



## ARTÍCULO ESPECIAL

### Viejos ladrillos, nuevas y exitosas arquitecturas ¿Cómo y por qué Deep Learning llegó al trono en el área Machine Learning? ¿Qué oportunidades, dilemas y riesgos nos presenta?

*Old Bricks, New and Successful Architectures: How and Why Deep Learning Came to Reign in the Field of Machine Learning? What Opportunities, Dilemmas, and Risks Does It Present to Us?*

**Cristobal ARRIETA** 

**a** Facultad de Ingeniería, Universidad Alberto Hurtado, Chile  
 Millennium Institute for Intelligent Healthcare Engineering, iHEALTH, Chile

#### INFORMACIÓN DEL ARTÍCULO

##### **Historia del Artículo:**

Recibido: 01 01 2025  
 Aceptado: 01 04 2025

##### **Palabras claves:**

Machine Learning. Deep Learning. Aprendizaje. Algoritmos. Dilemas. Riesgos.

##### **Key words:**

Administration.  
 Resources. Decision-Making. Management.

#### RESUMEN

Aquí se presenta una revisión de la disrupción que generó Deep Learning en el desarrollo del área de Machine Learning. Primero, definiendo los dos problemas generales que se buscan resolver con machine learning, los modelos discriminativos y modelos generativos, y cómo la modelación estadística, la optimización y, el nuevo ingrediente, el uso de datos, logran generar algoritmos que “aprenden automáticamente”. Para ello, se revisan especialmente los algoritmos de machine learning vigentes al momento en que se produce la irrupción de Deep Learning en la escena y cómo estos últimos renuevan una antigua tecnología, las redes neurales artificiales. Luego, se describen los antecedentes técnicos y tecnológicos que habilitaron el desarrollo de Deep Learning, particularmente, el avance de Big Data, el algoritmo de Backpropagation, el desarrollo de la GPU y las plataformas de desarrollo de código abierto (tensorflow, keras, pythorch), permitiendo también comprender la infraestructura necesaria para su desarrollo. Seguidamente, se revisan las arquitecturas más exitosas, como U-NET, las redes generativas adversariales (GANs), Transformers, Stable Diffusion, entre otras, destacando los impactantes avances en procesamiento de datos y procesamiento de lenguaje natural aplicado al ámbito médico. Finalmente, se discuten los dilemas y desafíos pendientes respecto a la explicabilidad, interpretabilidad y sesgos de los resultados de los llamados modelos opacos (no transparentes), al igual que los riesgos de vulnerabilidad que se han reportado, permitiendo incluso extraer los datos originales a partir de los modelos, jaqueando los enfoques tradicionales de anonimización y de-identificación de los datos.

#### ABSTRACT

Here is a review of the disruption that Deep Learning generated in the development of the Machine Learning area. First, defining the two general problems that are sought to be solved with machine learning, discriminative models and generative models, and how statistical modeling, optimization and, the new ingredient, the use of data, manage to generate algorithms that “learn automatically”. To this end, the machine learning algorithms in force at the time when Deep Learning burst onto the scene and how the latter renew an old technology, artificial neural networks, are especially reviewed. Then, the technical and technological background that enabled the development of Deep Learning is described, particularly, the advancement of Big Data, the Backpropagation algorithm, the development of the GPU and open source development platforms (tensorflow, keras, pythorch), also allowing us to understand the infrastructure necessary for its development. Next, the most successful architectures are reviewed, such as U-NET, generative adversarial networks (GANs), Transformers, Stable Diffusion, among others, highlighting the impressive advances in data processing and natural language processing applied to the medical field. Finally, the dilemmas and pending challenges regarding the explainability, interpretability and biases of the results of the so-called opaque (non-transparent) models are discussed, as well as the vulnerability risks that have been reported, even allowing the extraction of the original data from the models, challenging traditional approaches of anonymization and de-identification of data.

#### Autor para correspondencia

Correo electrónico:

<https://doi.org/10.63706/jsibemir.v1i1.15>

e-ISSN: 3087-2367/© 2025 JS

Este es un artículo Open Access bajo licencia BY-NC-ND  
 (<http://creativecommons.org/licenses/by-nc-nd/4.0/>)

## INTRODUCCIÓN: MACHINE LEARNING ¿QUÉ ES Y POR QUÉ?

Machine Learning (o aprendizaje de máquinas) es un área de la Inteligencia Artificial (IA) cuyo objetivo es desarrollar métodos computacionales y algoritmos que permiten a las máquinas aprender y tomar decisiones, autónomamente, a partir de un conjunto de datos; se diferencian de los sistemas expertos, desarrollados en los años 60 y 70, que producían conclusiones a partir de evaluar un conjunto de reglas o condiciones, los métodos basados en machine learning son capaces de extraer estas reglas, patrones o relaciones a partir de datos (Buchanan, 2005; Harmon, 2022; Ravuri et al. 2018). Con datos nos referimos a un conjunto extenso de observaciones o muestras que describen múltiples variables. Pero, además, los modelos de machine learning son capaces de optimizar automáticamente sus parámetros para mejorar su rendimiento según algún criterio de evaluación de la performance en una tarea específica (Yang & Shami, 2020). Así, en la medida que tenemos más y mejores datos, el modelo podría mejorar.

En suma, el área de Machine Learning recibe contribuciones de la Estadística, la Matemática, la Optimización y las Ciencias de la Computación. Su desarrollo data de la década de 1950, en la cual Arthur Samuel crea el primer sistema de este tipo, capaz de jugar damas y aprender de la experiencia (Kononenko, 2001; Fradkov, 2020). Sin embargo, en las décadas de 1980 y 1990 se desarrollaron los modelos, algoritmos y métodos computacionales fundacionales, cuyas directrices seguimos hasta hoy, como los árboles de decisión, las redes neuronales o las máquinas de soporte vectorial (SVM) (Kubát, 2017).

## ¿QUÉ ES DEEP LEARNING Y CÓMO SE APRENDE DE FORMA “PROFUNDA”?

Deep Learning es un conjunto de métodos proveniente de Machine Learning, cuyos notables resultados en múltiples campos de aplicación han acelerado la adopción masiva de la Inteligencia Artificial. Estos métodos están basados en el uso de varias capas de grandes redes neuronales que logran modelar patrones complejos presentes en los datos. Los métodos de Deep Learning logran establecer relaciones entre variables de entrada y variables de salida, a partir de un gran número de capas intermedias interconectadas, normalmente llamadas capas ocultas. De ahí que la denominación de “Deep” o profunda viene dada por estas múltiples capas intermedias que le brindan profundidad a la red.

Los métodos de Deep learning transformaron el panorama de la IA, abarcando rápidamente tareas como el reconocimiento de voz, clasificación de imágenes, procesamiento de lenguaje natural y sistemas autónomos, entre otros (LeCun et al., 2015; Wang, 2016; Deng, 2016; Xu, 2023). Estas tareas, a su vez, han tenido cabida en ámbitos como las finanzas, el entretenimiento, el transporte, la educación y la salud.

