

Aprendizaje automático aplicado en física: Una revisión de la literatura científica

Iris Iddaly Méndez-Gurrola¹, Abdiel Ramírez-Reyes¹,
Román Anselmo Mora-Gutiérrez²

¹ Universidad Autónoma de Ciudad Juárez,
México

² Universidad Autónoma Metropolitana,
Unidad Azcapotzalco,
México

iddalym@yahoo.com.mx, adbiel.ramirez@uacj.mx,
mgra@correo.azc.uam.mx

Resumen. El Aprendizaje Automático es una rama dentro de Inteligencia Artificial que utiliza algoritmos y herramientas para lograr predicciones y juicios, analizando y aprendiendo de cantidades de datos históricos y sintéticos, lo cual puede ayudar por ejemplo en la toma de decisiones. Esta rama se ha abierto paso en muchas disciplinas científicas durante los últimos años. En el presente artículo se realiza una revisión de la literatura en la que se utiliza el Aprendizaje Automático en Física, se resaltan los desarrollos que ha habido en cuanto a la interrelación de ambas disciplinas durante los años 2005-2020, esto incluye desarrollos en la aplicación de técnicas de Aprendizaje Automático a varios dominios de la Física. Primeramente, se brinda una noción básica de Aprendizaje Automático la Física. Seguidamente se centra en organizar cada una de las publicaciones encontradas por categorías o áreas de la Física, para brindar un panorama general de áreas con mayores aplicaciones del Aprendizaje Automático en Física. Destaca en la investigación, el crecimiento acelerado de publicaciones de 2017 a la fecha. Finalmente, se discuten los diversos hallazgos en la aplicación de métodos y técnicas de Aprendizaje Automático en Física, y aquellos orientados a la búsqueda de conocimiento de frontera en la Física.

Palabras clave: Aprendizaje automático, inteligencia artificial, física, revisión de literatura, física aplicada.

Machine Learning Applied in Physics: A Review of the Scientific Literature

Abstract. Machine Learning is a branch within Artificial Intelligence that uses algorithms and tools to make predictions and judgments, analyzing and learning from amounts of historical and synthetic data, which it can help for example in decision making. This branch has been used in many scientific disciplines in recent years. In this article a literature review is made in which the Machine Learning is used in Physics, highlights the developments that have been in the

interrelation of both disciplines during the years 2005-2020, this includes developments in the application of Machine Learning techniques to various domains of Physics. First, a basic notion of Machine Learning is made and later of Physics. Then it focuses in organizing each of the publications found by categories or areas of Physics, which allows to provide an overview of areas with higher applications of Machine Learning within Physics. Highlight in the investigation, the accelerated growth of publications from 2017 to the date. Finally, various findings in the application of methods and techniques of Machine Learning in Physics are discussed, and those oriented to the search of new knowledge in frontier Physics.

Keywords: Machine learning, artificial intelligence, physics, literature review, applied physics.

1. Introducción

El Aprendizaje Automático es un área dentro de la Inteligencia Artificial (IA) que abarca una amplia gama de algoritmos y herramientas de modelado utilizados para una amplia gama de tareas de procesamiento de datos, que ha entrado en la mayoría de las disciplinas científicas en los últimos años, las Ciencias Físicas no han sido la excepción. En Física se desea comprender los mecanismos de la naturaleza y se utiliza su propio conocimiento, inteligencia e intuición para formar sus modelos. Por tanto, ambas disciplinas están preocupadas por el proceso de recopilación y análisis de datos para diseñar modelos que puedan predecir el comportamiento de sistemas complejos. El uso de la IA en las ciencias Físicas es algo que se ha planteado desde hace años; se sabe de la importancia de la IA para mostrar fenómenos, comportamientos o propiedades que no pueden ser inferidos a partir de metodologías tradicionales [1,2], pero que inicialmente tenían la dificultad del insuficiente procesamiento de cómputo o el poco desarrollo de los algoritmos.

La intersección entre ambas disciplinas es un tema de amplio interés actual en la Física, pues esto ofrece nuevas estrategias para resolver los problemas de alta complejidad que hay en las ciencias Físicas, pero a la vez importante para el desarrollo de las técnicas del Aprendizaje Automático. Ahora bien, ¿Cómo identificar estas intersecciones?, ¿Qué avances se han hecho al respecto? y ¿Qué hallazgos se han encontrado de esta conjunción? Para responder a estas y otras preguntas es necesario hacer una revisión de la literatura. Construir una investigación y relacionarla con el conocimiento existente es cada vez más una tarea compleja, debido a que la generación de conocimiento es de forma acelerada, por tal motivo, es tan importante realizar una revisión de literatura como método de investigación. La revisión de la literatura es, en términos generales, una forma sistemática de recopilar y sintetizar investigaciones previas y que puede llegar a ser una base firme para el avance en el conocimiento [3].

Este trabajo comienza dando una breve descripción de Aprendizaje Automático, y se mencionan algunos de los paradigmas de aprendizaje que se encuentran dentro de esta área y algunos de los campos donde se aplica. En la sección 3 se define la Física y se muestra una categorización de las áreas que la integran. La sección 4 especifica la metodología utilizada para la revisión de la literatura en este trabajo. En sección 5 se muestra el análisis de datos y los resultados de la investigación, para finalmente en la sección 6 se abordan las conclusiones y perspectivas del trabajo.

