



RECIBE

Revista electrónica
DE COMPUTACIÓN, INFORMÁTICA, BIOMÉDICA Y ELECTRÓNICA

Índice

Computación e Informática

La Realidad Virtual como apoyo en psicoterapias para niños con autismo y/o ansiedad social: una revisión sistemática

Lilia Guiodi Gómez Sánchez, Graciela Lara López, Felipe de Jesús Orozco Luna

C1

Aplicaciones de la Inteligencia Artificial en Microbiología Agroambiental

Brayan Steven Cruz Florez, Blair Ricardo Gomez Torres, Ligia Consuelo Sanchez Leal

C2

La generación de comportamientos autónomos para ambientes virtuales basados en steering. Caso de estudio: Evacuaciones de espacios en situaciones de riesgo.

Sabino Hernández Paulino, Vianney Muños Jiménez, Marco Antonio Ramos Corchado, Adriana Herlinda Vilchis Gonzales

C3

Inteligencia Artificial en la Academia: Oportunidades y Desafíos

Fernando Wario Vazquez, Ricardo Ramírez Romero

C4

La Realidad Virtual como apoyo en psicoterapias para niños con autismo y/o ansiedad social: una revisión sistemática

Virtual Reality as a support in psychotherapies for children with autism and/or social anxiety: a systematic review

Lilia Guiodi Gómez Sánchez¹
Graciela Lara López*
Felipe de Jesús Orozco Luna¹

*Contacto correspondencia: lara_graciela@hotmail.com

¹Universidad de Guadalajara

RESUMEN

Propósito

El crecimiento de las aplicaciones de Realidad Virtual (RV) para terapias ha aumentado y se ha diversificado con el tiempo. A través de la RV, se anima a los pacientes a sumergirse en entornos virtuales para interactuar y socializar. En este artículo analizamos las terapias que aplican la RV, como estrategia que atiende necesidades de salud, para mejorar la calidad de vida del paciente en trastornos mentales como la ansiedad y el espectro autista. Además, comparamos las similitudes y diferencias de las terapias, evaluando la eficacia de la RV. Finalmente, presentamos una revisión de la RV desde un punto de vista tecnológico.

Metodología

La búsqueda bibliográfica se guió por las directrices PRISMA; criterios de elegibilidad de los estudios: año de publicación de 2014 a 2022, artículos completos y de acceso abierto. Artículos para mejorar las habilidades sociales en niños y adolescentes con autismo, así como en el abordaje de la ansiedad social en jóvenes. Criterios de exclusión: revisiones sistemáticas, metaanálisis, comorbilidad, postoperatorios y otros trastornos.

Resultados

Consideramos 14 estudios elegibles, con bajo riesgo de sesgo. El 78% de las terapias de RV se implementaron de forma inmersiva y el 85% de forma interactiva, involucrando la participación activa del usuario en entornos virtuales a través de la voz, la mirada y los movimientos corporales. Las terapias de RV para niños con TEA se centran en el desarrollo de habilidades sociales, con reconocimiento de expresiones faciales, reconocimiento de emociones, desarrollo cognitivo social y comunicación verbal y no verbal. Las terapias de RV para la ansiedad social se tratan de manera efectiva con meditación y relajación muscular progresiva.

Conclusión

La RV puede simplificar la vida de aquellos pacientes que no pueden salir de casa, debido a una enfermedad o discapacidad, permitiéndoles cumplir con las sesiones de terapia.

Palabras clave: Realidad virtual, terapias psicológicas, trastornos de ansiedad social, habilidades sociales, autismo (Trastorno del Espectro Autista (TEA)).

ABSTRACT

Purpose

The growth of Virtual Reality (VR) applications for therapies has increased and diversified over time. Through VR, patients are encouraged to immerse themselves in virtual environments to interact and socialize. In this article we analyze the therapies that apply VR, as a strategy that addresses health needs, to improve the patient's quality of life in mental disorders such as anxiety and autism spectrum. Furthermore, we compare the similarities and differences of the therapies, evaluating the efficacy of VR. Finally, we present a review of VR from a technological point of view.

