side-scan sonar image», *Remote Sensing*, 11 (3): 243.

7. APÉNDICE

APÉNDICE TABLA 1  
 Información de las sociedades (los datos han sido recopilados de D-PLACE)

Sociedades	Distancia a la costa	Elevación	Pendiente	Temperatura media anual	Variación de la temperatura media	Constancia de la temperatura	Contingencia de la temperatura	Precipitación media mensual	Variación de la precipitación media	Constancia de la precipitación	Contingencia de la precipitación	Producción primaria neta media mensual	Constancia de la producción primaria neta	Contingencia de la producción primaria neta	Caza	Recolección	Ganadería	Pesca	Agricultura
Ababda	128,86	379,49	0,68	24,94	51,53	0,35	0,32	4283,93	107365001,90	0,17	0,13	-0,12	0,62	0,20	<15	<15	>=75	<15	<15
Adi	681,24	234,06	1,64	16,86	28,67	0,43	0,31	216081,10	59736865351,00	0,36	0,23	1,82	0,28	0,21	16-25	<15	16-25	16-25	15-45
Aimol	357,69	844,47	5,13	20,00	27,05	0,45	0,28	104628,21	8929329311,00	0,38	0,19	3,02	0,18	0,22	16-25	<15	16-25	<15	45-75
Akha	507,03	725,66	4,39	18,40	22,79	0,45	0,25	116660,65	14190769772,00	0,36	0,22	3,97	0,15	0,24	16-25	<15	<15	<15	45-75
Alorese	2,64	100,99	1,76	26,78	0,43	0,76	0,08	167525,44	23728404151,00	0,38	0,22	2,82	0,27	0,18	<15	16-25	<15	<15	45-75
Amba	1200,51	1353,30	3,61	19,30	0,30	0,76	0,04	193996,33	13230061873,00	0,54	0,17	3,42	0,18	0,21	<15	<15	<15	<15	45-75
Ami	1,80	297,45	3,67	22,78	15,97	0,47	0,27	131471,03	15275025962,00	0,47	0,11	2,85	0,23	0,18	<15	<15	<15	<15	45-75
Anaguta	567,15	958,42	1,46	23,34	2,79	0,60	0,14	110037,10	10752520350,00	0,32	0,31	1,11	0,26	0,26	<15	<15	<15	<15	45-75
Anuak	1001,71	465,03	0,37	22,93	1,47	0,65	0,11	187101,79	20849179556,00	0,38	0,25	1,31	0,20	0,24	<15	<15	<15	16-25	45-75
Ao	535,43	150,52	1,10	16,82	33,69	0,42	0,31	179460,48	42894348062,00	0,34	0,21	1,52	0,34	0,17	<15	<15	16-25	<15	45-75
Apinaye	374,32	177,70	0,76	24,65	1,87	0,65	0,11	245754,47	51558049606,00	0,32	0,32	1,58	0,22	0,24	16-25	16-25	<15	<15	45-75
Arbore	853,36	977,10	2,28	24,27	3,16	0,59	0,13	66131,55	3516476752,00	0,39	0,14	0,81	0,39	0,16	<15	<15	15-45	<15	45-75
Arikara	1338,75	588,04	0,81	7,69	176,05	0,20	0,31	38952,28	860454562,40	0,52	0,10	0,63	0,35	0,31	15-45	<15	<15	16-25	45-75
Asben	1336,63	771,13	1,42	24,73	36,40	0,40	0,25	14756,80	674404146,90	0,24	0,24	-0,18	0,64	0,17	<15	<15	45-75	<15	15-45
Asháninka	404,40	176,09	0,26	22,50	1,45	0,65	0,10	119770,55	5352258429,00	0,52	0,19	3,06	0,10	0,27	15-45	<15	<15	16-25	45-75
Atayal	53,85	1377,47	11,09	21,21	24,60	0,43	0,29	118186,24	10911121517,00	0,50	0,09	3,36	0,19	0,23	16-25	<15	<15	<15	45-75
Azande	1697,74	683,54	0,39	21,96	1,10	0,69	0,09	191222,45	13888434966,00	0,50	0,24	1,75	0,10	0,23	16-25	<15	<15	<15	45-75
Bacairi	1381,81	469,04	0,85	24,55	3,24	0,58	0,13	122925,94	14132908028,00	0,26	0,33	1,25	0,16	0,24	16-25	<15	16-25	15-45	45-75
Bafute	328,23	837,14	0,86	20,21	1,44	0,67	0,12	183005,87	15106533871,00	0,43	0,25	2,73	0,23	0,22	<15	<15	<15	<15	45-75
Baiga	504,36	346,60	0,44	22,98	28,43	0,39	0,28	119045,61	20536641180,00	0,29	0,22	0,80	0,26	0,27	<15	<15	<15	16-25	45-75
Balinese	1,76	447,93	3,12	26,42	0,36	0,77	0,07	183963,99	15442713680,00	0,50	0,14	4,20	0,16	0,20	<15	<15	15-45	<15	45-75
Banyang	139,06	279,58	2,61	22,85	1,50	0,67	0,12	178809,31	13895927578,00	0,47	0,24	2,70	0,18	0,26	<15	<15	<15	<15	45-75
Banyaruanda	1061,93	1422,33	1,89	16,74	1,07	0,67	0,09	155682,96	18719752040,00	0,42	0,28	2,22	0,32	0,14	<15	<15	15-45	<15	45-75
Barabra	260,25	273,04	0,63	24,54	48,37	0,36	0,30	3922,20	99943100,38	0,19	0,12	-0,05	1,00	0,00	<15	<15	15-45	<15	45-75
Barama River Carib	153,17	125,80	1,25	22,09	0,54	0,73	0,08	123855,80	8501746826,00	0,55	0,25	3,97	0,19	0,25	16-25	16-25	<15	16-25	15-45
Bete	143,98	167,45	0,37	23,59	1,42	0,67	0,13	148449,42	12007934520,00	0,47	0,26	2,62	0,20	0,23	<15	<15	<15	<15	45-75
Bhil	115,82	367,81	2,85	24,69	25,00	0,39	0,27	97684,16	21349455040,00	0,17	0,27	0,54	0,34	0,26	<15	<15	16-25	<15	45-75
Bikinians	0,14	0,01	0,00	27,19	0,43	0,75	0,08	159342,51	12438316825,00	0,48	0,19	0,90	0,46	0,07	<15	<15	<15	15-45	45-75
Bira	1296,91	944,11	1,18	19,94	0,30	0,77	0,05	226955,43	11179558329,00	0,62	0,13	3,80	0,09	0,25	<15	<15	<15	<15	>=75
Birifor	531,32	275,57	0,57	25,39	2,62	0,60	0,15	106101,90	11327497055,00	0,30	0,34	0,87	0,26	0,22	<15	<15	<15	<15	45-75
Bisa	661,91	280,11	0,35	26,09	5,97	0,52	0,19	74486,36	6995762761,00	0,29	0,33	0,23	0,36	0,23	<15	<15	<15	<15	45-75
Bobo	856,25	272,13	0,13	26,62	8,85	0,49	0,21	69892,61	7495201848,00	0,27	0,36	0,12	0,36	0,20	<15	<15	16-25	<15	45-75
Bontok	58,61	791,53	5,95	25,16	3,02	0,61	0,16	167495,61	21137694128,00	0,44	0,19	2,80	0,22	0,19	<15	<15	16-25	<15	45-75