2. Aprendizaje automático

La IA se podría decir que es una colección de varias herramientas analíticas que colectivamente intentan imitar el comportamiento del ser humano. En los últimos años, la IA ha madurado a un conjunto de herramientas analíticas que facilitan la resolución de problemas que antes eran difíciles o imposibles de resolver. La tendencia ahora es la integración de estas herramientas, con tecnologías convencionales como el análisis estadístico, para construir sistemas sofisticados capaces de resolver problemas desafiantes [4]. La IA se divide básicamente en dos tipos: IA débil e IA fuerte.

Dentro de la IA débil sobresalen las áreas de: a) Aprendizaje Automático, b) Métodos Probabilísticos, c) Computación Evolutiva, d) Sistemas Difusos, entre otras. Este trabajo se centra en el **Aprendizaje Automático** o Machine Learning (ML), el cual es capaz de simular un comportamiento utilizando algoritmos que requieren una gran cantidad de datos. En la mayoría de las ocasiones el algoritmo “aprende” qué decisión adoptar y crea un modelo. Pertenecen a esta rama las redes neuronales, modelos basados en KNN o en regresión logística, árboles de decisión, máquinas de soporte vectorial, entre otros [5].

Con relación al Aprendizaje Automático entre los modelos utilizados para entrenar los algoritmos se ubican los modelos lógicos, los modelos geométricos y los modelos probabilísticos. Además, entre los paradigmas de aprendizaje se encuentran [5]:

- **Aprendizaje supervisado.** Basándose en el pasado el modelo elabora una función que relaciona las variables predictoras con las de clase. Esta función es utilizada posteriormente para realizar predicciones (clasificación).
- **Aprendizaje no supervisado.** Tiene el objetivo de la obtención de grupos, tal que en cada uno de ellos haya instancias homogéneas, mientras que los grupos son heterogéneos entre sí. En este aprendizaje no hay información del pasado, es el propio modelo el encargado de realizar sus propias divisiones.
- **Aprendizaje por refuerzo.** El algoritmo aprende, no con la información previa que se le hubiera proporcionado, sino con su interacción con el mundo que le rodea, por tanto, se produce una retroalimentación que va modificando y refinando su comportamiento.

Los campos de aplicación de la IA y en particular del Aprendizaje Automático son cada vez más diversificados, entre ellos se encuentran las aplicaciones en la Física y sus diferentes áreas que la integran.

3. Física

La Física es una ciencia natural cuyo objeto de estudio es la materia, la energía, los campos y sus interacciones entre sí, en escalas microscópicas o macroscópicas. Posee un marco lógico-matemático, con el que formula y cuantifica principios físicos. Es una ciencia fundamental, sobre la que se fundamentan otras ciencias naturales y aplicadas. La Física tiene aplicaciones extraordinariamente amplias en otras áreas del conocimiento, así como en cuestiones prácticas que han suscitado sustanciales repercusiones tecnológicas. Con un enfoque reduccionista y pragmático, la Física —o Ciencias Físicas— las podemos categorizar como Física Básica y Física Aplicada.

- **La Física Básica**, son los conocimientos que permiten comprender los problemas fundamentales en la naturaleza, es decir, busca el conocimiento solo por conocer y comprender la naturaleza.
- **La Física Aplicada**, tiene la finalidad de utilizar los conocimientos de la Física Básica para resolver problemas prácticos dentro de la misma Física, así como en otras disciplinas del conocimiento.

Las principales áreas o subdisciplinas que forman parte de la Física Básica o Aplicada se muestran en la Figura 1. Dicha clasificación es tomada en parte de [6], pero no es exhaustiva.

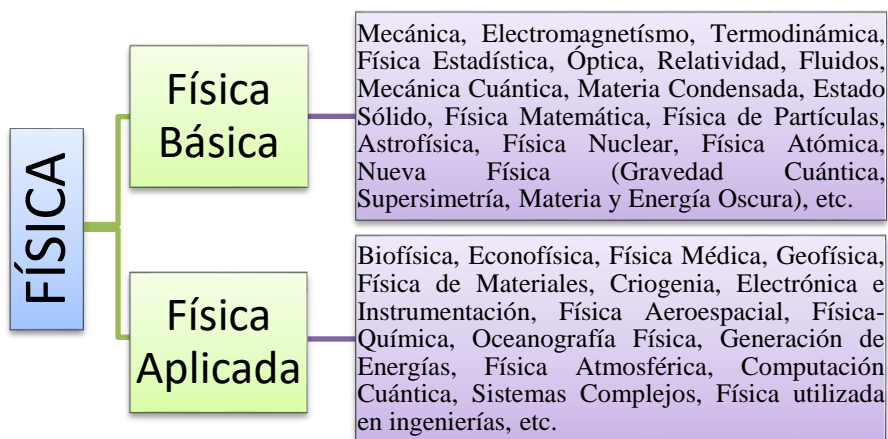


Fig. 1. Síntesis de las principales áreas de la Física.