Methods

The literature search was guided by PRISMA guidelines; study eligibility criteria: year of publication from 2014 to 2022, full-length and open access articles. Articles to improve social skills in children and adolescents with autism, as well as in addressing social anxiety in youth. Exclusion criteria: systematic reviews, meta-analyses, comorbidity, postoperative, and other disorders.

Results

We considered 14 eligible studies, with a low risk of bias. 78% of VR therapies were implemented immersively and 85% interactively, involving active user participation in virtual environments through voice, gaze, and body movements. VR therapies for children with ASD focus on the development of social skills, with facial expression recognition, emotion recognition, social cognitive development, and verbal and non-verbal communication. VR therapies for social anxiety are effectively treated with meditation and progressive muscle relaxation.

Conclusion

VR can simplify the lives of those patients who are unable to leave home, due to illness or disability, allowing them to comply with therapy sessions.

Keywords: Virtual reality, psychological therapies, social anxiety disorders, social skills, autism (Autism Spectrum Disorder (ASD)).

1. Introduction

In recent years, virtual Reality (VR) has grown and applications have been developed in different professional areas such as medicine, education, architecture, video games, sightseeing tours, and e-commerce, among others.

VR applications for therapies have increased and diversified over time. It has been found that physiotherapy supported by virtual reality, immerses the patient in an experience that distracts him/her from the pain and can perform the exercises, incorporating it as an analgesic, helping patients to overcome the barriers they put to perform the exercises (Phelan et al., 2021).

Psychotherapies cope with mental illnesses, by using VR to treat different mental disorders (Rivas et al., 2019). This is how VR effectively treats, evaluates, and diagnoses some mental disorders. Some psychotherapies transport patients to immersive and interactive virtual environments, safe and controlled by the researcher or therapist (Bell et al., 2020). VR under the development of virtual environments promotes positive stimuli, which are combined with psychological therapies, proving to be a valuable tool to improve mental health and public health (Jerdan et al., 2018).

VR simplifies the lives of homebound patients by delivering therapies in a self-guided manner, without a therapist, using avatars to instruct the patient. The therapies incorporate applied computational sciences such as dynamic video technology, machine learning optimization algorithms, biometrics, and programming (Zainal et al., 2021). The objectives of this research are: Compare virtual therapies by category and review intervention methods (traditional therapy vs virtual therapy). To analyze the effectiveness of therapies for anxiety, and autism disorders. Also, present a review of VR from a technological perspective, showing a comparative table of both software and hardware implemented to support each of the disorders studied.

Method

In the systematic review by PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) guidelines (citation), the searches were in PubMed, Web of Science, Springer Link, and Science of direct. The terms searched:

- a. (social skills) AND (virtual reality in children with autism)
- b. (((recognition of emotions) AND (facial expressions)) AND (virtual reality)) AND (children with autism)
- c. ((virtual reality) AND (psychological therapies)) AND (patients with anxiety)
- d. (Virtual reality) AND (therapies for patients with social Anxiety disorders)

For the development of this article, bibliographic searches of articles published from 2014 to September 2022 were performed.

Eligibility criteria

The selection process of publications was based on studies dedicated to psychotherapies with virtual reality in patients with mental disorders of autism and anxiety. Primarily articles to improve social skills, and emotional recognition in children and adolescents with autism. As well as articles to treat, social anxiety. We considered the summary of articles corresponding to the topics addressed in this review, especially open access articles that show the method, design, implementation, and results.

Exclusion criteria

Studies outside the 8-year range, systematic reviews, meta-analyses, studies with augmented reality and mixed reality were excluded. Also, those that included comorbidity, postoperative, addictions, psychosis, and therapies for adults with autism. Some subtypes of mental disorders such as fear of flying, stress, and obsessive-compulsive disorder.

The selection is shown in Fig. 1 by mental disorder. The search for autism yielded 2502 articles; after automation and elimination of duplicates, 130 articles remained; applying the screening criteria, 8 were selected (see Fig. 1 (a)). For screening, studies should not be combined with other diseases or other types of mental disorders or medication treatments. These aspects applied to all disorders. For social anxiety disorder, the searches yielded 8465 studies; after automation and removal of duplicates, 121 studies remained. After the screening, 6 studies for social anxiety (see Fig. 1 (b)).