Si bien el concepto de las redes neuronales existía desde la década de 1950, los factores habilitantes de su irrupción en las primeras dos décadas del 2000 fue la aparición altas potencias de cómputo paralelo usando graphics processing units (GPUs), la disponibilidad de grandes volúmenes de datos almacenados en diversas plataformas digitales, la capacidad de manejar esos datos a través de Big Data (Jordan & Mitchell, 2015), y de forma más técnica, la implementación eficiente del algoritmo Backpropagation, que permite que el entrenamiento de las redes neuronales se acerque convenientemente a la solución óptima (Kubát, 2017). Esto, sumado a las nuevas plataformas que permitieron masificar el uso de estos métodos, inició a partir de 2022 una nueva era en el desarrollo de la IA (Huh et al., 2023; Russo, 2023).

## ¿QUÉ PROBLEMAS SE RESUELVEN USANDO MACHINE LEARNING?

Principalmente, los métodos basados en Machine Learning resuelven dos tipos de problemas, los cuales se solucionan con dos tipos de modelos:

- **Modelos Discriminativos.** Su objetivo es distinguir o reconocer diferentes categorías o clases presentes en los datos de entrada. Por esta razón, son útiles para problemas de detección y de clasificación, donde la salida o resultado del modelo es el tipo o clase de dato de entrada. Son ejemplos, la clasificación de imágenes o la detección de fraude (Kubát, 2017).
- **Modelos Generativos.** Su objetivo es generar nuevos datos que se comporten estadísticamente en forma similar a los datos de entrenamiento, siendo necesario entender y describir la distribución que los produjo. Así, el resultado de estos modelos es un nuevo dato u observación idealmente indistinguible de los datos originales. Esto es extremadamente útil en aplicaciones de generación de texto o de síntesis de imágenes o de voz (Jordan & Mitchell, 2015).

Considerando estos dos tipos modelos, ambos problemas requieren herramientas conceptualmente similares para producir el aprendizaje automático, traducido en la optimización de estos modelos. En ambos casos el uso de modelación estadística es lo que permitirá entender, describir y predecir el comportamiento de los datos (Kubát, 2017). Luego, cada algoritmo, típicamente mediante un proceso iterativo, va mejorando su poder de predicción utilizando técnicas de optimización que minimicen el error y mejoren la performance evaluada con alguna métrica. Esto permite hacer un fine-tuning de los parámetros que definirán cada modelo usando técnicas como descenso de gradiente, optimización convexa o algoritmos evolutivos (Jordan & Mitchell, 2015).

Todo esto, sumado al desarrollo de Big Data para gestionar un gran volumen de datos, además de garantizar que estos datos sean de buena calidad y estén disponibles, permitió el desarrollo de modelos complejos y de alto desempeño (Fradkov, 2020).

## MACHINE LEARNING ANTES DE DEEP LEARNING

Previamente a introducir Deep Learning, los métodos de Machine Learning tuvieron un gran desarrollo, tanto en el tipo de datos como en las aplicaciones. Desde algoritmos de clusters (Jain et al., 1999), k-Nearest Neighbor (k-NN) (Cover & Hart, 1967), regresión lineal (Seber & Lee, 2012) o logística (Hosmer et al., 2013), naive Bayes (Zhang, 2004), hasta los clasificadores de que lideraban la escena antes de la llegada de Deep learning: decision trees (DT) (Breiman et al., 1984), support vector machine (SVM) (Cortes & Vapnik, 1995), random forest (RF) (Breiman, 2001) y extreme gradient boosting (XGBoost) (Chen & Guestrin, 2016).

Pero, pregunta clave ¿cómo los distintos algoritmos de Machine Learning previos a Deep Learning lograron funcionar exitosamente para distintos tipos de datos, por ejemplo, imágenes, audio o series de tiempo? La respuesta se debe al uso de espacios de características (en inglés, features), los cuales debían ser previamente calculados sobre los datos de entrada (Hatami et al., 2017; Pathak et al., 2018; Dhaville & Dinakarrao, 2020; Shin et al., 2011; Flamary et al., 2015). Luego, sólo las características relevantes deben ser conservadas, y podía ser realizado manualmente por una persona con gran experiencia o utilizando algoritmos automáticos de ranking de características (Cao et al., 2018; Hatami et al., 2017). Luego, las características seleccionadas se concatenan, construyendo un vector “descriptor” de cada dato de entrenamiento. Así, el algoritmo de Machine Learning tradicional opera sobre los descriptores, logrando la independen-

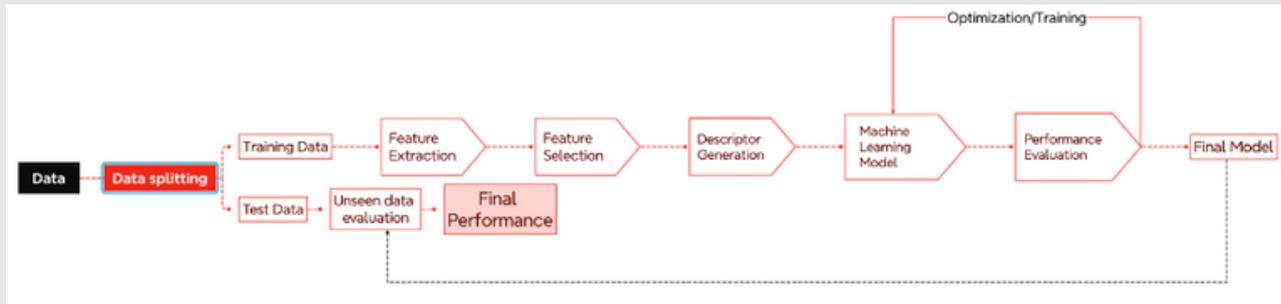


Figura 1

Resumen del proceso de entrenamiento de un modelo de Machine Learning. Los datos divididos en datos pruebas y entrenamiento. Se extraen las características, se seleccionan las relevantes y se construye el descriptor. Posteriormente se entrena el modelo hasta conseguir el modelo final, el cual se prueba con datos que no han sido vistos en el set de entrenamiento.

cia de la naturaleza de los datos de entrada (Fig. 1); aunque, su resultado final depende fuertemente de este paso crucial (Dhavlle & Dinakarao, 2020; Pathak et al., 2018). En contraste, los métodos actuales de Deep Learning no requieren este paso, pues estiman autónomamente, los descriptores utilizando un codificador, proceso que detallaremos más adelante, y que genera un espacio de dimensiones más pequeñas que captura las características relevantes de los datos de entrada (Ker et al., 2018, Guo et al., 2016, Zhang & Zhang, 2019, Ye et al., 2018).

Algunos algoritmos que son representativos de machine learning tradicional son k-nearest neighbors (kNN o k-vecinos más cercanos), decision trees (DT, árboles de decisión), logistic regression (LR), support vector machine (SVM) y métodos que ensamblan varias instancias de estos algoritmos, como random forest (RF) y extreme gradient boosting (XGBoost).

kNN es un clasificador que busca los k datos más parecidos al dato nuevo que se busca clasificar, y le asigna la clase que tenga más votos dentro de esos k. Su gran ventaja es la simpleza, sin embargo, para bases de datos de grandes se torna no factible, pues hallar los k datos más parecidos implica calcular alguna métrica de distancia del dato a clasificar a toda la base de datos, hecho que implica un cómputo muy intensivo (Cover & Hart, 1967).