La Física siempre ha sido, es y será un área de amplio interés para el humano. Los conocimientos generados en experimentos como el Gran Colisionador de Hadrones [7, 10-19], la prometedora Computación Cuántica [7, 22], la existencia de sistemas tan exóticos como agujeros negros [7], la hadronterapia para tratamientos de enfermedades como cáncer [8] y muchos otros experimentos o aplicaciones, hacen evidente la importancia de la Física —todos estos ejemplos hacen uso de la IA—.

Sin embargo, como cualquier otra disciplina científica, posee limitantes y requiere de robustas herramientas de las ciencias computacionales, en particular la IA. Las ciencias interdisciplinarias que surgen de la interacción de la Física con otras ciencias no son nuevas —basta recordar el origen de la Biofísica, Física Médica, Física de Materiales, etc.—. Una hipótesis de este trabajo es que está surgiendo un área nueva del conocimiento producto del cruce de la Física y la IA, con un enorme potencial de generar nuevo conocimiento y nuevas tecnologías con importantes implicaciones en ciencia y tecnología. Es importante identificar las herramientas específicas de IA que se están aplicando en la Física.

Es importante mencionar que existen pocos estudios como el presente, los estudios existentes no son exhaustivos —se enfocan en un área de IA aplicada a una o pocas áreas de la Física y publicados en revistas de Física—.

Esto no permite a los lectores o investigadores interesados en estos tópicos tener una visión general, actual y pronta del tema. De los trabajos existentes destaca [10, 11], quienes revisan los métodos de Aprendizaje Automático Aplicado a la Física de Partículas, Mecánica Cuántica, Física Estadística y Astrofísica. Ninguno de los trabajos revisados hace un estudio de cómo se está dando la interacción entre la IA y la Física.

4. Metodología

De acuerdo con Snyder [3], el proceso para llevar a cabo una revisión de la literatura está dividido en cuatro fases: 1) el diseño de la revisión, 2) realización de la revisión, 3) análisis y 4) escribir la reseña. Esta metodología es la generalmente utilizada en el desarrollo de trabajos de este tipo.

Fase I Diseño de la revisión. Aquí se indica la pertinencia de la revisión a realizar, considerando preguntas como ¿Existe realmente la necesidad de una revisión de la literatura en esta área? Si es así ¿Qué tipo de revisión de la literatura será la más útil y haría la mayor contribución? Ante estos cuestionamientos, es necesaria una revisión de la literatura, dado que en Física recientemente son muy utilizadas técnicas y herramientas de IA, específicamente de Aprendizaje Automático, existiendo pocos artículos de revisión [10, 11]. Ahora, dentro de los tres diferentes enfoques que señala Snyder [3], en esta investigación se seleccionó la revisión semi-sistemática pues el objetivo es tener una visión general de un tema, en este caso ¿Cómo el Aprendizaje Automático ha contribuido o permeado en varias de las áreas de la Física? Se señala además que en la revisión semi-sistemática se analiza cómo la investigación dentro de un campo seleccionado ha progresado en el tiempo y cómo se ha desarrollado un tema a través de las tradiciones de investigación [9]. Entonces, esta investigación busca identificar y comprender todas las áreas de la Física que usan el Aprendizaje Automático y sus implicaciones, además de sintetizarlas utilizando meta-narrativas.

Una vez que se ha identificado la pregunta de investigación y se ha considerado un enfoque de revisión general, es necesario desarrollar una estrategia de búsqueda para identificar la literatura, esto incluye seleccionar los términos de búsqueda y las bases de datos apropiadas y decidir sobre los criterios de inclusión y exclusión [3].

La estrategia de búsqueda utilizada fue la siguiente: se seleccionaron referencias bibliográficas de las bases de datos electrónicas más representativas, como: 1) Biblioteca digital ACM, 2) Annual Reviews, 3) EBSCOHOST, 4) Biblioteca digital IEEE Xplore, 5) Nature, 6) ScienceDirect, 7) Scopus, 8) Wiley, 9) Google Scholar y 10) InSpire. La ventana de observación definida para este estudio fue de 15 años: enero de 2005 hasta marzo del 2020. La búsqueda se efectuó con limitación del idioma inglés. Las palabras clave utilizadas para la búsqueda fueron "machine learning", "physical sciences", "physics" y "review". Los criterios de inclusión involucran todos los aspectos señalados anteriormente y los criterios de exclusión fueron: artículos científicos que se refieren a cualquier otro tipo de ciencia no relacionadas con la Física, y estudios realizados más bajo un enfoque matemático.

Fase II Realización de la revisión. En esta fase se realiza la revisión real, Snyder [3] señala que es preferible utilizar dos revisores, con el objetivo de garantizar la calidad y fiabilidad del protocolo de búsqueda. El presente estudio fue realizado por dos

revisores. Se utilizaron las 10 bases de datos descritas anteriormente, encontrando 25 y 29 artículos potencialmente relevantes por cada revisor, dando un total de 54 artículos en esta fase. La selección real de la muestra se puede hacer de varias maneras, dependiendo de la naturaleza y el alcance de la revisión específica, en este caso, el enfoque utilizado fue realizar la revisión por etapas; se eliminaron elementos duplicados y se realizó un análisis preliminar, basado en el título, resumen y los criterios de exclusión, para seleccionar documentos elegibles. Después de la selección quedaron 42 artículos (ver Figura 2), y que se leyeron por completo.