Bororo Fulani	716,74	289,14	0,40	26,03	9,10	0,50	0,20	61213,27	5080640079,00	0,31	0,32	0,04	0,46	0,18	<15	<15	>=75	<15	16-25
Budu	1448,49	805,08	0,60	21,42	0,31	0,77	0,04	243307,95	9483286472,00	0,67	0,11	3,49	0,06	0,26	15-45	<15	<15	<15	45-75
Buem	146,54	158,83	1,19	24,80	1,32	0,66	0,11	113787,08	6842333406,00	0,43	0,25	1,45	0,36	0,17	16-25	<15	<15	<15	45-75

Bunlap	3,18	48,81	0,94	26,11	2,01	0,65	0,18	173785,63	13387756112,00	0,52	0,11	3,27	0,20	0,21	<15	<15	<15	<15	45-75
Burusho	1499,72	4677,38	15,07	-10,54	132,52	0,25	0,33	53185,11	1318317887,00	0,53	0,11	-0,03	0,85	0,12	<15	<15	15-45	<15	45-75
Canela	403,26	293,90	1,28	25,34	2,62	0,61	0,12	230093,11	68788797471,00	0,28	0,38	1,36	0,19	0,21	15-45	16-25	<15	<15	15-45
Cariña	147,54	162,21	0,43	27,24	0,75	0,71	0,09	47313,99	1538704047,00	0,53	0,26	1,21	0,44	0,16	<15	<15	<15	<15	>=75
Catawba	177,06	76,56	0,40	15,34	61,76	0,32	0,30	96559,16	2369453480,00	0,60	0,07	1,67	0,23	0,28	<15	<15	<15	<15	45-75
Chaambra	508,33	523,33	0,91	18,34	71,99	0,31	0,33	5977,84	69011621,60	0,28	0,07	-0,04	0,62	0,25	<15	<15	45-75	<15	16-25
Chácobo	758,37	167,66	0,19	26,43	1,72	0,62	0,09	97157,61	4643088500,00	0,43	0,24	2,14	0,12	0,25	16-25	16-25	<15	16-25	15-45
Chagga	306,80	1403,04	3,02	19,05	2,86	0,60	0,16	69841,81	3910439083,00	0,54	0,16	2,23	0,45	0,09	<15	<15	15-45	<15	45-75
Chahar	313,03	1169,43	4,08	2,80	181,88	0,24	0,36	55745,69	4662103275,00	0,35	0,25	0,71	0,35	0,38	<15	<15	>=75	<15	<15
Cham	13,96	34,42	0,47	25,97	1,41	0,66	0,12	162927,12	17206992207,00	0,44	0,19	1,39	0,43	0,14	<15	<15	16-25	<15	>=75
Chamorro	1,82	3,02	0,12	27,06	0,68	0,72	0,10	145605,24	14212042245,00	0,47	0,17	3,70	0,16	0,27	<15	<15	16-25	<15	45-75
Chawai	567,15	958,42	1,46	23,34	2,79	0,60	0,14	110037,10	10752520350,00	0,32	0,31	1,11	0,26	0,26	<15	<15	16-25	<15	45-75
Cherokee	437,04	822,09	4,39	12,60	64,48	0,31	0,29	104937,44	2426963765,00	0,62	0,06	2,61	0,10	0,41	16-25	<15	<15	16-25	45-75
Chewa	595,32	1036,92	1,84	19,14	11,42	0,50	0,23	106646,68	15053921231,00	0,39	0,28	2,14	0,17	0,30	16-25	<15	<15	<15	45-75
Chinantec	80,63	214,21	1,98	18,34	7,40	0,53	0,22	162223,95	4577464479,00	0,67	0,10	2,16	0,34	0,14	<15	<15	16-25	<15	>=75
Chukchi	168	93,25	1,72	-12,53	178,34	0,19	0,26	43569,92	556591264,80	0,58	0,04	0,42	0,54	0,29	16-25	<15	45-75	<15	<15
Cocama	4,41	890,22	4,90	22,70	0,26	0,76	0,02	256564,75	16219626157,00	0,61	0,12	2,33	0,24	0,18	<15	<15	<15	45-75	15-45
Coniagui	238,58	122,25	0,90	28,12	4,08	0,56	0,18	53899,59	4818628566,00	0,25	0,35	0,47	0,27	0,33	<15	16-25	<15	<15	45-75
Curripaco	592,07	616,94	4,18	21,50	0,32	0,76	0,04	327938,24	61683927938,00	0,44	0,26	3,87	0,16	0,28	16-25	<15	<15	15-45	45-75
Dagara	640,86	279,02	0,45	25,77	4,44	0,55	0,18	94588,34	10925222409,00	0,27	0,37	0,50	0,30	0,24	<15	<15	15-45	<15	45-75
Dahuni	3,67	437,28	5,07	25,54	1,25	0,68	0,15	174584,50	12756561738,00	0,54	0,15	3,48	0,16	0,22	<15	<15	<15	15-45	45-75
Dani	180,07	2446,31	11,10	19,91	0,19	0,80	0,03	365403,98	22850805065,00	0,65	0,07	2,90	0,24	0,16	<15	<15	<15	<15	>=75
Daza	1473,34	201,98	0,13	25,72	29,60	0,42	0,239434353	11443,30	438955508,00	0,29	0,23	-0,05	1,00	0,00	<15	<15	15-45	<15	15-45
Delaware	78,59	161,05	1,31	10,13	93,68	0,27	0,32	88892,56	1650692032,00	0,64	0,04	2,09	0,12	0,43	16-25	16-25	<15	16-25	15-45
Dogon	1080,89	323,84	0,75	27,18	16,24	0,45	0,22	39960,22	2776757623,00	0,29	0,32	-0,20	0,54	0,19	<15	16-25	16-25	<15	45-75
Druze	4,30	167,70	2,06	19,72	26,01	0,41	0,29	22585,52	639554699,70	0,38	0,16	1,20	0,36	0,20	<15	<15	<15	<15	>=75
Dyan	640,86	279,02	0,45	25,77	4,44	0,55	0,18	94588,34	10925222409,00	0,27	0,37	0,50	0,30	0,24	<15	<15	15-45	<15	45-75
Dzing	842,35	450,90	1,31	22,96	0,64	0,73	0,08	175745,31	11784954429,00	0,51	0,24	2,21	0,11	0,25	16-25	<15	<15	<15	45-75
Emberá	25,69	307,34	3,76	25,32	0,26	0,79	0,03	282178,67	66788679672,00	0,35	0,33	2,24	0,25	0,22	16-25	<15	<15	<15	45-75
Enga	163,03	1580,80	6,37	19,78	0,18	0,81	0,03	349730,58	28580874001,00	0,61	0,13	4,17	0,16	0,20	<15	<15	16-25	<15	45-75
Fang	144,82	511,41	0,94	23,22	0,25	0,79	0,05	185072,29	5681318043,00	0,67	0,12	2,05	0,23	0,25	<15	<15	<15	16-25	45-75
Fipa	884,63	1466,46	2,17	18,85	5,12	0,57	0,19	123074,50	18758274140,00	0,36	0,33	2,19	0,18	0,27	<15	<15	<15	15-45	45-75
Fore	101,84	1817,83	7,58	19,12	0,23	0,79	0,04	327433,58	30045541590,00	0,59	0,14	4,19	0,15	0,19	<15	<15	<15	<15	45-75
Gagu	212,83	222,88	0,54	23,48	1,85	0,64	0,14	135975,53	10307515210,00	0,44	0,28	2,59	0,20	0,24	15-45	<15	<15	<15	45-75
Garó	358,87	725,34	3,06	22,93	26,61	0,43	0,25	116149,27	15283382412,00	0,30	0,20	2,81	0,21	0,21	<15	<15	<15	<15	>=75