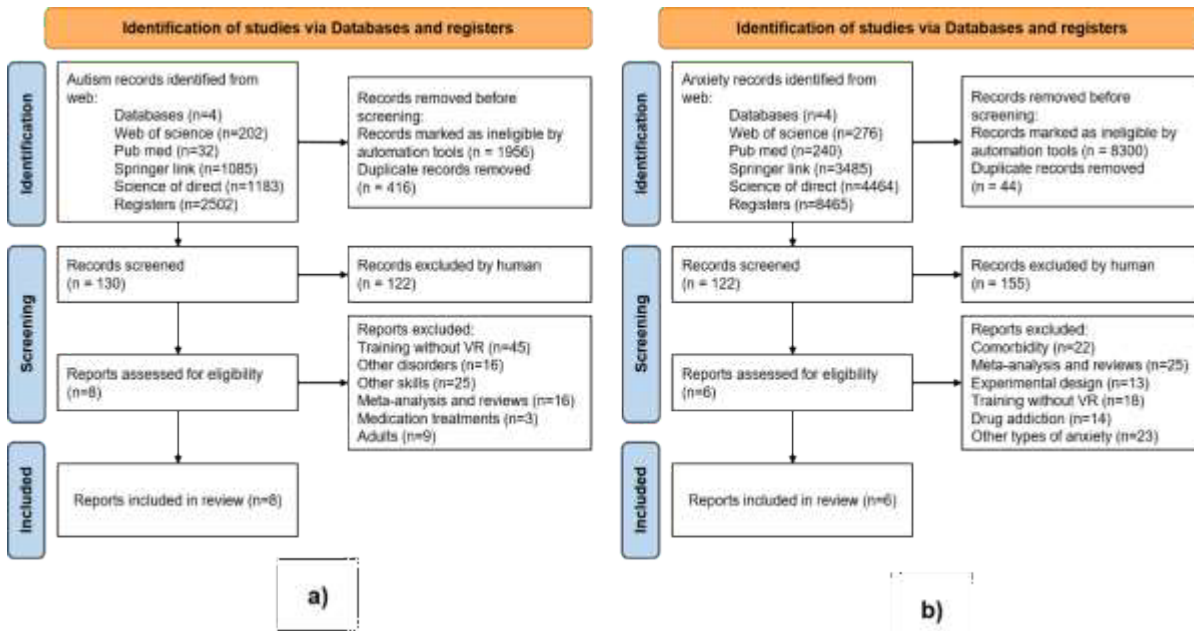


Figure 1. PRISMA Flow Diagram of Study Selection Process, (a) autism, (b) anxiety

Risk of bias and quality Assessment

The Cochrane risk of bias assessment tool was selected to assess the methodological quality of the included studies. The tool was selected according to the methods recommended by the Cochrane Collaboration (Higgins, 2011). The following judgments were used: low risk, high risk, or unclear (either lack of information or uncertainty about the potential for bias). For the assessment of the risk of bias and methodological quality of included studies, the parameters assessed were random sequence generation, allocation concealment, blinding of participants and staff, blinding of outcome assessment, incomplete outcome data, selective reporting, and other biases (see Fig. 2).