Fase III Análisis. Aquí se debe utilizar un medio estandarizado para extraer información apropiada de cada artículo. Los datos resumidos pueden ser en forma de información descriptiva, como autores, años de publicación, tema o tipo de estudio, o en forma de efectos y hallazgos. En esta fase se llevó a cabo la Tabla 1, que muestra la información descriptiva de cada artículo, determinando la referencia, el año de publicación, el título del artículo y el área de la Física a la que corresponde.

Fase IV Escribir la reseña. Dependiendo del enfoque, el artículo de revisión final puede estructurarse de diferentes maneras y con y diferentes niveles de detalle. Sin embargo, algunas generalizaciones pueden ser indicadas, por ejemplo, se espera que todos los autores sigan las convenciones aceptadas para informar sobre cómo se realizó el estudio, y describir de manera transparente el proceso de diseño de la revisión y el método para recopilar literatura, es decir, cómo la literatura fue identificada, analizada, sintetizada e informada [3]. En este caso de estudio, cada una de estas indicaciones fue realizada en las fases previas. También en esta fase es importante señalar las diferentes contribuciones que pueden ser valiosas en el campo de estudio.

El proceso de búsqueda y selección de trabajos relevantes se resume en la Figura 2.



Fig. 2. Esquema del proceso de estrategia de búsqueda y selección.

5. Análisis de resultados y discusión

Siguiendo la metodología previamente planteada en la sección 4, se identificaron 42 publicaciones en la literatura internacional, que hacen uso explícito del Aprendizaje Automático —Inteligencia Artificial— en la resolución parcial o total de un problema físico, ver Tabla 1. Las publicaciones están bien referenciadas en bases de datos que registran artículos de alta calidad académica; es de resaltar que varios de los artículos pertenecen a las revistas de mayor impacto en la Física como “Nature” (ver ítem 6, 8, 13, 14, 17, 29, 33, 36, 41 y 47). Aproximadamente 80% de estas publicaciones están citadas en el “Journal Citation Reports 2019” [52]. Dado que algunos artículos aplican el Aprendizaje Automático a dos o más áreas de la Física, se utiliza un asterisco (*)

Tabla 1. Publicaciones en Física que utilizan Aprendizaje Automático.

	Autor	Año	Título	Área de Física
1	Larkoski et al. [10]	2020	Jet substructure at the LHC: A review of recent advances in theory and machine learning	Física de Partículas
2	Carleo et al. [11] *5	2019	Machine learning and the physical sciences	Física de Partículas
3	Calafiura et al. [12]	2019	TrackML: A High Energy Physics Particle Tracking Challenge	Física de Partículas
4	Benson y Gizdov [13]	2019	NNDrone: A toolkit for the mass application of machine learning in High Energy Physics	Física de Partículas
5	Guest et al. [14]	2018	Deep Learning and Its Application to LHC Physics	Física de Partículas
6	Radovic et al. [15]	2018	Machine learning at the energy and intensity frontiers of particle physics	Física de Partículas
7	Albertsson et al. [16]	2018	Machine Learning in High Energy Physics Community White Paper	Física de Partículas
8	Baldi et al. [17]	2014	Searching for exotic particles in high-energy physics with deep learning	Física de Partículas
9	Whitenson et al. [18]	2009	Machine learning for event selection in high energy physics	Física de Partículas
10	Rem et al. [19]	2019	Identifying quantum phase transitions using artificial neural networks on experimental data	Mecánica Cuántica
11	Carleo et al. [11] *5	2019	Machine learning and the physical sciences	Mecánica Cuántica
12	Dunjko y Briegel [20]	2018	Machine learning & artificial intelligence in the quantum domain: a review of recent progress	Mecánica Cuántica
13	Nieuwenburg et al. [21]	2017	Learning phase transitions by confusion	Mecánica Cuántica
14	Krein et al. [22]	2016	Automated Search for new Quantum Experiments	Mecánica Cuántica
15	Shuld et al. [23]	2015	An introduction to quantum machine learning	Mecánica Cuántica
16	Arsenault et al. [24] *2	2014	Machine learning for many-body physics: The case of the Anderson impurity model	Mecánica Cuántica
17	Carrasquilla y Melko [25]	2017	Machine learning phases of matter	Materia Condensada
18	Ch'ng, et al. [26] *2	2017	Machine Learning Phases of Strongly Correlated Fermions	Materia Condensada

para identificar la multiplicidad del artículo (p.ej. el item 2, aparece 5 veces), esto implicó los 50 ítems de la Tabla 1.