Gbande	190,74	413,89	1,14	22,29	2,03	0,65	0,15	230958,63	47691886928,00	0,35	0,33	3,17	0,13	0,29	<15	<15	<15	<15	45-75
Gbaya	723,87	772,99	1,22	21,01	1,53	0,66	0,13	144436,25	9502538686,00	0,26	0,69	1,43	0,14	0,25	<15	<15	<15	<15	45-75
Gheg	39,52	956,62	8,70	11,84	40,78	0,35	0,29	93554,72	4965584067,00	0,48	0,13	1,38	0,23	0,38	<15	<15	15-45	<15	45-75
Gogo	321,80	1081,53	4,73	19,46	4,98	0,57	0,20	105667,13	10965837982,00	0,48	0,24	2,08	0,28	0,20	<15	<15	15-45	<15	45-75
Guna	14,62	123,84	1,64	25,72	0,17	0,81	0,02	196658,84	32412931994,00	0,42	0,32	2,63	0,22	0,18	<15	<15	<15	15-45	45-75
Guro	212,83	222,88	0,54	23,48	1,85	0,64	0,14	135975,53	10307515210,00	0,44	0,28	2,59	0,20	0,24	16-25	<15	<15	<15	45-75
Hano	553,65	1675,56	1,16	10,89	101,49	0,26	0,32	33382,16	751192909,00	0,42	0,07	0,22	0,69	0,15	<15	0,5	15-45	<15	45-75
Hanuúo	25,18	366,71	4,50	26,78	0,86	0,71	0,09	186233,98	19797812460,00	0,47	0,17	2,53	0,24	0,17	<15	<15	<15	<15	45-75
Havasupai	514,85	1870,91	2,82	11,23	97,22	0,27	0,32	39527,91	1424041228,00	0,37	0,09	0,37	0,57	0,20	16-25	15-45	<15	<15	45-75
Haya	898,12	1134,05	0,00	18,62	0,68	0,70	0,07	128623,69	14304318419,00	0,38	0,27	1,36	0,70	0,07	<15	<15	15-45	16-25	45-75
Hazara	1039,85	3121,82	6,51	4,25	110,96	0,26	0,31	31604,43	1134163011,00	0,28	0,15	0,20	0,58	0,28	<15	<15	45-75	<15	45-75
Hidatsa	1236,35	569,77	0,74	6,82	187,56	0,19	0,32	37897,46	766656465,20	0,54	0,09	0,76	0,32	0,36	16-25	<15	<15	<15	45-75
Hill Bhuíya	154,82	133,40	1,14	24,19	23,70	0,40	0,26	129867,37	19562825562,00	0,33	0,22	1,20	0,26	0,21	<15	<15	16-25	<15	45-75
Hopi	553,65	1675,56	1,16	10,89	101,49	0,26	0,32	33382,16	751192909,00	0,42	0,074091728	0,22	0,69	0,15	<15	<15	<15	<15	45-75
Huichol	183,89	2060,05	3,85	14,77	10,35	0,51	0,24	139656,10	11745418019,00	0,46	0,14	1,71	0,29	0,26	16-25	<15	<15	<15	45-75
Huron	484,47	97,49	0,25	7,31	121,77	0,25	0,32	75250,30	1117728850,00	0,65	0,05	1,56	NA	NA	<15	<15	<15	15-45	45-75
Iatmul	70,33	22,96	0,32	20,92	0,24	0,79	0,05	365849,96	23468227861,00	0,66	0,09	2,93	0,31	0,15	<15	<15	<15	15-45	45-75
Ibibio	24,71	24,82	0,24	24,77	0,91	0,71	0,10	164988,01	10702093361,00	0,50	0,21	1,53	0,29	0,21	<15	<15	<15	16-25	45-75

Ifaluk	0,36	0,00	0,00	27,64	0,08	0,85	0,01	273484,46	14283286566,00	0,66	0,05	2,75	0,27	0,12	<15	<15	<15	15-45	45-75
Ifugao	58,61	791,53	5,95	25,16	3,02	0,61	0,16	167495,61	21137694128,00	0,44	0,19	2,80	0,22	0,19	16-25	<15	<15	<15	45-75
Igbo	139,82	114,55	0,71	24,34	1,98	0,65	0,13	138826,04	1,98	0,48	0,23	1,40	0,37	0,17	<15	<15	<15	<15	>=75
Ila	904,07	1078,26	0,35	20,83	12,75	0,47	0,22	95912,51	15750401614,00	0,26	0,31	1,56	0,17	0,29	<15	<15	15-45	<15	45-75
Iraqw	464,54	1671,28	1,92	19,05	3,22	0,59	0,15	87453,74	10443153939,00	0,45	0,23	2,06	0,27	0,21	<15	<15	45-75	<15	45-75
Iwa	816,66	1243,63	0,89	17,78	8,77	0,53	0,22	117924,01	18211605052,00	0,39	0,33	2,20	0,19	0,27	<15	<15	<15	<15	>=75
Jemez	776,92	2093,44	2,87	6,89	104,87	0,26	0,31	60834,52	1273609490,00	0,56	0,05	0,96	0,37	0,27	16-25	16-25	<15	<15	45-75
Jur	1498,53	447,95	0,31	24,85	2,37	0,61	0,14	116212,58	7429342236,00	0,42	0,26	0,48	0,24	0,21	<15	<15	16-25	<15	45-75
Kabyle	96,37	637,90	1,74	17,16	53,48	0,33	0,29	26627,79	359595815,20	0,49	0,49	0,28	0,56	0,56	<15	<15	15-45	<15	45-75
Kachin	662,53	685,48	6,39	17,57	27,75	0,44	0,31	112411,03	8627735957,00	0,42	0,18	3,61	0,10	0,29	<15	<15	16-25	<15	45-75
Kadazan-Dusun	62,33	168,76	2,82	25,17	0,21	0,80	0,04	207120,07	8656099523,00	0,66	0,05	3,74	0,17	0,19	<15	<15	16-25	16-25	45-75
Kakoli	163,03	1580,80	6,37	19,78	0,18	0,81	0,03	349730,58	28580874001,00	0,61	0,13	4,17	0,16	0,20	<15	<15	<15	<15	45-75
Kalinga	53,26	629,63	5,84	25,38	3,84	0,59	0,18	153686,84	19303377937,00	0,43	0,19	3,48	0,16	0,23	16-25	<15	<15	<15	45-75
Kamayurá	1135,41	321,97	0,45	24,50	3,79	0,57	0,17	133138,77	15646577187,00	0,27	0,34	2,53	0,10	0,31	<15	16-25	<15	15-45	15-45
Kaoka	11,77	52,30	0,85	27,39	0,29	0,78	0,07	278247,05	16021527620,00	0,65	0,04	3,73	0,21	0,18	<15	<15	<15	15-45	45-75
Kara	750,22	1155,98	0,42	19,86	0,86	0,69	0,08	120448,76	17128915243,00	0,32	0,30	1,55	NA	NA	<15	<15	15-45	16-25	45-75
Karekare	836,87	396,75	0,30	25,57	8,24	0,51	0,19	62808,45	5048116214,00	0,30	0,33	0,15	0,41	0,21	<15	<15	<15	<15	45-75
Kayapo	641,91	425,54	1,41	23,72	2,14	0,62	0,15	202287,58	31344533546,00	0,35	0,34	3,08	0,09	0,28	16-25	<15	<15	<15	45-75
Keraki	16,33	9,74	0,09	26,59	1,02	0,70	0,12	156481,66	17586384064,00	0,43	0,23	2,28	0,29	0,15	<15	<15	<15	<15	45-75
Khalka	1858,74	2109,31	3,77	-2,99	256,73	0,22	0,35	26098,48	353038440,80	0,54	0,09	0,15	0,62	0,27	<15	<15	>=75	<15	<15