DT es un algoritmo de clasificación que divide los datos de entrenamiento en subconjuntos sobre la base de los valores del espacio de características, y crea modelos de decisión de tipo árbol, que optimiza las condiciones que garantizan la separabilidad entre las clases. Para esto, se van “podando” aquellas características no relevantes y conservando únicamente los umbrales en las características que permiten diferenciar una clase de otra (Batra & Agrawal, 2018; Sani et al., 2018). Una gran ventaja es que, al término del algoritmo, el resultado es transparente e interpretable al analizar las ramas del árbol de decisión (Thomas et al., 2019). La gran desventaja es que esas separaciones sobre-ajustan el árbol a los datos de entrenamiento, produciendo soluciones poco generalizables y muy sensibles a pequeños cambios de los datos de entrada (Phalak et al., 2014).

LR es un modelo estadístico de clasificación que estima la probabilidad que un dato nuevo pertenezca a cada clase observada en el conjunto de datos de entrenamiento, procurando además que el resultado dependa de la menor cantidad de características relevantes posibles (Courvoisier et al., 2011). Su resultado es altamente interpretable, aunque no funciona bien cuando la separabilidad de clases implica relaciones muy complejas, por ejemplo, no-lineales (Wilson & Lorenz, 2015).

SVM es un exitoso algoritmo de clasificación que trata de estable-

cer planos que corten el espacio para separar una clase de otra. Para esto, en lugar de mirar todos los datos de entrenamiento busca analizar aquellos que están en la frontera entre las clases, los vectores de soporte, y optimiza en esa región con un criterio matemáticamente robusto (Cortes & Vapnik, 1995). Es un algoritmo que funciona en forma excelente cuando puede establecerse una separación lineal entre las clases, de lo contrario, se deben aplicar transformaciones a los datos (se aplica un kernel), para transformar estos espacios en linealmente separables (por ejemplo, transformaciones radiales, gaussianas, etc.) (Ben-Hur et al., 2008). Su resultado no es tan interpretable como los árboles de decisión, si bien se puede forzar un análisis de los vectores de soporte y de los planos hallados para hacer hipótesis de interpretación de los resultados (Ben-Hur et al., 2008).

Los dos últimos casos, RF y XGBoost son métodos provenientes de la filosofía que, si bien un clasificador simple no es capaz de resolver por sí sólo un problema de clasificación complejo, un conjunto o ensamble de ellos son capaces de mejorar la performance del sistema.

En el caso de RF, el algoritmo encuentra múltiples árboles de decisión, que son parte de este “bosque”, cada uno entrenado en diferentes subconjuntos de los datos de entrenamiento (con reposición) y sobre conjuntos aleatorios de características, optimizándose en forma independiente cada árbol, pero generando una alta diversidad de representación del problema (Breiman, 2001). Al llegar un dato nuevo, estos árboles corren en paralelo y el veredicto es por mayoría de votos, o la moda estadística de las clases que reportan cada árbol del bosque (Talekar & Agrawal, 2020).

Finalmente, XGBoost también opera con árboles de decisión, pero a diferencia de RF, los árboles se ensamblan de forma secuencial, y cada árbol va corrigiendo el error residual acumulado de los árboles anteriores (Chen & Guestrin, 2016). El proceso de optimización con el cual se minimiza el error final es bastante robusto y eficiente (Chen & Guestrin, 2016; Zhang et al., 2022).

En conclusión, una gran limitación de los algoritmos de Machine Learning tradicionales reside en su habilidad de manejar datos de alto grado de complejidad y dimensionalidad (Kubát, 2017), por lo que es necesario seleccionar previamente un espacio de características adecuado, manualmente o en forma asistida.

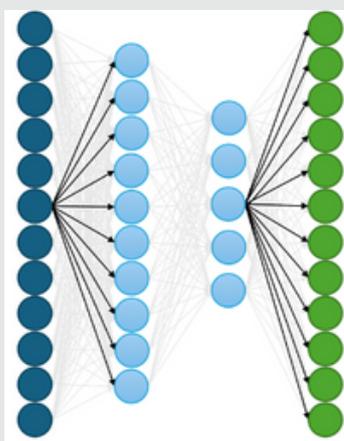
## EL ASCENSO DE DEEP LEARNING

Los algoritmos utilizados en Deep Learning surgen ante la necesidad de resolver el problema de independizarse de la selec-

ción del espacio de características, sin embargo, durante su desarrollo se descubrieron ventajas inesperadas, como su rendimiento creciente, aparentemente sin barreras, en la medida de disponer de más datos y modelos cada vez más complejos. En diferentes variantes de esta tecnología se basan muchos de los sistemas más exitosos que utilizan IA hoy en día, desde sistemas de recomendación, análisis de voz, análisis de imágenes, hasta chatGPT (OpenAI) o Gemini (Google).

El “ladrillo base” de Deep Learning se llama Artificial Neural Networks (ANN); estas redes fueron creadas en la década de 1950 por Frank Rosenblatt, bajo el nombre de Perceptrón, inspiradas en el comportamiento del cerebro humano (McClelland, 2020). Consisten en una serie de neuronas o funciones aditivas que se interconectan entre sí, cada una con un peso a determinar y una función de activación que permite a la neurona “apagarse o encenderse” conforme a la señal que recibe. Si bien mostraron inicialmente un comportamiento prometedor, en 1969 se demostró que el perceptrón no era capaz de representar algunas funciones lógicas básicas (particularmente el “or exclusivo”, XOR), quedando en evidencia una gran limitación (Minsky & Papert, 1969).

La respuesta a esta cuestión consistió en ir más profundo, o “Deep”, introduciendo el multi-layer perceptron, también conocido como fully connected neural networks (Fig. 2). La filosofía, detrás, fue agregar a la arquitectura del perceptrón capas intermedias u ocultas, totalmente conectadas entre sí, aumentando la complejidad de las funciones que la red era capaz de representar (McClelland, 2020). Todo esto implicó un aumento de la cantidad de pesos o parámetros de la red que debían ser estimados, y fue cuando, en la década de 1980 se introdujo el algoritmo de Backpropagation. Este algoritmo de optimización permite entrenar la red neuronal ajustando los pesos o parámetros a partir de los datos de entrenamiento, minimizando el error de las estimaciones de la red y calculando de forma eficiente el gradiente de cada capa, operador matemático esencial para encontrar una solución óptima (Schmidhuber, 2014). De forma importante, en el año 1989 se probó matemáticamente que estas redes son aproximadores universales, es decir, que son capaces de representar cualquier función matemática, por compleja que esta sea (Hornik et al., 1989). Sin embargo, que esta condición se cumpla no significa que esta red ideal pueda ser aprendida a partir de los datos, por lo que en el área de Deep Learning, basado en este marco conceptual, ha proliferado una forma de trabajar basada en la heurística y el ensayo y error, si bien aún se siguen buscando “las garantías matemáticas” de lo que son capaces de resolver o la explicación de su buen desempeño.



**Figura 2**

Ejemplo de perceptrón multi-capas o fully connected artificial neural network con dos capas ocultas.

Por supuesto, una importante pregunta es que, si bien este desarrollo estaba avanzado ya para la década de 1980, ¿por qué recién ahora se ha masificado su uso? Y la respuesta es simple, pues se necesitaba una gran capacidad computacional para tales aplicaciones. Por esta razón, se desarrollaron “algoritmos tradicionales” de Machine Learning. Sin embargo, a partir del siglo XXI hubo tres elementos que cambiaron las reglas del juego.