19	Arsenault et al. [24] *2	2014	Machine learning for many-body physics: The case of the Anderson impurity model	Materia Condensada
20	Qian et al. [27]	2020	Lift & Learn: Physics-informed machine learning for large-scale nonlinear dynamical systems	Física Matemática
21	Pei et al. [28]	2020	Machine learning as a contributor to physics: Understanding Mg alloys	Física Matemática
22	Raissi, et al. [29]	2018	Hidden physics models: Machine learning of nonlinear partial differential equations	Física Matemática
23	Zhang et al. [30]	2020	A Review of Research on Pulsar Candidate Recognition Based on Machine Learning	Astrofísica
24	Carleo et al. [11] *5	2019	Machine learning and the physical sciences	Astrofísica
25	Cruz et al. [31]	2019	The use of the Reynolds force vector in a physics informed machine learning approach...	Fluidos
26	Swischuk et al. [32]	2019	Projection-based model reduction: Formulations for physics-based machine learning	Fluidos
27	Nakamura y Hashimoto [33]	2007	Hybrid learning strategy to solve pendulum swing-up problem for real hardware	Mecánica
28	Ruta y Gabris, 2007 [34] *2	2007	A framework for machine learning based on dynamic physical fields	Mecánica
29	Zdeborová et al. [35]	2017	MACHINE LEARNING New tool in the box	Física Estadística
30	Ruta y Gabris, 2007 [34] *2	2007	A framework for machine learning based on dynamic physical fields	Electromagnetismo
31	Zhou et al. [36]	2019	Emerging role of machine learning in light-matter interaction	Óptica
32	D'angelo y Wulzer [37]	2019	Learning new physics from a machine	Nueva Física
33	Collins et al. [38]	2018	Anomaly Detection for Resonant New Physics with Machine Learning	Nueva Física
34	Carleo et al. [11] *5	2019	Machine learning and the physical sciences	Física de Materiales
35	Oviedo et al. [39]	2019	Fast and interpretable classification of small X-ray diffraction datasets using data augmentation	Física de Materiales
36	Butler et al. [40] *2	2018	Machine learning for molecular and materials science	Física de Materiales
37	Rosenbrock et al. [41]	2017	Discovering the building blocks of atomic systems using machine learning: application	Física de Materiales
38	Ch'ng, et al. [26] *2	2017	Machine Learning Phases of Strongly Correlated Fermions	Física de Materiales
39	Li et al. [42]	2020	Reaction diffusion system prediction based on convolutional neural network	Física-Química

40	Lattimer et al. [43]	2020	Using machine learning in physics-based simulation of fire	Física-Química
41	Butler et al. [40] *2	2018	Machine learning for molecular and materials science	Física-Química
42	Carleo et al. [11] *5	2019	Machine learning and the physical sciences (Revisión)	Física-Química
43	Issam, et al. [44]	2015	Machine Learning in Radiation Oncology	Física Médica
44	Zhu et al. [45]	2011	A planning quality evaluation tool for prostate adaptive IMRT based on machine learning	Física Médica
45	Grazzini et al. [46]	2019	Extreme precipitation events over northern Italy. Part I: A systematic classification	Física Atmosférica
46	Xu et al. 2017 [47]	2017	A Novel Ozone Profile Shape Retrieval Using Full-Physics Inverse Learning Machine	Física Atmosférica
47	Hulbert et al. [48]	2018	Similarity of fast and slow earthquakes illuminated by machine learning	Geofísica
48	Ng et al. [49]	2019	Predicting the state of charge and health of batteries using data-driven machine learning	Electrónica e Instrumentación
49	Cheng and Yu, 2019 [50]	2019	A new generation of AI: A review and perspective on machine learning technologies applied to smart energy	Sistemas de energía
50	Alber et al. [51]	2019	Integrating machine learning and multiscale modeling—	Biofísica

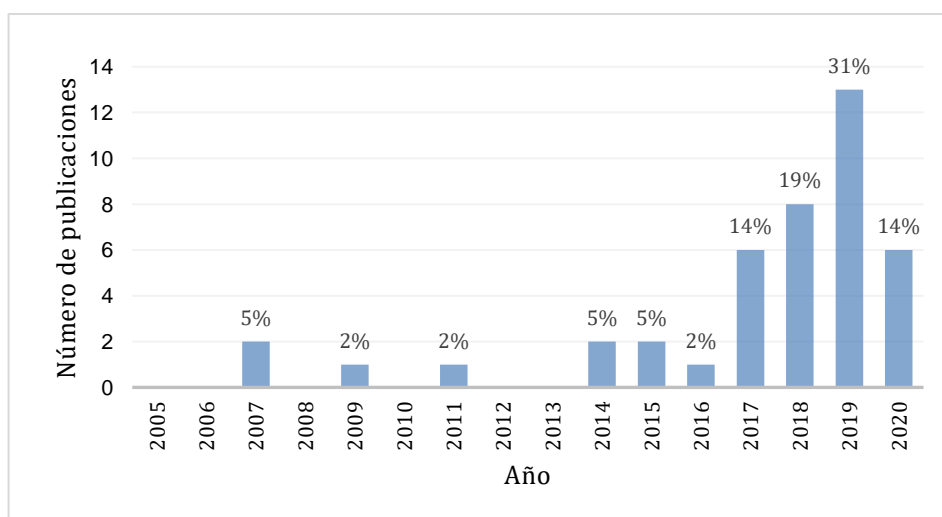


Fig. 3. Núm. de publicaciones en Física que utilizan Aprendizaje Automático.