Kikuyu	403,12	1443,92	1,33	17,92	2,07	0,62	0,14	52669,70	2351512834,00	0,55	0,15	1,80	0,33	0,18	<15	<15	15-45	<15	45-75
Kimam	12,19	5,55	0,05	26,76	0,82	0,71	0,13	167735,47	13741738381,00	0,47	0,17	3,14	0,23	0,16	<15	16-25	<15	<15	45-75
Kissi	279,61	605,15	1,28	22,14	2,57	0,62	0,18	199226,27	36033841413,00	0,30	0,34	2,98	0,19	0,24	<15	<15	<15	<15	>=75
Kodavas	59,19	755,94	2,66	24,64	1,40	0,68	0,13	206521,57	48131988832,00	0,34	0,28	3,00	0,19	0,22	<15	<15	16-25	<15	45-75
Kpe	24,27	260,78	2,30	24,95	0,34	0,77	0,07	212615,84	14404955165,00	0,53	0,19	1,71	0,29	0,21	<15	<15	15-45	<15	45-75
Kpelle	168,77	278,74	0,58	23,27	1,67	0,66	0,14	203221,95	31535205520,00	0,41	0,30	2,90	0,16	0,29	<15	<15	<15	<15	45-75
Krahn	151,12	208,66	0,44	23,85	1,30	0,68	0,13	170030,00	17504744958,00	0,46	0,26	2,80	0,18	0,23	<15	<15	<15	<15	45-75
Kuba	1022,65	544,04	0,95	22,54	0,72	0,72	0,08	172282,76	14911292219,00	0,41	0,27	2,54	0,10	0,26	<15	<15	<15	16-25	45-75
Kuikuru	1236,46	386,26	0,71	24,47	3,29	0,58	0,15	127652,15	15121763255,00	0,26	0,33	2,04	0,07	0,32	<15	<15	<15	16-25	45-75
Kulango	207,99	233,66	0,80	23,72	1,93	0,64	0,14	123888,69	8057890777,00	0,45	0,24	2,62	0,16	0,28	<15	<15	16-25	<15	45-75
Kumu	1413,60	701,65	1,47	21,01	0,97	0,75	0,06	244159,72	13402719796,00	0,60	0,16	3,47	0,12	0,21	15-45	<15	<15	<15	45-75
Kunda	585,57	655,68	1,81	22,44	11,09	0,49	0,22	94550,64	14090898866,00	0,34	0,29	1,63	0,20	0,26	<15	<15	<15	<15	45-75
Kundu	567,15	958,42	1,46	23,34	2,79	0,60	0,14	110037,10	10752520350,00	0,32	0,31	1,11	0,26	0,26	<15	<15	16-25	<15	45-75
Kurtatchi	6,23	174,44	1,82	27,22	0,31	0,79	0,07	280132,84	14939851997,00	0,67	0,05	2,93	0,29	0,14	<15	<15	<15	16-25	45-75
Lakalai	3,16	374,50	3,48	26,32	0,31	0,78	0,08	271024,84	13402360753,00	0,68	0,05	3,37	0,20	0,23	<15	16-25	<15	16-25	15-45
Lamet	497,35	781,63	5,28	19,65	20,89	0,45	0,24	125905,66	17970820984,00	0,34	0,26	3,89	0,15	0,26	16-25	<15	16-25	<15	45-75
Lamotrek	0,61	0,00	0,00	27,63	0,08	0,85	0,01	275682,85	14694739960,00	0,65	0,05	NA	NA	NA	<15	<15	<15	15-45	45-75
Lau	1,39	0,03	0,00	25,61	2,43	0,63	0,18	161981,07	10881084118,00	0,54	0,07	3,90	0,21	0,23	<15	<15	<15	15-45	45-75
Lawa	127,31	713,48	5,22	23,69	12,18	0,47	0,22	139419,56	28260811769,00	0,27	0,29	3,31	0,08	0,30	<15	<15	<15	<15	>=75
Lele	920,60	513,65	1,38	22,69	0,67	0,72	0,08	171380,69	13786380862,00	0,43	0,27	2,51	0,10	0,26	<15	<15	<15	<15	45-75
Lepcha	604,30	4354,04	9,56	2,87	51,40	0,38	0,30	193285,55	52455365945,00	0,32	0,24	0,48	0,49	0,23	<15	<15	<15	<15	45-75
Lesu	1,63	106,22	1,60	27,52	0,19	0,81	0,04	221072,12	9190985596,00	0,62	0,02	3,41	0,22	0,16	<15	<15	<15	15-45	15-45
Li	36,70	415,21	4,52	24,27	17,30	0,47	0,26	107151,12	12425114579,00	0,40	0,20	3,06	0,22	0,17	<15	<15	<15	<15	45-75
Ili-Mandiri	4,01	57,95	1,33	26,94	0,40	0,76	0,07	168017,22	19724883062,00	0,42	0,19	3,45	0,22	0,19	<15	<15	<15	15-45	45-75
Lobi	524,40	331,99	0,67	25,25	2,88	0,59	0,16	112869,44	13075485836,00	0,29	0,35	1,01	0,25	0,23	<15	16-25	<15	<15	45-75
Lokono	0,14	9,75	0,10	26,22	0,79	0,70	0,10	90660,99	5064667854,00	0,53	0,25	3,34	0,23	0,20	<15	<15	<15	15-45	45-75
Lolo	954,03	1995,19	1995,19	8,38	49,22	0,34	0,33	192218,85	28069010048,00	0,45	0,27	1,79	0,16	0,32	<15	<15	15-45	<15	45-75
Lotuko	1085,67	1116,66	2,45	23,81	2,72	0,62	0,12	121924,37	10631556968,00	0,39	0,18	1,44	0,21	0,25	16-25	<15	15-45	<15	15-45
Lovedu	254,95	434,65	0,69	17,62	10,47	0,50	0,21	99002,38	9388284713,00	0,42	0,19	1,33	0,32	0,18	<15	<15	15-45	<15	45-75
Lozi	1055,19	1048,14	0,20	21,27	9,70	0,51	0,22	116187,87	18444498077,00	0,22	0,32	1,18	0,20	0,25	16-25	<15	16-25	<15	15-45
Luapula	1142,34	1273,23	0,90	19,23	7,01	0,54	0,21	141280,58	24264393558,00	0,36	0,35	2,15	0,12	0,27	<15	<15	<15	15-45	45-75
Luo	703,55	1314,22	1,36	19,42	0,93	0,68	0,09	94339,47	11215854123,00	0,34	0,23	2,32	0,33	0,16	<15	<15	16-25	<15	45-75



Maasi	455,2842844	1057,47	2,35	18,96	2,36	0,61	0,14	62002,16	4394659365,00	0,49	0,17	1,04	0,40	0,12	<15	<15	>=75	<15	<15
Macassarese	32,51	388,53	3,43	27,15	0,38	0,76	0,08	157292,40	10746023095,00	0,48	0,12	3,13	0,25	0,20	<15	<15	16-25	16-25	45-75
Madia	253,29	425,52	1,83	24,43	14,83	0,45	0,24	138058,44	26362286210,00	0,31	0,26	1,46	0,16	0,26	<15	16-25	16-25	<15	45-75
Majuro	0,78	0,02	0,00	27,50	0,10	0,84	0,02	279388,96	15593397736,00	0,62	0,08	0,74	0,66	0,03	<15	<15	<15	15-45	45-75
Makin	2,51	0,05	0,00	27,40	0,15	0,79	0,01	209493,38	23456572588,00	0,47	0,09	1,56	0,50	0,07	<15	<15	<15	15-45	15-45
Mambila	407,73	1047,95	1,58	19,71	2,29	0,64	0,14	167732,46	16112833795,00	0,36	0,28	2,18	0,21	0,25	<15	<15	16-25	<15	>=75