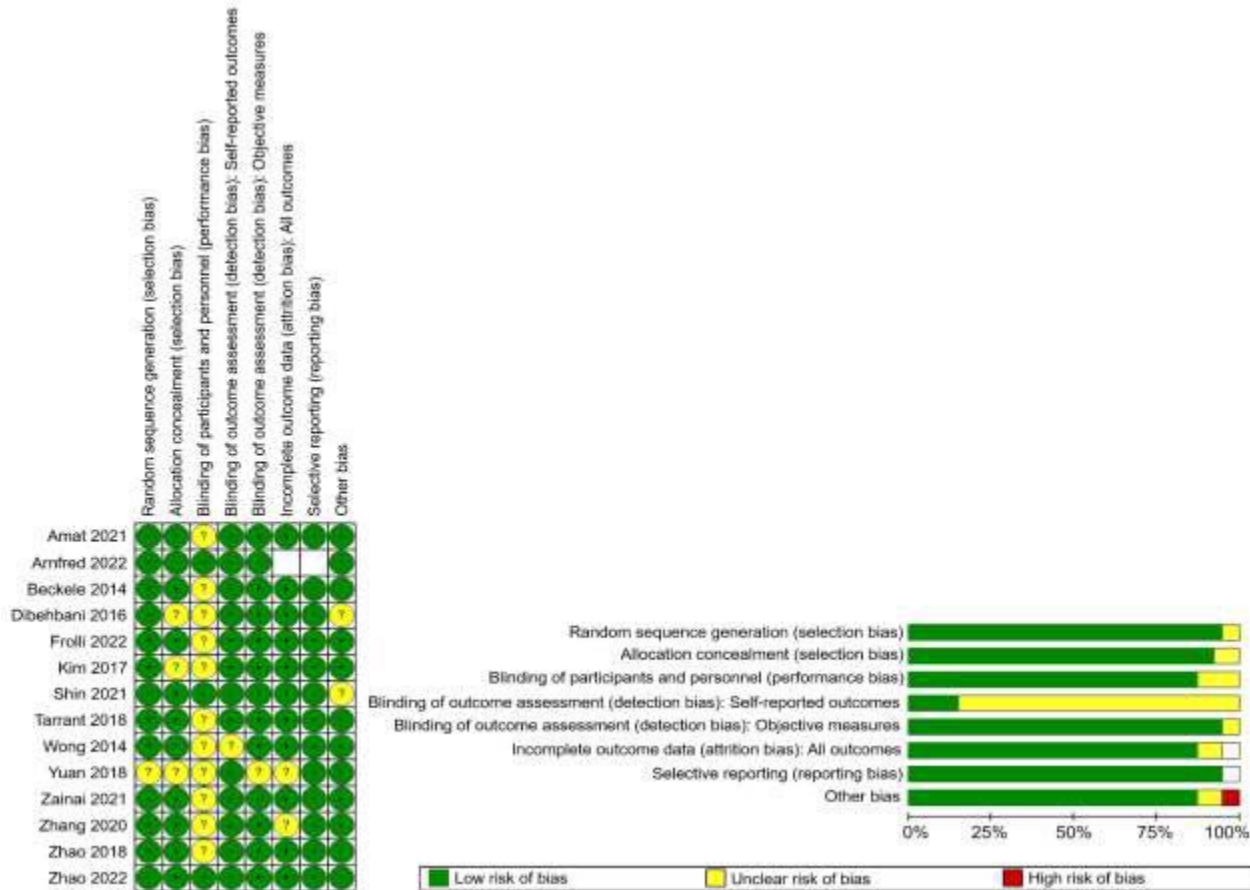


Figure 2. Risk of bias in individual studies

2. Background on autism and anxiety

Within the background: autism has grown over the years, in 2000 one for every 150 children was detected, and in 2018 one for every 44 children. It is four times more frequent in boys than in girls (CDC, 2023). Autism is a neurodevelopmental disorder that globally affects the individual's higher brain functions, such as intelligence, language ability, and social interaction (Mulas et al., 2010).

In recent years, anxiety and depression have become prevalent worldwide. According to figures from the World Health Organization (WHO), it increased by 25% due to the Covid-19 pandemic. At the same time, in 2019, the number of patients suffering from anxiety was approximately 301 million people. This disease is characterized by excessive fear and worry (WHO, 2022).

2.1. Traditional therapies for the management of autism and anxiety

For the management of these disorders, traditional therapies are diverse and help to improve the patient's conditions. The following are the most commonly used:

a) Therapies for children with autism (Autism Spectrum Disorder ASD), behavior management therapy, consists of reinforcing desired behaviors and reducing undesired behaviors; Cognitive behavioral therapy, focused on the link between thoughts, feelings, and behaviors; Early intervention, is performed between two and four years; Educational therapies, develop communication in classes; Therapies to improve joint attention, develop attention such as following a person's gaze or looking at something; Social skills development training, improve interaction with others; Speech and language therapy, improve communication skills and interaction with others; Social cognition training, help in understanding the emotions and intentions of others and act accordingly (NICHD, 2021); Social stories, is a technique of teaching social behavior, how a person should act at a certain time (Gray, 1993).

b) Therapies for anxiety management: Cognitive Behavioral Therapy (CBT) is an effective psychological treatment for anxiety disorders, depression, and severe mental illness. CBT treatment involves changing thinking patterns such as: improving understanding of behavior, using problem-solving skills, learning to develop confidence, and learning to recognize distortions in thinking. CBT strategies include coping with fears, role-playing, learning to calm the mind and relax the body. CBT includes exposure therapy, which consists of exposing the patient to objects or situations they fear, gradually, to confront patients with situations that help them to control fear, negative feelings, and thoughts (Beck, 2011).