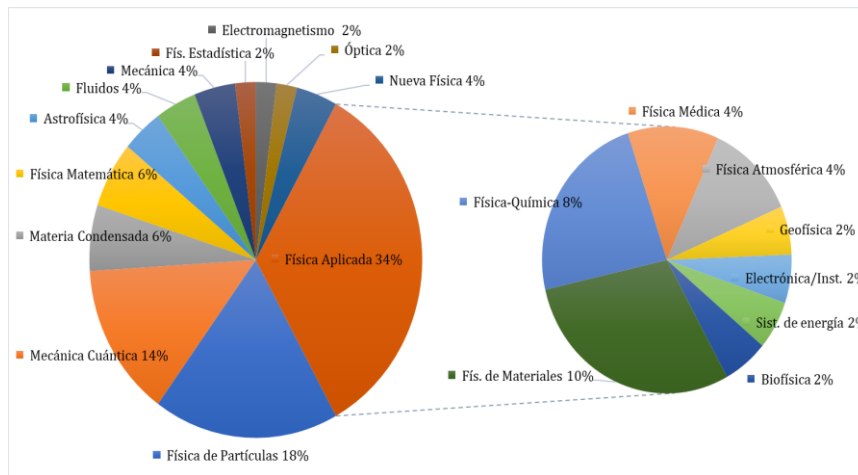


Fig. 4. Áreas de la Física que utilizan Aprendizaje Automático.

La Figura 3 muestra los artículos de investigación publicados en función del tiempo, entre enero-2005 y marzo-2020. Resalta el aumento significativo y acelerado de publicaciones en los últimos 4 años, y que corresponde al 78% de las publicaciones.

Para agrupar los artículos se propuso la siguiente clasificación que consta de 2 categorías que cubren varias áreas de Física: 1) Física Básica, y 2) Física Aplicada. En la Figura 4 se muestra la clasificación realizada en este estudio y el porcentaje de trabajos encontrados por áreas de la Física. Es importante notar que todas las publicaciones hacen uso del Aprendizaje Automático como una herramienta sumamente poderosa para llegar a una conclusión o resultado en la Física y son publicaciones en revistas de Física. No hay en sentido opuesto, de aplicaciones de la Física a IA.

En la Figura 4 se puede observar que las áreas del conocimiento que concentran las publicaciones son en primer lugar Física de Partículas (18%), seguida de Mecánica Cuántica (14%), en tercer lugar Física de materiales (10%), posteriormente Física-química (8%), Materia Condensada (6%), Física matemática (6%), después Física médica, Física atmosférica, Mecánica, Astrofísica, Fluidos, nueva Física con 4%, y finalmente con 2% cada una de las restantes áreas.

Es conveniente mencionar que se logró establecer una metodología para identificar las intersecciones de la Física con el Aprendizaje Automático, mediante ello se identificaron las publicaciones al respecto y con base en esto se hace evidente que la Inteligencia Artificial, a través del Aprendizaje Automático, está volviéndose una herramienta importante en las Ciencias Físicas. Este cruzamiento es relativamente nuevo y muy novedoso, esto puede ser explicado por el robustecimiento del Aprendizaje Automático, por una parte, y por otra, debida a la necesidad de nuevas herramientas para resolver problemas sumamente complejos en las Ciencias Físicas, que por sí solas no pueden resolver con herramientas tradicionales.

Algo que es muy interesante para la Física es que, analizando cualitativamente los ítems 14, 32 y 33, se observa una estrategia nueva para identificar nueva Física (como nuevos experimentos en Mecánica Cuántica o Física más allá del modelo estándar) mediante la Inteligencia Artificial. Esto es algo completamente nuevo, pues la Física nunca se ha construido mediante IA. Podemos sugerir el término de Física de IA.

6. Conclusiones

Se identificaron 42 artículos científicos sobre IA (Aprendizaje Automático) aplicado a la Física, y las formas en cómo se utilizan y aplican las técnicas de Aprendizaje Automático a las diferentes áreas de la Física. De lo anterior sobresalen los siguientes puntos: primero resalta el gran interés creciente que las técnicas de Aprendizaje Automático tienen en la Física, pues en los últimos 4 años están el 78% de todas las publicaciones identificadas. Sobresale Física Básica, con las áreas de Física de Partículas y Mecánica Cuántica pues son las que más hacen uso del Aprendizaje Automático, concentrando el 48% de las publicaciones en esa área en los últimos 4 años. Segundo, en lo referente a Física Aplicada, sobresale Física de Materiales con el 10%.

Es importante indicar como se observa en la Figura 4, que la cantidad de áreas donde ha sido utilizado Aprendizaje Automático es muy amplia, en Física Básica abarca Física de Partículas, Mecánica Cuántica, Materia Condensada, Física Matemática, Astrofísica, Fluidos, Física estadística, Mecánica, Electromagnetismo y Óptica. Ahora bien, la conexión de técnicas de Aprendizaje Automático con la Física Aplicada también es muy amplia, abarca: Materiales, Física-química, Física médica, Física Atmosférica, Geofísica, Electrónica e Instrumentación, Sistemas de energía y Biofísica. Tercero, destacan dos trabajos que aplican Aprendizaje Automático para la búsqueda de nueva Física, lo que implica una nueva forma de construir conocimiento en Física.

Cuarto, el trabajo realizado permite observar que la interacción entre el Aprendizaje Automático y las Ciencias Físicas ha tenido un crecimiento los últimos años, sin embargo, aún hay mucho por hacer, pues en muchas de las áreas no se ha aplicado grandemente y que se podrían generar resultados interesantes. Como trabajo futuro se realizará un análisis detallado de la revisión por áreas de la Física, con el objetivo de encontrar específicamente las herramientas y técnicas de Aprendizaje Automático que son más utilizadas dentro de cada área en particular.