Mambwe	1076,54	402,29	0,03	24,73	2,69	0,61	0,16	119347,59	8216232591,00	0,40	0,28	0,74	0,21	0,25	<15	<15	16-25	<15	45-75
Mamvu	1397,00	924,65	0,71	20,47	0,37	0,75	0,05	221198,53	12804449399,00	0,60	0,17	3,42	0,06	0,25	<15	<15	<15	<15	45-75
Mandan	1236,35	569,77	0,74	6,82	187,56	0,19	0,32	37897,46	766656465,20	0,54	0,09	0,76	0,32	0,36	15-45	<15	<15	16-25	45-75
Mapuche	319,27	376,03	0,88	10,34	40,44	0,36	0,30	41571,08	843655633,40	0,52	0,04	0,43	0,54	0,18	<15	<15	16-25	<15	45-75
Margi	830,35	526,30	0,97	24,85	5,34	0,54	0,17	75630,68	6162380149,00	0,32	0,34	0,52	0,28	0,25	<15	<15	16-25	<15	45-75
Marind-Amin	5,02	4,35	0,05	26,34	0,87	0,71	0,12	165555,76	14843210399,00	0,47	0,19	2,32	0,29	0,13	16-25	<15	<15	16-25	15-45
Marquesans	2,57	17,48	0,37	26,81	0,30	0,75	0,04	154798,14	22176393604,00	0,45	0,19	3,22	0,33	0,11	<15	<15	<15	15-45	45-75
Marri	546,41	1057,97	2,74	20,21	80,04	0,30	0,31	26987,48	1993955714,00	0,18	0,16	0,06	0,60	0,15	<15	<15	45-75	<15	15-45
Mbum	571,87	1090,44	1,07	19,47	2,68	0,63	0,16	155366,48	13853376632,00	0,35	0,28	1,90	0,16	0,28	15-45	<15	<15	<15	15-45
Mbundu	241,11	1655,28	1,21	17,79	2,70	0,61	0,13	122622,70	13467979126,00	0,29	0,28	2,36	0,21	0,25	<15	<15	16-25	<15	45-75
Mee	54,86	806,52	5,97	23,97	0,36	0,77	0,07	330068,14	29213650732,00	0,59	0,06	3,43	0,17	0,25	<15	<15	16-25	<15	45-75
Mekeo	7,20	308,69	2,97	25,24	1,00	0,70	0,13	166767,40	14598519070,00	0,49	0,19	4,15	0,29	0,15	<15	<15	<15	<15	45-75
Mende	127,29	271,31	1,20	23,74	1,68	0,67	0,14	252285,28	62410786057,00	0,35	0,35	2,95	0,14	0,27	<15	<15	<15	<15	45-75
Messiria Humr	1332,35	444,34	0,10	25,55	3,92	0,57	0,16	73558,59	4432881245,00	0,35	0,30	0,20	0,36	0,21	<15	<15	45-75	<15	15-45
Miao	478,72	977,71	2,84	14,24	51,96	0,36	0,32	108771,19	7725928053,00	0,46	0,17	1,44	0,23	0,26	<15	<15	16-25	<15	45-75
Minchia	869,89	2206,12	7,15	10,86	28,10	0,42	0,32	137972,01	11204436072,00	0,48	0,16	2,42	0,25	0,21	<15	<15	16-25	<15	45-75
Mnong Gar	160,21	321,84	1,45	23,74	2,60	0,61	0,14	193655,04	27512600566,00	0,45	0,25	3,54	0,18	0,21	<15	<15	16-25	16-25	45-75
Motu	7,20	308,69	2,97	25,24	1,00	0,70	0,13	166767,40	14598519070,00	0,49	0,19	4,15	0,29	0,15	<15	<15	<15	15-45	45-75
Muju	231,58	53,73	0,27	24,31	0,51	0,75	0,08	347725,94	21869230720,00	0,63	0,08	2,69	0,17	0,26	<15	<15	16-25	<15	45-75
Mumuye	586,44	462,88	2,39	24,02	1,88	0,63	0,11	113972,17	9896182724,00	0,36	0,30	1,10	0,23	0,25	<15	<15	16-25	<15	45-75
Myaamia	766,40	261,12	0,21	11,52	114,50	0,25	0,31	84531,65	1949865906,00	0,59	0,05	1,15	0,24	0,40	15-45	16-25	<15	<15	15-45
Nama	289,67	1032,86	0,62	20,44	20,63	0,43	0,22	39669,86	2158663295,00	0,30	0,16	0,12	0,67	0,10	15-45	<15	45-75	<15	<15
Nauruans	1,37	0,02	0,00	27,52	0,17	0,77	0,01	117091,70	9608083201,00	0,39	0,04	1,58	0,46	0,10	<15	<15	<15	15-45	45-75
Navajo	694,85	1714,15	1,89	10,45	115,20	0,25	0,33	36422,40	693927816,90	0,45	0,07	0,21	0,67	0,16	<15	16-25	15-45	<15	15-45
Ndembu	1326,30	1497,34	0,84	18,28	7,46	0,55	0,20	146959,56	23765211571,00	0,35	0,35	2,15	0,12	0,29	16-25	<15	<15	<15	45-75
Ndyuka	69,48	116,93	0,75	25,49	0,87	0,69	0,09	98274,39	6451318535,00	0,53	0,22	3,82	0,12	0,25	<15	<15	<15	<15	>=75
Ngala	896,57	325,18	0,15	22,94	0,27	0,78	0,05	188283,91	6321638490,00	0,66	0,14	2,67	0,03	0,27	<15	<15	<15	15-45	15-45
Ngarawapum	52,10	1071,37	7,05	19,46	0,35	0,77	0,06	325294,97	34514342882,00	0,58	0,15	3,49	0,22	0,16	16-25	16-25	16-25	<15	45-75
Ngere	240,71	270,66	0,48	22,87	1,88	0,65	0,15	175544,92	19943006262,00	0,42	0,29	2,91	0,16	0,26	<15	<15	16-25	16-25	45-75
Ngombe	1121,19	371,29	0,38	22,83	0,32	0,77	0,05	188204,32	7378565987,00	0,64	0,15	2,42	0,06	0,25	16-25	<15	<15	16-25	45-75
Ngoni	764,28	1181,95	0,89	19,36	10,26	0,51	0,22	108967,74	16053942987,00	0,38	0,31	1,94	0,26	0,27	<15	<15	<15	16-25	45-75
Nicobarese	4,84	0,47	0,01	26,60	1,41	0,67	0,14	162840,66	20262542464,00	0,40	0,19	3,02	0,16	0,25	<15	<15	<15	16-25	45-75
Niueans	6,54	1,83	0,03	24,96	2,65	0,62	0,18	136966,38	7661467639,00	0,54	0,06	3,31	0,25	0,24	<15	<15	<15	45-75	45-75
Nsaw	252,80	833,62	1,57	20,75	1,36	0,68	0,12	187740,91	15731303961,00	0,45	0,25	2,94	0,26	0,21	<15	<15	<15	<15	>=75
Nupe	339,50	133,88	0,67	24,45	1,55	0,64	0,11	126172,57	11507784946,00	0,35	0,29	0,97	0,34	0,17	<15	<15	<15	<15	45-75
Nyakyusa	583,68	1891,42	3,88	17,86	7,47	0,55	0,20	108215,33	14168511801,00	0,44	0,29	2,32	0,23	0,24	<15	<15	16-25	<15	45-75
Nyamwezi	649,67	1216,43	0,53	21,03	2,50	0,60	0,14	106582,38	15717116419,00	0,35	0,32	1,67	0,21	0,26	<15	<15	<15	<15	45-75
Nyankole	1048,66	1281,15	0,84	18,60	0,50	0,72	0,06	150722,58	14072964595,00	0,43	0,23	2,05	0,36	0,12	<15	<15	15-45	<15	45-75