En primer lugar, el desarrollo de las Graphics Processing Units (GPU) liderado por la compañía NVIDIA®, permite realizar tareas computacionales en forma paralela, reduciendo el tiempo requerido para entrenar modelos grandes desde semanas a horas (Geirhos et al., 2020). En segundo lugar, el crecimiento de la cantidad de datos disponibles y el desarrollo del área de Big Data, habilitó los altos rendimientos y una sorprendente capacidad de generalizar por parte de los modelos de Deep Learning, cuando son entrenados con cantidades masivas de datos (LeCun, Bengio, & Hinton, 2015). En tercer lugar, el desarrollo de plataformas de código abierto permitió acelerar el desarrollo y compartir y difundir las técnicas muy rápidamente; las plataformas más utilizadas son TensorFlow, desarrollada por Google, incluyendo Keras, una API que corre sobre TensorFlow que facilita aún más el desarrollo (Minar & Naher, 2018), y PyTorch desarrollado por exFacebook, actualmente Meta (Lemley, Bazrafkan, & Corcoran, 2017).

En base a lo vertido precedentemente, hubo una importante pérdida con respecto a los algoritmos tradicionales de Machine Learning, pues Deep Learning genera modelos llamados “cajas negras”, donde la interpretabilidad y explicabilidad de sus resultados son extremadamente difíciles de seguir a partir del análisis de los parámetros de la red (Zhang & Zhu, 2018). Debido a esto, la adopción de Deep Learning para procesos de toma de decisiones y la confianza en los resultados se ha cuestionado y ha frenado su adopción, especialmente en áreas como la salud (El Zini & Awad, 2022).

## DE LOS LADRILLOS A LA ARQUITECTURA

Considerando todos los insumos mencionados previamente, la creatividad de los desarrolladores y desarrolladoras, investigadores e investigadoras, ha posibilitado desarrollar de diversas formas las estrategias de Deep Learning, debido a la manera de combinar estos perceptrones, generando diferentes arquitecturas de las redes, mejorando las estrategias de entrenamiento de las redes, hasta incluso cómo interpretar los resultados.

A modo de ejemplo, seguidamente se presentarán las cuatro arquitecturas más exitosas en diferentes ámbitos de aplicación:

1) CNN (Convolutional Neural Networks) produjeron una revolución en el área de procesamiento de imágenes y visión por computadora. En lugar de usar redes cuyas capas ocultas estuviesen totalmente conectadas, las capas convolucionales permitían aprender características espaciales en forma jerárquica, enfatizando en la relación de cada elemento con sus vecinos y no con toda la imagen, como habitualmente ocurre en una imagen donde la información relevante es local (LeCun, Bengio, & Hinton, 2015). Recientemente, las CNN también han probado ser aproximadores universales (Zhou, 2020). Un exitoso ejemplo de esta arquitectura es U-NET, que generó una revolución en el área de segmentación de imágenes y fue originalmente desarrollada para imágenes biomédicas (Ronneberger et al., 2015).

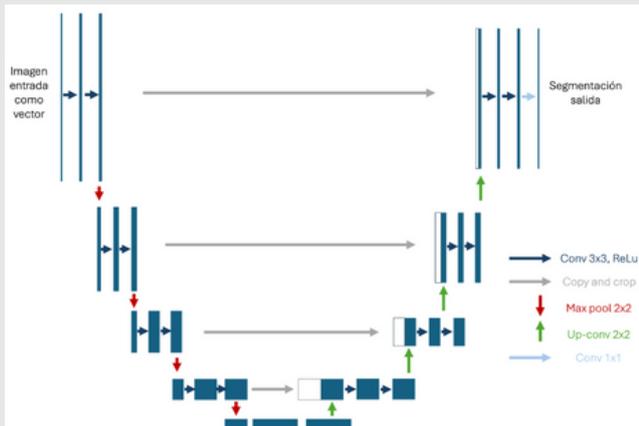


Figura 3

Arquitectura U-Net, donde en cada nivel la dimensión de los datos va cambiando debido al uso de las capas convolucionales, manteniendo la información más relevante de forma jerárquica.

2) RNN (Recurrent Neural Networks) y su variante, LSTM (Long-Short Term Memory), se desarrollaron especialmente para el análisis de datos secuenciales, que consideran conexiones que forman ciclos en la red. Han mostrado significativos avances en reconocimiento de voz, y hasta el surgimiento de los modelos Attention y Transformers (en este caso, basamento del chat GPT), dominaban el procesamiento de lenguaje natural (Schmidhuber, 2014).

3) GAN (Generative Adversarial Networks) generaron una nueva revolución en el área de Deep Learning, y el término "IA Generativa" está influenciado por su éxito. Realmente, están compuestas por dos redes, una red generativa, que crea nuevos datos a partir del conjunto de entrenamiento y que intenta engañar a la otra red, una red discriminativa que intenta detectar si estas imágenes son "verdaderas", pertenecen a los datos, o son "falsas", es decir, son creadas por la red generativa (Fig. 4). La optimización conjunta de las dos redes permite que la red generativa cree imágenes cada vez más realistas merced a que la red discriminativa se va haciendo cada vez más experta en detectar las imágenes creadas. Este tipo de redes se ha aplicado en transferencia de estilo y generación de imágenes sintéticas (Mittal et al., 2021).

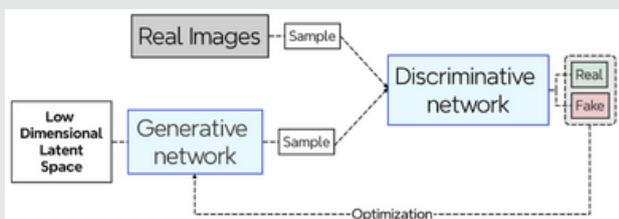


Figura 4

Esquema de Generative Adversarial Networks (GAN). El sistema se compone de dos redes con objetivos que compiten, la red generativa intenta copiar, en este caso, las imágenes reales y la red discriminativa intenta determinar si las imágenes son reales o son "falsas", es decir, generadas por la otra red.

En el proceso de optimización conjunta, la red generativa crea imágenes cada vez más realista y la red discriminativa detecta cada vez más detalle.

4) Los modelos Attention, corresponden al estado del arte en procesamiento de lenguaje natural. Son redes neuronales que permiten que el modelo se enfoque en partes específicas de una secuencia, ponderando la relevancia de las características de tal secuencia. Especialmente, los modelos de self-attention calculan el nivel de relación o similitud de cada elemento de la

secuencia con respecto al resto de los elementos. Los Transformers, tecnología de basamento del Chat GPT o Gemini, se fundamentan en la concatenación de varios bloques de self-attention combinados con otras redes neuronales de procesos anteriores y posteriores a los bloques de atención; han generado los modelos más robustos, actualmente, para generación de texto (Vaswani et al., 2017).

5) Los modelos basados en Stable Diffusion son modelos generativos aplicados a la creación de imágenes que utilizan procesos de difusión para generar nuevos datos desde la distribución de los datos de entrenamiento (Xu et al., 2023). El algoritmo tiene dos partes: (1) En múltiples pasos, degrada gradualmente las imágenes de entrenamiento agregando ruido con características conocidas, como ruido gaussiano; (2) Entrena una red neuronal de reducción de ruido en los distintos pasos generados, de menos ruido a más ruido, prediciendo el ruido agregado en cada paso (Ho et al., 2020). Estos modelos pueden ser combinados con modelos de lenguaje para generar imágenes o videos a partir de texto (Dhariwal & Nichol, 2024).