Referencias

1. Hogg, T., Huberman, B.A.: Artificial intelligence and large scale computation: A physics perspective. *Physics Reports*, 156(5), pp. 227–310 (1987)
2. Rossel, C., Nordberg, M.: Physics and its current and future applications. *Europhysics News* (2018)
3. Snyder, H.: Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, pp. 333–339 (2019)
4. Gordon, B.M.: *Artificial intelligence: approaches, tools, and applications*. New York: Nova Science Publishers, Inc. (2011)

5. Nguyen, G., Dlugolinsky, S., Bobák, M., Tran, V., García, Á.L., Heredia, I.: Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*, pp. 77–124 (2019)
6. Sears, F.W., et al.: *Física Universitaria*. 1 (2009)
7. Russell, S.: Artificial intelligence: The future is superintelligent. *Nature*, 548(7669), pp. 520 (2017)
8. Akgun, U.: CARNA with artificial intelligence-use of machine learning for a proton imaging. In: *SPIE Medical Imaging Conference* (2019)
9. Wong, G., Greenhalgh, T., Westhorp, G., Buckingham, J., Pawson, R.: RAMESES publication standards: realist syntheses. *BMC medicine*, 21 (2013)
10. Larkoski, A.J., Moul, I., Nachman, B.: Jet substructure at the Large Hadron Collider: a review of recent advances in theory and machine learning. *Physics Reports*, 841, pp. 1–63 (2020)
11. Carleo, G., Cirac, I., Cranmer, K., Daudet, L., Schuld, M., Tishby, N., Zdeborová, L.: Machine learning and the physical sciences. *Reviews of Modern Physics*, 91(4), 045002 (2019)
12. Calafiura, P., Farrell, S., Gray, H., Vlimant, J.R., Innocente, V., Salzburger, A., Germain, C.: TrackML: A high energy physics particle tracking challenge. In: *14th International Conference on e-Science*, IEEE. pp. 344–344 (2018)
13. Benson, S., Gizdov, K.: NNDRone: A toolkit for the mass application of machine learning in High Energy Physics. *Computer Physics Communications*, 240, pp. 15–20 (2019)
14. Guest, D., Cranmer, K., Whiteson, D.: Deep learning and its application to LHC physics. *Annual Review of Nuclear and Particle Science*, pp. 161–181 (2018)
15. Radovic, A., Williams, M., Rousseau, D., Kagan, M., Bonacorsi, D., Himmel, A., Wongjirad, T.: Machine learning at the energy and intensity frontiers of particle physics. *Nature*, 560(7716), pp. 41–48 (2018)
16. Albertsson, K., Altoe, P., Anderson, D., Anderson, J., Andrews, M., Espinosa, J.P.A., Bonacorsi, D.: Machine learning in high energy physics community white paper (2018)
17. Baldi, P., Sadowski, P., Whiteson, D.: Searching for exotic particles in high-energy physics with deep learning. *Nature communications*, pp. 1–9 (2014)
18. Whiteson, S., Whiteson, D.: Machine learning for event selection in high energy physics. *Engineering Applications of Artificial Intelligence*, pp. 1203–1217 (2009)
19. Rem, B.S., Käming, N., Tarnowski, M., Asteria, L., Fläschner, N., Becker, C., Weitenberg, C.: Identifying quantum phase transitions using artificial neural networks on experimental data. *Nature Physics*, 15(9), pp. 917–920 (2019)
20. Dunjko, V., Briegel, H.J.: Machine learning & artificial intelligence in the quantum domain: a review of recent progress. *Reports on Progress in Physics*, 81(7), 074001 (2018)
21. Van Nieuwenburg, E.P., Liu, Y.H., Huber, S.D.: Learning phase transitions by confusion. *Nature Physics*, 13(5), pp. 435–439 (2017)
22. Krenn, M., Malik, M., Fickler, R., Lapkiewicz, R., Zeilinger, A.: Automated search for new quantum experiments. *Physical review letters*, 090405 (2016)
23. Schuld, M., Sinayskiy, I., Petruccione, F.: An introduction to quantum machine learning. *Contemporary Physics*, 56(2), pp. 172–185 (2015)
24. Arsenault, L.F., Lopez-Bezanilla, A., von Lilienfeld, O.A., Millis, A.J.: Machine learning for many-body physics: The case of the Anderson impurity model. *Physical Review B*, 90(15), 155136 (2014)
25. Carrasquilla, J., Melko, R.G.: Machine learning phases of matter. *Nature Physics*, 13(5), pp. 431–434 (2017)
26. Ch'Ng, K., Carrasquilla, J., Melko, R.G., Khatami, E.: Machine learning phases of strongly correlated fermions. *Physical Review X*, 7(3), 031038 (2017)