Nyoro	1050,80	1056,75	0,40	22,58	1,30	0,68	0,09	144039,04	15069126112,00	0,42	0,17	1,92	0,18	0,19	<15	<15	16-25	<15	45-75
Omaha	1236,69	321,41	0,58	12,04	157,97	0,21	0,32	56576,73	1479082272,00	0,51	0,11	0,99	0,26	0,36	15-45	<15	<15	<15	15-45
Orokaiva	52,54	1002,63	6,53	23,70	1,05	0,69	0,13	185681,39	10919413329,00	0,58	0,15	4,24	0,19	0,20	<15	<15	<15	16-25	45-75
Paiwan	15,25	183,75	2,88	23,99	13,32	0,49	0,26	121982,75	15323340427,00	0,44	0,11	3,83	0,23	0,17	16-25	<15	<15	<15	45-75
Palaung	478,93	930,19	4,70	21,09	21,14	0,44	0,25	107503,91	12260014652,00	0,33	0,23	3,22	0,16	0,22	<15	<15	16-25	<15	>=75
Panare	460,87	552,00	4,78	21,39	1,02	0,67	0,08	156506,89	24530921795,00	0,40	0,25	4,69	0,20	0,22	15-45	<15	<15	16-25	45-75
Paresi	1366,09	214,24	0,79	26,01	3,12	0,58	0,12	106033,93	9982277662,00	0,28	0,31	1,80	0,08	0,28	16-25	16-25	<15	<15	45-75
Pawnee	1435,06	789,01	0,48	10,23	40,63	0,22	0,31	49431,81	1386862473,00	0,50	0,12	0,79	0,32	0,32	15-45	<15	<15	<15	45-75
Pedi	272,83	1568,00	4,03	14,54	12,44	0,48	0,23	92810,09	6312434612,00	0,44	0,19	2,12	0,24	0,33	<15	<15	15-45	<15	45-75

Piapoco	491,88	86,90	0,52	24,81	1,74	0,65	0,10	316063,40	86694974362,00	0,37	0,32	1,09	0,45	0,14	16-25	<15	<15	16-25	45-75
Picuris	846,88	2298,68	3,59	6,96	92,23	0,27	0,32	63833,91	1627921380,00	0,54	0,08	1,39	0,27	0,30	16-25	<15	<15	<15	45-75
Podokwo	896,08	451,73	0,94	25,46	5,18	0,54	0,17	71063,12	5476210063,00	0,32	0,35	0,23	0,35	0,19	<15	<15	16-25	<15	>=75
Popoi	1643,76	527,73	0,46	22,43	0,33	0,76	0,05	230789,74	9559562628,00	0,66	0,14	2,86	0,05	0,26	16-25	<15	<15	<15	45-75
Pukapukans	1,38	0,00	0,00	27,52	0,15	0,82	0,03	239561,28	11517650221,00	0,65	0,07	NA	NA	NA	<15	<15	<15	15-45	45-75
Purum	357,69	844,47	5,13	20,00	27,05	0,45	0,28	104628,21	8929329311,00	0,38	0,19	3,02	0,18	0,22	<15	<15	16-25	<15	45-75
Puyuma	25,08	297,45	3,67	22,78	15,97	0,47	0,27	131471,03	15275025962,00	0,47	0,11	2,85	0,23	0,18	<15	<15	<15	<15	45-75
Qashqui	143,38	1961,05	4,77	18,86	89,30	0,31	0,35	21092,24	1285394021,00	0,18	0,12	0,16	0,53	0,26	<15	<15	>=75	<15	<15
Quechan	146,24	229,30	0,96	20,79	0,30	0,30	0,30	17822,17	0,26	0,11	0,11	0,03	0,59	0,20	<15	16-25	<15	16-25	45-75
Reddi	101,41	581,01	3,66	24,33	10,43	0,49	0,24	141620,66	24506252038,00	0,36	0,25	1,89	0,16	0,27	<15	16-25	<15	<15	45-75
Sakalava	6,02	46,82	0,25	25,64	5,52	0,56	0,22	64203,69	8449879269,00	0,27	0,25	1,42	0,27	0,18	<15	<15	45-75	<15	15-45
Samburu	530,82	1226,46	2,23	21,02	1,29	0,67	0,10	45335,30	2706384224,00	0,40	0,15	0,85	0,50	0,12	<15	<15	>=75	<15	<15
Sapo	84,33	174,64	0,54	24,75	0,95	0,70	0,12	189545,08	25542539762,00	0,44	0,27	2,52	0,18	0,22	<15	<15	<15	16-25	45-75
Sateré Mawé	545,41	4,53	0,46	24,84	0,86	0,692032863	0,09	186124,37	16582574468,00	0,49	0,25	3,44	0,13	0,26	16-25	<15	<15	<15	45-75
Sema	507,06	1082,01	8,85	18,63	30,98	0,43	0,30	97213,12	7864901987,00	0,38	0,19	3,34	0,12	0,29	<15	<15	16-25	16-25	45-75
Sena	140,25	118,77	0,48	23,14	9,68	0,51	0,21	105555,58	11245276016,00	0,44	0,20	1,96	0,25	0,20	<15	<15	<15	<15	45-75
Seneca	348,15	272,44	1,50	7,76	114,26	0,25	0,32	82005,77	1331502405,00	0,65	0,05	1,33	0,21	0,42	15-45	<15	<15	16-25	15-45
Senoi	109,42	215,00	2,47	24,37	0,31	0,78	0,05	248762,45	18691867658,00	0,58	0,13	3,10	0,23	0,19	<15	<15	<15	16-25	45-75
Shambaa	114,10	530,83	1,55	19,71	3,43	0,60	0,19	107772,98	3509696126,00	0,62	0,09	1,92	0,33	0,11	<15	<15	15-45	<15	45-75
Sherpa	648,15	3592,45	15,95	5,84	45,87	0,39	0,29	278598,72	12500000000,00	0,39	0,29	1,10	0,36	0,23	<15	<15	45-75	<15	45-75
Shilluk	1009,74	395,46	0,02	25,48	4,08	0,59	0,17	103203,75	6976110728,00	0,38	0,30	0,56	0,29	0,22	<15	<15	16-25	<15	45-75
Shina	1214,91	2328,06	14,13	8,22	97,23	0,29	0,32	84959,09	6511299256,00	0,40	0,07	1,36	0,24	0,40	<15	<15	15-45	<15	45-75
Shona	388,32	1309,61	0,99	18,62	12,61	0,49	0,21	80000,56697 - monthly	9844635651,00	0,37	0,23	1,83	0,27	0,24	<15	<15	16-25	<15	45-75
Sia	776,92	2093,44	2,87	6,89	104,87	0,26	0,31	60834,52	1273609490,00	0,56	0,05	0,96	0,37	0,27	<15	<15	16-25	<15	45-75
Siane	101,84	1817,83	7,58	19,12	0,23	0,79	0,04	327433,58	30045541590,00	0,59	0,14	4,19	0,15	0,19	<15	<15	<15	<15	45-75
Sio	6,49	1705,41	8,92	21,07	0,38	0,77	0,08	322209,80	36508281191,00	0,57	0,14	2,93	0,24	0,16	<15	<15	<15	15-45	45-75
Somali	186,56	563,87	0,49	24,67	4,94	0,55	0,18	43922,29	2717708916,00	0,39	0,22	0,27	0,74	0,04	<15	<15	>=75	<15	<15
Sonjo	401,27	1306,43	3,05	18,94	2,69	0,60	0,15	73136,75	6457756809,00	0,49	0,19	1,15	0,42	0,14	<15	<15	16-25	<15	>=75
Sotho	301,39	2345,15	5,56	10,68	17,61	0,45	0,26	124839,60	7069531633,00	0,50	0,18	1,50	0,28	0,35	<15	<15	15-45	<15	45-75
Subanun	19,12	176,53	2,33	26,38	0,14	0,82	0,02	223654,19	6795251210,00	0,67	0,04	3,03	0,30	0,15	<15	<15	<15	<15	>=75