Todos estos modelos tuvieron y seguirán teniendo múltiples aplicaciones en el área de medicina, generando desarrollos acelerados, por ejemplo, durante la Pandemia CoVid19, aún con reparos e incertidumbre con respecto a su adopción, muchas veces totalmente justificado. En la sección siguiente se explorarán, brevemente, algunas de estas aplicaciones.

## APLICACIONES DE DEEP LEARNING EN MEDICINA

Deep Learning produjo una revolución en la segmentación de imágenes médicas, especialmente, con distintas variaciones de U-Net. La segmentación o delimitación de estructuras de interés dentro de una imagen es una tarea transversal a casi cualquier proceso de medicina. Por ejemplo, una modificación de U-Net fue utilizada para segmentar tumores cerebrales sobre imágenes de resonancia magnética, permitiendo no sólo detectar, sino también, delinear un tumor detalladamente y en pocos segundos, luego de un proceso de entrenamiento más intensivo (Ali et al., 2022). Otra aplicación es la segmentación de vasos en la retina, permitiendo realizar un diagnóstico más robusto de enfermedades retinales (Wang et al, 2023). Otras aplicaciones de U-Net incluyen la detección y conteo de células para análisis de morfometría (Falk et al., 2018), o la segmentación del disco óptico para la detección de glaucoma (Civit-Masot et al., 2019).

En muchas publicaciones, los autores entregan sus códigos completos, de forma que se puedan reproducir y difundir sus desarrollos. Sin embargo, uno de los mayores desafíos para implementar estas soluciones es la transferencia a los propios datos, originalmente el problema se conoció como Transfer Learning. Sin embargo, existen algunas aplicaciones como RadImageNet, un framework de Deep Learning, entrenado especialmente sobre imágenes radiológicas, el cual promete facilitar ese proceso de transferencia de los desarrollos a los propios datos (Mei et al., 2022).

Por otra parte, los modelos basados en Transformers están teniendo cada vez más aplicabilidad. Por ejemplo, para la detección temprana de lesiones renales agudas o fallas cardíacas, pues, a diferencia de otras propuestas basadas puramente en modelos de lenguajes, este sistema propone herramientas analíticas visuales, para inspeccionar, comparar y explicar el resultado entregado por modelos de Transformers pre-entrenados en la tarea de detección de estas condiciones de salud (Antweiler et al., 2023).

Sin embargo, la habilidad de procesar texto de los modelos basados en Transformers, particularmente, LLM (Large Language Models), abrieron una oportunidad para solucionar el problema

de extraer, analizar y procesar la información proveniente de los datos clínicos. Estos datos son muy desafiantes, muchas veces por falta de una aplicación consistente de un standard, porque diversos conceptos pueden apuntar a lo mismo, e incluso, por la dificultad para una máquina de discriminar entidades como partes del cuerpo, enfermedades, nombres personales, descripciones de estilo de vida, información psico-socio-cultural complementaria pero relevante, entre otras. Hubo un gran avance en modelos que logren extraer estos conceptos, y es claro que existe un salto en la performance que promete modificar la práctica clínica en el futuro cercano, tanto en inglés como en español, integrando a las máquinas en tareas rutinarias (Yang et al., 2020; Dunstan et al. 2024; Báez et al., 2020).

## LA VIGENCIA DE LO TRADICIONAL, APLICACIONES ACTUALES DE MACHINE LEARNING TRADICIONAL EN MEDICINA

Es necesario mencionar que los algoritmos tradicionales de Machine Learning siguen mostrando resultados interesantes en varios ámbitos. Uno que merece destacarse es Radiomics, que devela información que no es evidente a partir de los registros clínicos, permitiendo mejorar el diagnóstico, la prognosis y la predicción de respuesta a un tratamiento (Mayerhoefer et al., 2020); al efecto, se utilizan datos radiológicos, como imágenes médicas, pero pueden ser complementados con datos cualquier naturaleza. Normalmente implica pre-procesar imágenes médicas, segmentar estructuras de interés, extraer características y crear modelos (Rizzo et al., 2018). La explicabilidad y transparencia de los modelos tradicionales de Machine Learning presentan una ventaja crucial en este ámbito, no sólo para corroborar respuestas coherentes, sino que además permiten generar nuevo conocimiento y hallazgos de las condiciones estudiadas. Uno de los ámbitos de mayor interés de aplicación es la oncología, sin embargo, uno de los grandes desafíos que enfrenta la técnica en general, es la estandarización de la adquisición de los datos y reproducción de los procesos en distintas instituciones, usando equipos de diferentes fabricantes y con los sesgos locales que presentan los datos de las poblaciones incluidas en cada estudio (Kumar et al., 2012).

Un ejemplo de aplicación de Radiomics usando random forest, lo utiliza para predecir la falla local en cáncer cervical sobre imágenes de resonancia magnética (Upadhaya et al., 2019). También, en una línea similar usando Radiomics y resonancia magnética, pero combinado con SVM (Support Vector Machine), se tiene como ejemplo la predicción de la agresividad de cáncer de próstata (Cuocolo et al. 2019).

Vale destacar que también Deep Learning ha sido introducido en el ámbito de Radiomics, por ejemplo, abordando objetivos tan complejos como predecir mutaciones genéticas específicas a partir de imágenes de resonancia magnética usando CNN (Li et al. 2017).

## OPORTUNIDADES Y DESAFÍOS FUTUROS

Sin ánimo de abarcar todos los desafíos y oportunidades de estos modelos, considero abordar algunos puntos de discusión actual en cuanto a oportunidades y desafíos.

La democratización del acceso a herramientas de Machine Learning es un proceso que se ha acelerado muchísimo, especialmente desde Inteligencia Artificial Generativa. El proceso había comenzado con las plataformas de desarrollo abiertas y la forma de compartir los repositorios de los códigos (GitHub), pero con un salto exponencial desde el año 2022 con las plataformas que interactúan a través de prompt, como Chat GPT, se plantean nuevas formas de acceso más inclusivas y accesibles, abriendo la puerta a procesos de innovación para muchas más personas y

campos de acción (Lingo, 2023), incluyendo la Ciencia de Datos (Hassani & Silva, 2023) y el área de salud, desde el uso de la toma de decisiones hasta la comunicación con pacientes (Dave et al., 2023).

Sin embargo, esta democratización plantea múltiples desafíos evidentes, como los potenciales sesgos y limitaciones en la capacidad de razonamiento de estos modelos, una clara definición de las responsabilidades en caso de errores, así como las implicancias éticas y la conciencia del uso de estas plataformas con datos privados o sensibles como en área de la salud, en las cuales la información compartida con la plataforma queda desprotegida y podría incluso ser usada para entrenar el modelo (Rivas, 2023).

Además, la interpretabilidad y la explicabilidad son necesarias en áreas como la salud, para garantizar la confianza y transparencia de los procesos de toma de decisiones y diagnóstico. Los algoritmos tradicionales de Machine Learning, como los DT, siguen presentando esa ventaja. En el caso de Deep Learning, existen avances con técnicas como SHAP (Shaply Additive Explanations) o LIME (Local Interpretable Model-Agnostic Explanations) que son esfuerzos para intentar abrir estas cajas negras y entender las características que determinan las decisiones de estos métodos automáticos (Gulowaty & Wozniak, 2021). En áreas como la salud, no sólo el propósito es lograr procesos más eficientes, sino generar conocimiento y mejorar las capacidades humanas de acompañamiento a usuarios/as de los sistemas de salud. Esto incluye validar, entender y asegurar decisiones libres de sesgos e injusticias, balanceando el poder predictivo de estos modelos complejos con la necesidad de transparencia de los sistemas basados en Deep Learning (Moore & Bell, 2022).