2.2. Software, hardware for virtual reality, and other technologies

Psychological therapies appreciate virtual reality as a support tool. VR is defined as a computer-generated virtual environment where the user experiences and interacts in places that mimic the real world. In the virtual environment, sensory stimuli are experienced with scenarios, sounds, images, and 360-degree videos. Complementing the above, 360-degree videos immerse the viewer in complete scenes, to explore and view the video from different angles. Like 360-degree images, they contain the entire scene, unlike a photograph, which must be taken several times.

Continuing with psychological therapies with VR, virtual environments such as a room, supermarket, elevator, farm, or objects are recreated. For this, video game engines are required, such as 3ds Max, Unreal, Stride, Godot, and Unity 3D, the latter being the most widely used. Psychological therapies with VR can also include immersion, an example being 360-degree videos. The immersion consists of involving users in a new experience, immersing the viewer in an almost real world, it is the illusion of being present in a virtual environment; hardware devices are required for an immersive experience, oculus go, oculus rift, oculus quest, HTC Vive, HTC Vive Pro, that include manual controls, except VR glasses for Smartphone, it is only a viewer that requires a mobile phone.

In contrast, a non-immersive experience is viewed on the computer screen without head-mounted glasses. Some VR psychotherapies require devices that record movements and use Tobi-eye for eye tracking and leap motion for hand movement detection. In addition, VR therapies can be complemented by other technologies, in particular artificial intelligence (AI), the ability of machines, or systems, to learn from data through algorithms and apply what they learn. Applications of AI include computer vision for object detection and video and image analysis. The OpenCV library contains hundreds of useful algorithms for facial expression recognition, object tracking, and so on.

Another application of AI is natural language processing (NLP) so that the system understands text and speech as humans do. VR therapies require the system to interpret, recognize, and analyze text and voice. For example, Google's Speech-to-Text tool converts speech into text.

The avatars guide the development of the therapy and are programmed with finite-state machines, which detect events that are converted into actions performed by the avatar. They can also include intelligent agents modeled with AI algorithms to respond to the needs of the application and can process and interpret information from the environment. A further tool for VR therapies is EyeMMV (Eye Movements Metrics & Visualizations), which is used for eye movement observation, visualization techniques, supports eye tracking metrics and is very useful in therapies for children with autism.

Given this preamble, the formal structure of this paper is described below: Section two describes VR psychotherapies for ASD. Section three presents VR psychotherapies for anxiety disorders. At the end of this section we describe the characteristics of the therapies addressed in summary form within a set of tables. Likewise, we presented the similarities and differences of VR psychotherapies from a technological perspective are discussed, as well as the form of implementation (immersive or non-immersive). Within these tables, it is verified whether they integrate traditional psychotherapies into the therapeutic plan or not and whether they work with the support of therapists. The results of each study are compared to verify the effectiveness of the therapies and finally, the inclusion of other applied computer sciences in support of these therapies is reviewed. Section four presents the discussion and section five describes the conclusions.

3. Virtual therapies in patients with Autism Spectrum Disorder (ASD)

Following is a description of selected works that employ psychotherapies with Virtual Reality applications in support of patients with Autism Spectrum Disorder.

Bekele et al., (2014) focus their study on adolescents with ASD, mentioning that one of the deficiencies of this disease is recognizing non-verbal communication and recognizing facial expressions. In their study, they teach adolescents to recognize facial expressions, supported by avatars in simulated situations in virtual environments. The project contains seven avatars: four males and three females with the physical characteristics of teenagers. The facial expressions used are joy, surprise, contempt, sadness, fear, disgust, and anger. Each expression has four levels of emotional intensity (low, medium, high, and extreme). They examined glances between facial and non-facial regions using an eye tracker and also analyzed the time spent on emotion displays in the forehead, eyes, and mouth. Heat maps of facial expressions were used to assess differences between groups of adolescents with and without ASD. This study can help not only in recognizing facial emotions but also in the way children with ASD recognize emotions.