Suku	572,91	875,05	1,28	21,48	0,74	0,72	0,08	138862,81	9110469846,00	0,45	0,23	1,63	0,15	0,23	16-25	<15	<15	<15	45-75
Sumbawane	21,00	385,10	4,25	26,79	0,36	0,77	0,07	186978,21	20448903330,00	0,46	0,16	4,19	0,22	0,17	<15	<15	<15	<15	45-75
Sundi	184,70	401,29	1,55	23,37	0,72	0,71	0,10	134133,84	8573238351,00	0,52	0,23	2,00	0,24	0,21	<15	<15	<15	<15	45-75
Tanala	104,33	558,84	3,06	21,08	8,09	0,53	0,23	95639,95	8615565933,00	0,47	0,17	4,45	0,19	0,22	<15	<15	16-25	16-25	45-75
Taos	917,73	2551,05	3,41	5,35	97,15	0,27	0,32	62234,36	1488989584,00	0,55	0,08	0,71	0,39	0,33	<15	<15	<15	<15	45-75
Tapirapé	955,10	248,41	0,44	25,06	3,23	0,59	0,15	146834,60	19950602300,00	0,28	0,34	1,46	0,14	0,27	<15	<15	<15	15-45	45-75
Teda	1046,66	1857,04	3,68	21,24	46,53	0,36	0,27	5033,01	135962270,30	0,17	0,14	-0,04	0,70	0,19	<15	16-25	15-45	<15	45-75
Teita	62,83	183,36	0,77	22,78	2,44	0,61	0,17	96037,26	3332415560,00	0,592757318	0,10	1,93	0,38	0,13	<15	<15	15-45	<15	45-75
Teke	395,71	569,29	2,54	21,95	0,42	0,75	0,07	167835,28	8596792667,00	0,57	0,20	1,85	0,36	0,14	<15	<15	<15	<15	45-75
Ticuna	1066,00	117,59	0,30	24,57	0,37	0,75	0,05	190178,38	7759582638,00	0,60	0,19	3,19	0,18	0,22	<15	<15	<15	15-45	15-45
Tigre	4,21	53,55	0,30	26,50	12,43	0,47	0,26	16735,61	409641256,20	0,32	0,10	0,06	0,70	0,14	<15	<15	>=75	<15	16-25
Tikar	328,23	837,14	0,86	20,21	15106533871,00	0,67	0,12	183005,87	15106533871,00	0,43	0,25	2,73	0,23	0,22	<15	<15	<15	<15	>=75
Tikopia	0,06	0,09	0,01	27,24	0,64	0,73	0,11	239613,60	15697970977,00	0,62	0,06	1,87	0,41	0,09	<15	<15	<15	45-75	45-75
Tiriki	1848,30	1848,30	2,15	19,40	1,24	0,66	0,09	68198,10	6129817057,00	0,39	0,16	4,39	0,26	0,15	<15	<15	15-45	<15	45-75
Tiv	243,40	280,08	2,62	23,19	1,99	0,65	0,13	161826,88	13611477259,00	0,40	0,26	1,31	0,39	0,13	16-25	<15	<15	<15	45-75
Toda	152,81	684,39	3,09	22,56	2,62	0,60	0,17	179394,17	30744064387,00	0,40	0,25	2,08	0,28	0,17	<15	<15	>=75	<15	<15
Tonga	660,27	604,91	1,26	19,17	8,90	0,53	0,23	108738,28	15423010273,00	0,41	0,30	2,19	NA	NA	<15	<15	15-45	<15	15-45
Tristan da Cunha	3,10	18,02	0,52	6,38	15,40	0,54	0,23	91369,05	1805362026,00	0,65	0,06	3,05	0,10	0,40	<15	<15	16-25	15-45	15-45
Trobriands	2,44	0,31	0,01	26,79	0,73	0,73	0,12	223167,95	12381981194,00	0,61	0,07	2,91	0,24	0,18	<15	<15	<15	15-45	45-75
Tuareg Ahaggar	1239,62	1159,97	1,63	20,75	54,18	0,34	0,30	5661,32	187574058,80	0,16	0,12	-0,05	1,00	0,00	<15	<15	45-75	<15	15-45
Tupinambá	12,41	13,07	0,12	23,79	1,42	0,67	0,15	129478,13	10112576766,00	0,51	0,23	2,84	0,32	0,17	16-25	16-25	<15	16-25	15-45



Tura	345,93	310,48	0,69	22,50	2,14	0,63	0,15	154360,51	15629346320,00	0,36	0,31	2,23	0,28	0,19	<15	<15	<15	<15	>=75
Ulawans	5,27	17,26	0,47	27,34	0,33	0,78	0,08	275106,36	15811541694,00	0,65	0,04	3,28	0,22	0,18	<15	<15	<15	15-45	45-75
Ulithians	0,23	0,01	0,00	27,51	0,17	0,81	0,03	229984,55	11819976152,00	0,62	0,05	NA	NA	NA	<15	<15	<15	15-45	45-75
Umotina	1435,62	294,64	1,61	26,23	3,05	0,58	0,13	110350,01	11004295196,00	0,27	0,31	1,29	0,16	0,20	16-25	16-25	<15	<15	45-75
Upolu Samoans	8,65	21,03	0,36	26,99	0,62	0,74	0,11	219723,26	12213542079,00	0,62	0,06	3,49	0,24	0,17	<15	<15	<15	15-45	45-75
Usiai	2,79	24,72	0,41	27,71	0,16	0,81	0,03	219223,79	10765114054,00	0,59	0,03	3,09	0,22	0,16	<15	16-25	16-25	<15	45-75
Vanua Levu	25,42	215,92	2,83	25,38	2,54	0,62	0,19	160464,97	11207299165,00	0,53	0,09	4,25	0,19	0,20	<15	<15	<15	15-45	45-75
Venda	405,40	776,11	2,53	19,09	11,36	0,49	0,19	78645,35	7342754886,00	0,38	0,20	1,87	0,28	0,17	<15	<15	16-25	<15	45-75
Vugusu	709,76	1867,52	2,27	20,57	1,64	0,64	0,09	72322,03	6707058434,00	0,36	0,14	2,61	0,22	0,19	<15	<15	15-45	<15	45-75
Wantoat	43,08	1681,33	10,65	19,89	0,42	0,76	0,08	330001,82	37678605809,00	0,57	0,15	3,16	0,22	0,17	16-25	<15	<15	<15	45-75
Wayuu	17,11	53,81	0,57	26,13	1,22	0,69	0,17	25502,40	690620975,30	0,49	0,20	0,64	0,56	0,07	<15	<15	45-75	<15	<15
Wodaabe Fulani	874,70	380,97	0,17	25,45	8,77	0,50	0,19	62734,29	5202997730,00	0,30	0,34	0,09	0,41	0,19	<15	<15	>=75	<15	<15
Wogeo	4,21	2,52	0,12	26,75	0,08	0,84	0,01	287703,77	20282610586,00	0,63	0,07	2,22	0,33	0,12	<15	16-25	<15	16-25	45-75
Yagua	858,93	121,64	0,25	24,57	0,39	0,05	0,75	186218,66	8510722559,00	0,58	0,21	3,23	0,17	0,24	45-75	<15	<15	<15	15-45
Yakut	684,27	68,30	0,60	-12,32	462,20	0,13	0,35	27199,94	275799172,60	0,57	0,07	0,58	0,48	0,32	16-25	<15	15-45	16-25	<15
Yao	476,87	710,81	1,09	19,98	7,86	0,54	0,22	108716,73	14422661246,00	0,44	0,28	2,27	0,19	0,27	<15	<15	<15	16-25	45-75
Yombe	97,60	330,77	1,67	24,52	0,73	0,72	0,10	131393,66	767931207,00	0,50	0,23	2,16	0,21	0,23	16-25	<15	<15	16-25	45-75