En otros ámbitos, es importante comprender la relevancia del proceso Transfer Learning, donde el conocimiento desarrollado en un dominio, que genera un modelo pre-entrenado, habitualmente tendrá que ser ajustado para un nuevo dominio, por ejemplo, para los datos y protocolos que se generan en cada centro de salud. Es difícil aún que existan modelos "plug and play", que funcionen bajo cualquier condición. Este proceso, sin embargo, es delicado y debe ser realizado con una estrategia de entrenamiento adecuada (por ejemplo, reentrenar sólo las últimas capas de la red neuronal), así como un conjunto de datos adecuado, pues una mala decisión podría deteriorar la performance del modelo pre-entrenado. Este proceso será cada vez más común en la implementación de soluciones locales que usen estas técnicas, en el mejor de los casos como procesos de calibración y control de calidad (Ruder et al., 2019; Pan & Yang, 2010).

Una mención especial merece la protección de los datos, especialmente la anonimización y de-identificación de los datos. La anonimización requiere procesar los datos crudos, tal que cada individuo no pueda ser identificado. Sin embargo, este proceso debe asegurar que la información útil para el modelo de Machine Learning se conserve. Se ha reportado que altos niveles de anonimización para minimizar riesgos de privacidad pueden deteriorar la utilidad del modelo (Senavirathne & Torra, 2020), al igual que guías para evitar que esto ocurra (Goldsteen et al., 2021; Díaz & García, 2023). Los métodos de anonimización deben ser robustos para las técnicas de de-identificación, los cuales son ataques que permiten obtener información de los datos de entrenamiento a partir de los resultados de los modelos.

Finalmente, esto lleva a ver de qué forma se puede compartir la información para mejorar los modelos. En ese sentido, la introducción de Federated Learning constituye una herramienta clave, que permite entrenar modelos de Machine Learning en forma descentralizada, manteniendo la privacidad de los datos.

En este modelo existe un servidor central que tiene un modelo de Machine Learning general, y podría ser un modelo de detección de una enfermedad a nivel nacional propiedad del Ministerio de Salud correspondiente. Este servidor central puede compartir su modelo, sin los datos de origen, a dispositivos clientes, que podrían ser servicios de salud locales, como hospitales. Los hospitales pueden usar este modelo o bien mejorarlo con sus propios datos, de acuerdo a las características de las personas de sus territorios. Finalmente, el servidor central puede recibir nuevamente todos los modelos de los clientes y, combinando estas mejoras, intentar mejorar el modelo a nivel a central. Así, el sistema se basa en compartir modelos y no datos. Siempre que el modelo sea robusto a ataques de de-identificación, esta técnica es efectiva y segura para mejorar modelos importantes y mantenerlos actualizados en el tiempo y en forma colaborativa y dinámica (Yang et al., 2019; Kairouz et al., 2019).

## CONCLUSIONES

Este artículo presenta una guía básica de los elementos clave para comprender conceptos de Machine Learning. A partir del estudio de sus algoritmos tradicionales, en contraste con los algoritmos basados en Deep Learning, se presentan muy brevemente los avances, controversias, oportunidad y resolución de problemas aún en desarrollo.

Es interesante ver esta evolución como parte de un proceso de desarrollo tecnológico coherente y consistente, y adaptarse lo antes posible para las disrupciones futuras. Ciertamente, muchas de las controversias y los desafíos éticos permanecen desde el siglo XX, desde mediados de la década del '50, y otros nuevos aparecen, conforme avanzan los procesos de democratización y diversidad de usos de la inteligencia artificial.

En el área de la salud, la interpretación de los modelos y la protección de los datos sensibles son temas cruciales, en los cuales es urgente más investigación en conjunto con las personas clave que ejercen sus tareas en la práctica clínica, así como con usuarios y usuarias de los sistemas de salud. Las soluciones realmente sostenibles en el tiempo nacerán de considerar todas las perspectivas.

En este sentido, el llamado de estas palabras explicativas se centra en perder el miedo, comprender a fondo, utilizar, desarrollar, evaluar rigurosamente y compartir las experiencias para que rápidamente el uso de las máquinas beneficie a la sociedad en su conjunto.

## REFERENCIAS BIBLIOGRÁFICAS

- Buchanan, B. (2005). Can machine learning offer anything to expert systems? *Machine Learning*, 4(2), 251-254.
- Harmon, P. (2022). The Expert Systems Business: How It Grew and Died. *IEEE Annals of the History of Computing*, 44(1), 31-43.
- Ravuri, M., Kannan, A., Tso, G.J., Amatriain, X. (2018). Learning from the experts: From expert systems to machine-learned diagnosis models. *Proceedings of the 3rd Machine Learning for Healthcare Conference*, in *Proceedings of Machine Learning Research*, 85, 227-243.
- Yang L, Shami A. On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*. 2020;415:295-316.
- Kononenko, I. (2001). Machine learning for medical diagnosis: history, state of the art and perspective. *Artificial intelligence in medicine*, 23 1, 89-109.
- Fradkov, A. (2020). Early History of Machine Learning. *IFAC-PapersOnLine*, 53, 1385-1390.
- Kubát M. An Introduction to Machine Learning. 2017. p. 1-348.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521, 436-444.
- Nature, 521, 436-444.
- Wang X. Deep learning in object recognition, detection, and segmentation. *Found Trends Signal Process*. 2016;8(3-4):217-82.
- Wang, X. (2016). Deep learning in object recognition, detection, and segmentation. *Foundations and Trends in Signal Processing*, 8(3-4), 217-382.
- Deng, L. (2016). Deep learning: From speech recognition to language and multimodal processing. *APSIPA Transactions on Signal and Information Processing*, 5.
- Xu, Z. (2023). Research on Deep Learning in Natural Language Processing. *Advances in Computer and Communication*, 4(3), 196-200.
- Jordan, M., & Mitchell, T. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349, 255 - 260.
- Huh, J., Nelson, M., & Russell, C. (2023). ChatGPT, AI advertising, and advertising research and education. *Journal of Advertising*, 52(4), 477-482.
- Russo, D. (2024). Navigating the complexity of generative AI adoption in software engineering. *ACM Transactions on Software Engineering and Methodology*, 33(5), Article 135.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and Regression Trees*. CRC Press.
- Chen T, Guestrin C. XGBoost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016. p. 785-94.
- Cover, T. M., & Hart, P. E. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21-27.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression* (3rd ed.). Wiley.
- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data clustering: A review. *ACM Computing Surveys*, 31(3), 264-323.
- Seber, G. A. F., & Lee, A. J. (2012). *Linear Regression Analysis* (2nd ed.). Wiley.
- Zhang, H. (2004). The optimality of naive Bayes. In *Proceedings of the 17th International Florida Artificial Intelligence Research Society Conference* (pp. 562-567).
- Hatami, N., Gavet, Y., & Debayle, J. (2017). Classification of time-series images using deep convolutional neural networks. *Proceedings of SPIE*, 10696, 106960Y.
- Pathak, S., Cai, X., & Rajasekaran, S. (2018). Ensemble Deep TimeNet: An ensemble learning approach with deep neural networks for time series. *2018 IEEE 8th International Conference on Computational Advances in Bio and Medical Sciences (ICCBMS)*, 1-1.
- Dhavlle, A., & Dinakarrao, S. M. P. (2020). A comprehensive review of ML-based time-series and signal processing techniques and their hardware implementations. *2020 11th International Green and Sustainable Computing Workshops (IGSC)*, 1-8.
- Shin, H.-C., Orton, M., Collins, D., Doran, S., & Leach, M. (2011). Autoencoder in time-series analysis for unsupervised tissues characterization in a large unlabeled medical image dataset. *2011 10th International Conference on Machine Learning and Applications and Workshops*, 1, 259-264.
- Flamary, R., Fauvel, M., Mura, M., & Valero, S. (2015). Analysis of multitemporal classification techniques for forecasting image time series. *IEEE Geoscience and Remote Sensing Letters*, 12(5), 953-957.
- Cao, C., Liu, F., Tan, H., Song, D., Shu, W., & Li, W. (2018). Deep learning and its applications in biomedicine. *Genome Biology*, 19, 29.
- Ker, J., Wang, L., Rao, J., & Lim, T. C. C. (2018). Deep learning applications in medical image analysis. *IEEE Access*, 6, 9375-9389.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review.