Children with ASD struggle with social skills, so Didehbani et al., (2016) safely address this issue, with virtual reality social cognition training (VR-SCT). The scenarios are adjusted to different complexities, depending on the age of the participant. Patients have personalized avatar that closely resembles them and their doctors. Doctors take on various roles within virtual environments, including a voice modifier, with which they change their voice to a child, woman, or man. The lifelike virtual scenarios are used to train social cognition, ranging from a school classroom, school canteen, playground, campground, racetrack, fast food restaurant, technology shop, and one department. Patients in the sessions deal with different scenarios in which they confront conflicts, deal with a bully, bond with friends, meet new people, and handle social dilemmas. To learn in different contexts and to train social skills such as initiating a conversation, knowing their emotions, collaborating with others, making decisions, developing social relationships, and self-affirmation.

A further study is presented by Yuan and Ip (2018), they focus on practicing the skills repeatedly, the virtual environment is a four-sided cave, which allows interaction with objects and avatars. The psychotherapy comprises six scenarios: one relaxation, four training, and one consolidation scenario. These scenarios are controllable, and safe, in a typical Hong Kong primary school environment. During the session, patients are guided and supported by a trainer, and at the end of the training, the children improved their emotional expression and regulation, as well as social interaction. This type of VR-based intervention is a valuable complement to traditional therapies for children with ASD, resulting in improvements in emotional understanding, social communication and adaptive behaviors.

Promoting real-time interaction and verbal communication between players through gameplay was the objective of the study presented by Zhao et al., (2018). Its design is engaging, easy to learn, and interactive and each game has a time limit. VR therapy forced both players to communicate and work collaboratively, to virtually move the same object, they must control the direction of the movements, without the help of a player, the piece can neither be chosen nor moved. The authors implement the client-server architecture, to play in real time on different computers. It requires a tracker that detects eye movements (Tobii eyeX), and a controller to detect players' hand movements and gestures in front of the screen (Leap motion). At the end of the study the children with ASD improved their social, communication and joint attention skills. This therapy provided a safe and comfortable environment for children with ASD.

Another way to speak about communication and social collaboration challenges in children with ASD is Creta, an intelligent agent that interacts in a collaborative virtual environment (CVE). In this project, communication and collaboration skills are monitored and indexed. Creta has two modes of human-human interaction (HHI) and human-intelligent agent interaction (HAI). Creta in HHI mode monitors the interaction of two patients, evaluates communication and collaboration. Creta in HAI mode, the patient plays with the intelligent agent and evaluates the performance of the patient's collaboration and communication skills. The project uses a finite state machine for the intelligent agent's cues, in addition, two machine learning models were built, the first one measured communication skills and the second one measured collaboration skills (Zhang et al., 2020).

On the other hand, to improve basic attention skills as following and sharing glances in children with ASD, InViRS was created, containing an algorithm that detects eye contact in real-time, an algorithm for adjusting the difficulty of the task, and an avatar controller that coordinates in real-time. All this is for joint and individualized closed-loop attention. VR psychotherapy manages the difficulty based on gaze data, game states, and avatar states. In addition, it contains two games, in the first game the player has to pop bubbles by looking at them, and in the second game the player has to put together a puzzle, the child looks at the piece, and it is highlighted with a color and moves the object with the mouse. If the participant does not look at the piece, the avatar is activated with

assistance events, so that the child focuses and completes the task. InViRS significantly improved the time to complete the game and response time in children with ASD (Amat et al., 2021).

Another more recent study was conducted in Rome, which was used for emotional literacy in children with ASD, using two different methods: the first with traditional therapy by a therapist and the second with VR support. There were two groups: the first used emotional literacy with VR (VRI) and the second used individual intervention with a therapist (IIT individual intervention with a therapist). The first group used 3D projections, worked with scenes for the recognition of primary emotions (PE) and secondary emotions (SE). Then they worked on situations with both primary emotions (ESPE) and secondary emotions (ESSE). The second group, working with 76 photographs using traditional therapy, aimed at emotional literacy. Like the first group, they first worked with primary and secondary emotions. Then they worked with primary and secondary situations and emotions by randomly presenting the photographs. Both groups did the same time for emotion recognition, but the VR group was faster in using primary and secondary emotions (Frolli et al., 2022).