Yupa	27,77	431,98	3,23	23,40	2,56	0,60	0,14	94470,78	8752924389,00	0,40	0,29	2,62	0,33	0,13	<15	15-45	<15	<15	45-75
Yurak-Samoyeds	6,88	32,91	0,31	-9,24	266,17	0,15	0,28	36216,25	322254754,10	0,62	0,05	0,33	0,57	0,27	15-45	<15	15-45	<15	<15
Yusufzai	1168,22	1416,94	8,90	8,87	109,32	0,28	0,32	59988,10	3516183058,00	0,39	0,07	0,99	0,33	0,25	<15	<15	15-45	<15	45-75

APÉNDICE TABLA 2  
Base de datos de los artículos recopilados

Algoritmos	Análisis espacial	Análisis textos	Reconocimiento de patrones	Sistemas socioecológicos
<i>Logistic regression</i>	VAUGHN y CRAWFORD, 2009; YAWORSKY <i>et al.</i> , 2020; LEATHWICK, 2000		MONNA <i>et al.</i> , 2020	VAHDATI <i>et al.</i> , 2019; ALBERTI, 2014
<i>Deep learning (neural networks, Artificial neural networks, Convolutional neural networks)</i>	BERGANZO-BESGA <i>et al.</i> , 2021; ALTAWHEEL <i>et al.</i> , 2022; RICHARDS-RISSETTO <i>et al.</i> , 2021; DAVIS <i>et al.</i> , 2021; HORN <i>et al.</i> , 2022; REICH <i>et al.</i> , 2021; GUYOT <i>et al.</i> , 2021; VERSCHOOF-VAN DER VAART <i>et al.</i> , 2020; ALBRECHT <i>et al.</i> , 2019; TRIER <i>et al.</i> , 2019; DUCKE, 2003; LAMBERS <i>et al.</i> , 2019; CHEN <i>et al.</i> , 2021; BONHAGE <i>et al.</i> , 2021; CASPARI y CRESPO, 2019; SOROUSH <i>et al.</i> , 2020; STOTT <i>et al.</i> , 2019; XU <i>et al.</i> , 2019; CHARACTER <i>et al.</i> , 2021; BUNDZEL <i>et al.</i> , 2020	RAMYA <i>et al.</i> , 2019; SANDERS, 2018; ASSAEL <i>et al.</i> , 2022; BRANDSEN <i>et al.</i> , 2020	COLMENERO-FERNÁNDEZ y FEITO, 2021; HLAD <i>et al.</i> , 2021; TSIGKAS <i>et al.</i> , 2020; GROVE y BLINKHORN, 2020; OSTERTAG y BEURTON-AIMAR, 2020; PAGNIN <i>et al.</i> , 2020; MA <i>et al.</i> , 2021; BELL y CROSON, 1998; OONK y SPIJKER, 2015; ARNAY <i>et al.</i> , 2021; CIFUENTES-ALCOBENDAS y DOMÍNGUEZ-RODRIGO, 2019; NAVARRO <i>et al.</i> , 2021; COURTENAY <i>et al.</i> , 2019; MONNA <i>et al.</i> , 2020; BYEON <i>et al.</i> , 2019; CINTAS <i>et al.</i> , 2020; LAMBERS <i>et al.</i> , 2019; WÄRMLÄNDER <i>et al.</i> , 2019; HEIN <i>et al.</i> , 2018; AGAPIOU <i>et al.</i> , 2021; RESLER <i>et al.</i> , 2021; PAWLOWICZ <i>et al.</i> , 2021; BICKLER, 2018; GUALANDI <i>et al.</i> , 2021; PRASOMPAN y JUNG, 2017; HUFFER y GRAHAM, 2018; NASH y PREWITT, 2016; CHETOUANI <i>et al.</i> , 2020; GANDHI y PONNAVAIKKO, 2020	VOS <i>et al.</i> , 2021; GINAU <i>et al.</i> , 2020; BURRY <i>et al.</i> , 2018

<i>Decision tree</i>			JEPPSON <i>et al.</i> , 2019; COURTENAY <i>et al.</i> , 2019	
<i>Regression tree</i>				VAHDATI <i>et al.</i> , 2019
<i>Classification and Regression tree (CART)</i>			HÖRR <i>et al.</i> , 2014	
<i>Support vector machine (SVM)</i>	THABENG <i>et al.</i> , 2019	HALIASSOS <i>et al.</i> , 2020	OONK y SPIJKER <i>et al.</i> , 2015; COURTENAY <i>et al.</i> , 2019; MONNA <i>et al.</i> , 2020; BYEON <i>et al.</i> , 2019; DIA <i>et al.</i> , 2021	AHEDO <i>et al.</i> , 2021; AHEDO <i>et al.</i> , 2019
<i>K-nearest neighbour</i>			OONK y SPIJKER <i>et al.</i> , 2015; COURTENAY <i>et al.</i> , 2019; MONNA <i>et al.</i> , 2020; SHARAFI <i>et al.</i> , 2016	VAHDATI <i>et al.</i> , 2019
<i>Random forest</i>	FRIGGENS <i>et al.</i> , 2021; ZHENG <i>et al.</i> , 2020; CASTIELLO y TONINI, 2019; GUYOT <i>et al.</i> , 2018; THABENG <i>et al.</i> , 2019		CHOWDHURY <i>et al.</i> , 2021; ORENGO y GARCIA-MOLSOSA, 2019; ABITBOL <i>et al.</i> , 2021; PARGETER <i>et al.</i> , 2019; USHIZIMA <i>et al.</i> , 2020; MESANZAMORAZA <i>et al.</i> , 2020; HANSEN y NEBEL, 2020; COURTENAY <i>et al.</i> , 2019; MONNA <i>et al.</i> , 2020; NAVEGA <i>et al.</i> , 2015	AHEDO <i>et al.</i> , 2021; DAVIS y DOUGLASS, 2021; VAHDATI <i>et al.</i> , 2019
<i>Bayesian networks</i>			DOMÍNGUEZ-RODRIGO y BAQUEDANO, 2018; COURTENAY <i>et al.</i> , 2019; MACLEOD, 2018; JEPPSON <i>et al.</i> , 2019; MONNA <i>et al.</i> , 2020	HYAFIL y BAUMARD, 2022; BUCHANAN <i>et al.</i> , 2022; BARCELÓ <i>et al.</i> , 2015
<i>Active learning</i>			ZHU <i>et al.</i> , 2019	
<i>Principal component analysis</i>			SHARAFI <i>et al.</i> , 2016	AHEDO <i>et al.</i> , 2021; MA <i>et al.</i> , 2022; BROZOU <i>et al.</i> , 2022
<i>Autoencoders</i>			SHARAFI <i>et al.</i> , 2016	

<i>Discriminant Analysis</i>			ANZANO <i>et al.</i> , 2015; DOMÍNGUEZ-RODRIGO y BAQUEDANO, 2018; COURTENAY <i>et al.</i> , 2019; MONNA <i>et al.</i> , 2020	
<i>K-means</i>			SHARAFI <i>et al.</i> , 2016	
<i>Self-organising map</i>			KOGOU <i>et al.</i> , 2020	
<i>Gaussian Mixture Models</i>			SHARAFI <i>et al.</i> , 2016	
<i>No especificado</i>		Fabricius Team		

Fuente: Elaboración propia.