- Neurocomputing, 187, 27-48.
32. Zhang, Y., & Zhang, R. (2019). Research on multimedia image classification technology based on chaos optimization machine learning algorithm. *Multimedia Tools and Applications*, 1-12.
  33. Ye, R., & Dai, Q. (2018). A novel transfer learning framework for time series forecasting. *Knowledge-Based Systems*, 156, 74-99.
  34. Batra M, Agrawal R. Comparative Analysis of Decision Tree Algorithms. In: Panigrahi B, Hoda M, Sharma V, Goel S, editors. *Nature Inspired Computing. Advances in Intelligent Systems and Computing*. Vol. 652. Springer, Singapore; 2018. p. 49-66.
  35. Sani, H.M., Lei, C., Neagu, D. (2018). Computational Complexity Analysis of Decision Tree Algorithms. In: Bramer, M., Petridis, M. (eds) *Artificial Intelligence XXXV. SGAI 2018. Lecture Notes in Computer Science*, 11311. Springer, Cham.
  36. Thomas T, Vijayaraghavan AP, Emmanuel S. Applications of Decision Trees. In: *Machine Learning Approaches in Cyber Security Analytics*. Springer, Singapore; 2020. p. 71-86.
  37. Phalak, M., Bhandari, M., & Sharma, R. (2014). Analysis of Decision Tree-A Survey. *International journal of engineering research and technology*, 3.
  38. Courvoisier, D., Combescure, C., Agoritsas, T., Gayet-Ageron, A., & Perneger, T. (2011). Performance of logistic regression modeling: beyond the number of events per variable, the role of data structure. *Journal of Clinical Epidemiology*, 64(9), 993-1000.
  39. Wilson, J. R., & Lorenz, K. (2015). Standard binary logistic regression model. In K. Lorenz (Ed.), *Springer Series in Statistics* (pp. 25-54). Springer.
  40. Ben-Hur, A., Ong, C. S., Sonnenburg, S., Schölkopf, B., & Rätsch, G. (2008). Support vector machines and kernels for computational biology. *PLoS Computational Biology*, 4(10), e1000173.
  41. Talekar B, Agrawal F. A detailed review on decision tree and random forest. *Biosci Biotechnol Res Commun*. 2020;13(14):245-8.
  42. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.
  43. Zhang, P., Jia, Y., & Shang, Y. (2022). Research and application of XGBoost in imbalanced data. *International Journal of Distributed Sensor Networks*, 18, 15501329221106935.
  44. McClelland, J. (2020). Deep learning. *Data Mining and Machine Learning*.
  45. Minsky, M., & Papert, S. (1969). *Perceptrons: An introduction to computational geometry*. MIT Press.
  46. Hagan, M., Demuth, H., & Jesus, O. (2002). An introduction to the use of neural networks in control systems. *International Journal of Robust and Nonlinear Control*, 12(11), 959-991.
  47. Schmidhuber, J. (2014). Deep learning in neural networks: An overview. *Neural networks: the official journal of the International Neural Network Society*, 61, 85-117.
  48. Hornik, K., Stinchcombe, M., White, H. (1989). Multilayer feedforward networks are universal approximators, *Neural Networks*, 2(5), 359-366.
  49. Geirhos, R., Jacobsen, J., Michaelis, C., Zemel, R., Brendel, W., Bethge, M., & Wichmann, F. (2020). Shortcut learning in deep neural networks. *Nature Machine Intelligence*, 2, 665 - 673.
  50. Minar, M.R., & Naher, J. (2018). Recent Advances in Deep Learning: An Overview. *ArXiv*, abs/1807.08169.
  51. Lemley, J., Bazrafkan, S., & Corcoran, P. (2017). Deep Learning for Consumer Devices and Services: Pushing the limits for machine learning, artificial intelligence, and computer vision. *IEEE Consumer Electronics Magazine*, 6, 48-56.
  52. Zhang, Q., & Zhu, S. (2018). Visual interpretability for deep learning: a survey. *Frontiers of Information Technology & Electronic Engineering*, 19, 27 - 39.
  53. Zini, J., & Awad, M. (2022). On the Explainability of Natural Language Processing Deep Models. *ACM Computing Surveys*, 55, 1 - 31.
  54. Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. *Lecture Notes in Computer Science*, 9351. Springer, Cham.
  55. Mittal, R., Arora, S., Bansal, V., & Bhatia, M. (2021). An Extensive Study on Deep Learning: Techniques, Applications. *Archives of Computational Methods in Engineering*, 28, 4471 - 4485.
  56. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Ł., Polosukhin, I. (2017). Attention is all you need. In *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*.
  57. Dhariwal, P., Nichol, A. (2024). Diffusion models beat GANs on image synthesis. In *Proceedings of the 35th International Conference on Neural Information Processing Systems (NIPS '21)*.
  58. Xu, Y., Tong, S., & Jaakkola, T. (2023). Stable Target Field for Reduced Variance Score Estimation in Diffusion Models. *ArXiv*, abs/2302.00670.
  59. Ho, J., Jain, A., Abbeel, P. (2020). Denoising diffusion probabilistic models. In *Proceedings of the 34th International Conference on Neural Information Processing Systems (NIPS '20)*.
  60. Ali, O., Ali, H., Shah, S. A. A., & Shahzad, A. (2022). Implementation of a Modified U-Net for Medical Image Segmentation on Edge Devices. *IEEE Transactions on Circuits and Systems II: Express Briefs*.
  61. Wang, Z., Zhang, H., He, J., Gao, Z., & Guo, X. (2023). Using a modified U-net model to improve Retinal Vessel Segmentation. *Cambridge Explorations in Arts and Sciences*.
  62. Mei, X., Liu, Z., Robson, P. M., Marinelli, B., Huang, M., Doshi, A., Jacobi, A., Cao, C., Link, K. E., Yang, T., Wang, Y., Greenspan, H., Deyer, T., Fayad, Z. A., & Yang, Y. (2022). RadImageNet: An open radiologic deep learning research dataset for effective transfer learning. *Radiology: Artificial Intelligence*, 4(5).
  63. Falk, T., Mai, D., Bensch, R., Çiçek, Ö., Abdulkadir, A., Marrakchi, Y., Böhm, A., Deubner, J., Jäckel, Z., Seiwald, K., Dovzhenko, A., Tietz, O., Bosco, C., Walsh, S., Saltukoglu, D., Tay, T., Prinz, M., Palme, K., Simons, M., Diester, I., Brox, T., & Ronneberger, O. (2018). U-Net: deep learning for cell counting, detection, and morphometry. *Nature Methods*, 16, 67 - 70.
  64. Civit-Masot, J., Luna-Perejón, F., Vicente-Díaz, S., Rodríguez Corral, J. M., & Civit, A. (2019). TPU Cloud-Based Generalized U-Net for Eye Fundus Image Segmentation. *IEEE Access*, 7, 142379-142387.
  65. Antweiler, D., Gallusser, F., & Fuchs, G. (2023). Multi-Task Transformer Visualization to build Trust for Clinical Outcome Prediction. *2023 Workshop on Visual Analytics in Healthcare (VAHC)*.
  66. Yang, X., Bian, J., Hogan, W., & Wu, Y. (2020). Clinical concept extraction using transformers. *Journal of the American Medical Informatics Association: JAMIA*.
  67. Dunstan, J., Vakili, T., Miranda, L., Villena, F., Aracena, C., Quiroga, T., Vera, P., Viteri Valenzuela, S., & Rocco, V. (2024). A pseudonymized corpus of occupational health narratives for clinical entity recognition in Spanish. *BMC Med Inform Decis Mak* 24, 204.
  68. Báez, P., Villena, F., Rojas, M., Durán, M., & Dunstan, J. (2020). The Chilean Waiting List Corpus: A new resource for clinical named entity recognition in Spanish. In *Proceedings of the 3rd Clinical Natural Language Processing Workshop* (pp. 291-300). Association for Computational Linguistics.
  69. Mayerhoefer, M., Materka, A., Langs, G., Häggström, I., Szczypinski, P., Gibbs, P., & Cook, G. (2020). Introduction to radiomics. *The Journal of Nuclear Medicine*, 61(4), 488-495.
  70. Rizzo, S., Botta, F., Raimondi, S., Origgi, D., Fanciullo, C.,