27. Qian, E., Kramer, B., Peherstorfer, B., Willcox, K.: Lift & learn: physics-informed machine learning for large-scale nonlinear dynamical systems. *Physica D: Nonlinear Phenomena*, 406, 132401 (2020)
28. Pei, Z., Yin, J.: Machine learning as a contributor to physics: Understanding Mg alloys. *Materials & Design*, 172, 107759 (2019)
29. Raissi, M., Karniadakis, G.E.: Hidden physics models: Machine learning of nonlinear partial differential equations. *Journal of Computational Physics*, 357, pp.125–141 (2018)
30. Zhang, C.J., Shang, Z.H., Chen, W.M., Xie, L., Miao, X.H.: A review of research on pulsar candidate recognition based on machine learning. *Procedia Computer Science*, 166, pp. 534–538 (2020)
31. Cruz, M.A., Thompson, R.L., Sampaio, L.E., Bacchi, R.D.: The use of the Reynolds force vector in a physics informed machine learning approach for predictive turbulence modeling. *Computers & Fluids*, 192, 104258 (2019)
32. Swischuk, R., Mainini, L., Peherstorfer, B., Willcox, K.: Projection-based model reduction: Formulations for physics-based machine learning. *Computers & Fluids*, 179, pp. 704–717 (2019)
33. Nakamura, S., Hashimoto, S.: Hybrid learning strategy to solve pendulum swing-up problem for real hardware. In: *IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pp. 1972–1977 (2007)
34. Ruta, D., Gabrys, B.: A framework for machine learning based on dynamic physical fields. *Natural Computing*, 8(2), pp. 219–237 (2009)
35. Zdeborová, L.: Machine learning: New tool in the box. *Nature Physics*, 13(5), pp 420–421 (2017)
36. Zhou, J., Huang, B., Yan, Z., Bünzli, J.C.G.: Emerging role of machine learning in light-matter interaction. *Light: Science & Applications*, pp. 1–7 (2019)
37. D’Agnolo, R.T., Wulzer, A.: Learning new physics from a machine. *Physical Review D*, 99(1), 015014 (2019)
38. Collins, J., Howe, K., Nachman, B.: Anomaly detection for resonant new physics with machine learning. *Physical review letters*, 121(24), 241803 (2018)
39. Oviedo, F., Ren, Z., Sun, S., Settens, C., Liu, Z., Hartono, N.T.P.: Fast and interpretable classification of small X-ray diffraction datasets using data augmentation and deep neural networks. *Computational Materials*, 5(1), pp. 1–9 (2019)
40. Butler, K.T., Davies, D.W., Cartwright, H., Isayev, O., Walsh, A.: Machine learning for molecular and materials science. *Nature*, pp. 547–555 (2018)
41. Rosenbrock, C.W., Homer, E.R., Csányi, G., Hart, G.L.: Discovering the building blocks of atomic systems using machine learning: application to grain boundaries. *Computational Materials*, 3(1), pp. 1–7 (2017)
42. Li, A., Chen, R., Farimani, A.B., Zhang, Y.J.: Reaction diffusion system prediction based on convolutional neural network. *Scientific reports*, pp. 1–9 (2020)
43. Lattimer, B.Y., Hodges, J.L., Lattimer, A.M.: Using machine learning in physics-based simulation of fire. *Fire Safety Journal*, 102991 (2020)
44. El Naqa, I., Murphy, M.J.: What is machine learning? In: *machine learning in radiation oncology*. Springer, pp. 3–11 (2015)
45. Zhu, X., Ge, Y., Li, T., Thongphiew, D., Yin, F.F., Wu, Q. J.: A planning quality evaluation tool for prostate adaptive IMRT based on machine learning. *Medical physics*, 38(2), pp. 719–726 (2011)
46. Grazzini, F., Craig, G.C., Keil, C., Antolini, G., Pavan, V.: Extreme precipitation events over northern Italy. Part I: A systematic classification with machine-learning techniques. *Quarterly Journal of the Royal Meteorological Society*, 146(726), pp. 69–85 (2020)
47. Xu, J., Schüssler, O., Rodriguez, D.G.L., Romahn, F., Doicu, A.: A novel ozone profile shape retrieval using full-physics inverse learning machine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(12), pp. 5442–5457 (2017)

48. Hulbert, C., Rouet-Leduc, B., Johnson, P.A., Ren, C.X., Rivière, J., Bolton, D.C., Marone, C.: Similarity of fast and slow earthquakes illuminated by machine learning. *Nature Geoscience*, 12(1), pp. 69–74 (2019)
49. Ng, M.F., Zhao, J., Yan, Q., Conduit, G.J., Seh, Z.W.: Predicting the state of charge and health of batteries using data-driven machine learning. *Nature Machine Intelligence*, pp. 1–10 (2020)
50. Cheng, L., Yu, T.: A new generation of AI: A review and perspective on machine learning technologies applied to smart energy and electric power systems. *International Journal of Energy Research*, 43(6), pp. 1928–1973 (2019)
51. Alber, M., Tepole, A.B., Cannon, W.R., De, S., Dura-Bernal, S., Garikipati, K., Kuhl, E.: Integrating machine learning and multiscale modeling—perspectives, challenges, and opportunities in the biological, biomedical, and behavioral sciences. *NPJ digital medicine*, 2(1), pp. 1–11 (2019)
52. Clarivate Analytics: Journal Citation Reports Social Sciences Edition, <https://clarivate.com/webofsciencegroup/> (2018)