Finally, Zhao et al., (2022) developed a study comprising two groups: a VR intervention group and a control group. In the control group, they conducted the following three conventional training sessions with a duration of 40-45 minutes each: the first training is about a group class, where the therapist gives oral instructions to the children and offered reinforcement if the child did not respond. The second training is about sensory integration, where the children develop gross motor skills. And the third training is to develop fine motor skills. The VR intervention group, besides including conventional training, contains six scenes developed with virtual environments: looking for things, a garden, forest animals, crossing the river, identifying vegetables, and selling vegetables. This experiment aims to focus on cognitive understanding, social imitation, gross motor skills, emotional expression, and language of children with ASD in an immersive, fun way, proving to be better than the control group only in the area of cognition and social interaction.

4. Virtual therapies for patients with Anxiety disorders

Anxiety disorder is characterized by excessive fear and worry. The types of anxiety are panic disorder, phobias, social anxiety, agoraphobia, and separation anxiety (WHO, 2022). Next, is a description of selected works that employ psychotherapies with Virtual Reality applications in support of patients with Anxiety disorders.

Wong et al., (2014) developed a study to treat social anxiety in preadolescent children. It is an interactive, but non-immersive school-based environment where children interact with virtual avatars (teachers, principal, and peers), the virtual settings are classroom, hallways, and gymnasium. The program contains four social skills, initiating conversation, maintaining conversation, giving and receiving compliments. Each skill has 3 levels of difficulty. The therapist has the power to control the direction, pace, and level of difficulty. This software is used at home with brief, repeated interactions, three times per week. In addition to the weekly clinic session.

Kim et al., (2017) developed a VR application, which uses mobile devices for the treatment of social anxiety. The therapy is performed by the patient, from the comfort of their home with the help of avatars that inform and introduce the patient during the training sessions. The heart rate is taken during the VR training, they analyze the percentage change in the listening and speaking phase. The psychotherapy addresses social situations with virtual environments simulating school, business, and everyday life, with levels of difficulty increasing as they progress. Results showed that it is beneficial in reducing anxiety and improving social interaction skills in patients with social anxiety.

Tarrant et al., (2018) presented a system using VR therapy for anxiety management. They analyzed Alpha and Beta brain waves, which were recorded with an encephalographic study (EEG). The results obtained from the EEG were analyzed with sIoreta (low-resolution electromagnetic tomography), in the regions of interest (ROI) which were: the posterior cingulate cortex (PCC) and anterior cingulate cortex (ACC) associated with cognitive and emotional processing. The patterns associated with anxiety and stress are Beta waves (increase) and Alpha waves (decrease). Therefore, a decrease in Beta frequency and an increase in Alpha waves are consistent with reduced anxiety and stress. During the study, they performed three measurements, in both groups (control and intervention VR). For the meditation in the VR group, they used 360-degree videos with a duration of 5 minutes, accompanied by piano and violin music. The viewer was voice-guided to mindfulness meditation. After the meditation, the Alpha and Beta waves changed validating the decrease in anxiety.

On the other hand, virtual reality exposure (VRE) therapies for social anxiety have been effective, and regulated by therapists, but this therapy works in a self-guided manner without a therapist. For the VRE training, two scenes, a formal job interview, and an informal dinner, were created with dynamic video technology, driven by machine learning optimization algorithms, biometrics, and programming. The videos could be operated with a tablet enabled to detect head movements and voice. The virtual therapist guides the patient through the scene, repeating instructions if the patient does not respond within 5 seconds. The virtual dinner environment covered the four domains of social fear: fear of assertiveness, fear of intimacy, observation anxiety, and performance anxiety. By performing this self-directed VRE treatment patients did not feel policed, which helps to build confidence, to tolerate, and consequently decrease their symptoms. The audio instructions allowed patients to perform the exercises without difficulty (Zainal et al., 2021).