- Morganti, A., & Bellomi, M. (2018). Radiomics: The facts and the challenges of image analysis. *European Radiology Experimental*, 2.
71. Kumar, V., Gu, Y., Basu, S., Berglund, A., Eschrich, S., Schabath, M., Forster, K., Aerts, H., Dekker, A., Fenstermacher, D., Goldgof, D., Hall, L., Lambin, P., Balagurunathan, Y., Gatenby, R., & Gillies, R. (2012). Radiomics: The process and the challenges. *Magnetic Resonance Imaging*, 30(9), 1234-1248.
72. Upadhaya, T., Vallières, M., Chatterjee, A., Lucia, F., Bonaffini, P., Masson, I., ... & Hatt, M. (2019). Comparison of radiomics models built through machine learning in a multicentric context with independent testing: Identical data, similar algorithms, different methodologies. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 3(2), 192-200.
73. Cuocolo, R., Cipullo, M. B., Stanzione, A., Ugga, L., Romeo, V., Radice, L., Brunetti, A., & Imbriaco, M. (2019). Machine learning applications in prostate cancer magnetic resonance imaging. *European Radiology Experimental*, 3.
74. Li, Z., Wang, Y., Yu, J., Guo, Y., & Cao, W. (2017). Deep learning based radiomics (DLR) and its usage in noninvasive IDH1 prediction for low grade glioma. *Scientific Reports*, 7, 546.
75. Zhou, D.-X. (2020). Universality of deep convolutional neural networks. *Applied and Computational Harmonic Analysis*, 48(2), 787-794.
76. Lingo, R. (2023). The Role of ChatGPT in Democratizing Data Science: An Exploration of AI-facilitated Data Analysis in Telematics. *ArXiv*, abs/2308.02045. <https://doi.org/10.48550/arXiv.2308.02045>.
77. Hassani, H., & Silva, E. S. (2023). The role of ChatGPT in data science: How AI-assisted conversational interfaces are revolutionizing the field. *Big Data and Cognitive Computing*, 7(2), 62.
78. Dave, T., Athaluri, S. A., & Singh, S. (2023). ChatGPT in medicine: An overview of its applications, advantages, limitations, future prospects, and ethical considerations. *Frontiers in Artificial Intelligence*, 6.
79. Rivas, P. (2023). Marketing with ChatGPT: Navigating the Ethical Terrain of GPT-Based Chatbot Technology. *AI*.
80. Gulowaty, B., & Wozniak, M. (2021). Extracting Interpretable Decision Tree Ensemble from Random Forest. 2021 International Joint Conference on Neural Networks (IJCNN), 1-8.
81. Moore, A., & Bell, M. (2022). XGBoost, A Novel Explainable AI Technique, in the Prediction of Myocardial Infarction: A UK Biobank Cohort Study. *Clinical Medicine Insights. Cardiology*, 16.
82. Ruder, S., Peters, M., Swayamdipta, S., & Wolf, T. (2019). Transfer Learning in Natural Language Processing. 15-18.
83. Pan, S., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22, 1345-1359.
84. Senavirathne, N., & Torra, V. (2020). On the Role of Data Anonymization in Machine Learning Privacy. 2020 IEEE 19th International Conference on Trust, Security and Privacy in Computing and Communications (TrustCom), 664-675.
85. Goldsteen, A., Ezov, G., Shmelkin, R., Moffie, M., Farkash, A. (2022). Anonymizing Machine Learning Models. In: Garcia-Alfaro, J., Muñoz-Tapia, J.L., Navarro-Arribas, G., Soriano, M. (eds) *Data Privacy Management, Cryptocurrencies and Blockchain Technology. DPM CBT 2021*. Lecture Notes in Computer Science, vol 13140. Springer, Cham.
86. Díaz, J., & García, Á. (2023). Comparison of machine learning models applied on anonymized data with different techniques. 2023 IEEE International Conference on Cyber Security and Resilience (CSR), 618-623.
87. Yang, Q., Liu, Y., Cheng, Y., Kang, Y., Chen, T., & Yu, H. (2019). Federated Learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*.
88. Kairouz, P., McMahan, H., Avent, B., Bellet, A., Bennis, M., Bhagoji, A., Bonawitz, K., Charles, Z., Cormode, G., Cummings, R., D'Oliveira, R., Rouayheb, S., Evans, D., Gardner, J., Garrett, Z., Gascón, A., Ghazi, B., Gibbons, P., Gruteser, M., Harchaoui, Z., He, C., He, L., Huo, Z., Hutchinson, B., Hsu, J., Jaggi, M., Javidi, T., Joshi, G., Khodak, M., Konečný, J., Korolova, A., Koushanfar, F., Koyejo, O., Lepoint, T., Liu, Y., Mittal, P., Mohri, M., Nock, R., Özgür, A., Pagh, R., Raykova, M., Qi, H., Ramage, D., Raskar, R., Song, D., Song, W., Stich, S., Sun, Z., Suresh, A., Tramèr, F., Vepakomma, P., Wang, J., Xiong, L., Xu, Z., Yang, Q., Yu, F., Yu, H., & Zhao, S. (2019). Advances and Open Problems in Federated Learning. *Found. Trends Mach. Learn.*, 14, 1-210.