To treat panic disorder, self-guided virtual therapy is supported by cognitive behavioral therapy. VR treatment exposed patients to feared situations gradually. In this context, Shin et al., (2021), carried out a study that contains an avatar as a virtual therapist that teaches patients progressive muscle relaxation and breathing. The patients were exposed to various situations in virtual environments guided by the avatar such as driving a car, taking an elevator, getting on a plane. Each virtual environment has different exposure levels and different virtual-guided and unguided modalities. The VR intervention was effective in treating panic symptoms and restoring the autonomic nervous system.

Another study for patients with social anxiety and agoraphobia was presented by Arnfred et al., (2022). They compared live cognitive behavioral group therapy (CBT-in vivo) vs. cognitive behavioral group therapy with virtual reality exposure (CBT-in virtuo) for mixed anxiety, showing very good results among the participants. They developed 13 virtual scenarios: supermarket queue, crowded shopping mall, attending a party, formal meeting and making a presentation, job interview, small talk, debating in a canteen, entering an auditorium, leaving your department, waiting and taking the bus, crossing a bridge, taking the lift, taking a commercial airliner, each having four to six levels of difficulty.

In summary, Table 1 presents the characteristics of the VR treatment plan of the articles reviewed for autism spectrum disorders.

Authors	Metrics, variables, scales, and tests used	Sample size	Duration of study	Traditional therapy	Therapy applied with VR	Study results	Limitations of the study
Bekele et al., (2014)	ADOS SB WISC WASI	20 participants 10 with ASD and 10 without ASD Aged 13-17 years old	One hour session	Social skills development training	Developing non-verbal communication with VR	SA system is capable of making changes, in emotion recognition and in the way emotions are recognized Children with ASD were slower in their responses than children without ASD	Small sample size Refine the stimuli and further develop the VR-programmed
Didehbani et al., (2016)	WASI NEPSY-II AR Ekman60 Triangles	30 children Aged 13-16 years old	5 weeks with 10 one-hour sessions	Social Cognition Training	VR Social Cognition Training (VR-SCT)	Improved social cognitive skills, as well as emotion recognition, social attribution and logical reasoning	Small sample size No VR vs. non-VR comparison group No real-time display of avatar emotions
Yuan & Ip., (2018)	PEP-3 (using 10 subtests, 6 measure developmental skills, and 4 measure maladaptive behaviors)	94 children	Unknown	Social stories	Social Stories in CAVE (cave Assisted Virtual Environment)	Determined the competencies of each child and improved the expression and regulation of emotions, as well as social interaction in	CAVE is expensive to develop and maintain, requires a large space, is fixed, and cannot be moved to other institutions

						children with autism	
Zhao et al., (2018) SRC	SRC Complete pieces (/minute) Cooperative Efficiency (%) Total play time (S) Back-and-forth Sentences (/per minute) Words count of one player (/minute)	12 groups: one child with ASD and one child without ASD	Unknown	Social skills development training	Interactive and collaborative games that detect eye, hand, and gesture movements	Improved game cooperation and communication by sharing information and discussing game strategies	Small sample size No haptic interface
Zhang et al., (2020)	SRS-2 ADOS IQ SCQ Success Frequency Failure frequency Dragging time Collaboration time	40 participants: 20 with ASD and 20 without ASD	40 minutes sessions with a 10 minutes break between each game	Behavioral therapy	Collaborative virtual environments with distributed systems for two players interacting with each other remotely	Moderate to high improvement in communication and collaboration skills	Limited to certain interactions and relatively small in size
Amat et al., (2021)	ADOS SCQ SRS-2 Score Time to complete(seconds) Responsive time (seconds) Fixation point Ratio of gaze Fixation on the eye to gaze Fixation on other facial features	18 children 9 children with ASD and 9 children without ASD Aged 7-13 years old	three sessions, with 5 to 10 days between visits	Therapy to improve joint attention	VR therapies focused on building joint attention skills	Improved performance with higher scores and shorter response time. Improved gaze communication	Relatively small sample size
Frolli et al., (2022)	VCI PRI WMI PSI	60 people were randomly divided into	Three times a week, for 3 months	Emotional Literacy Psychotherapy	Emotional Literacy Psychotherapy with Virtual	Helps to recognize emotions from facial expressions and basic and	Not tested with different levels of autism

	QIT ADOS-2	two groups			Reality (VRI)	complex social skills. Emotion and situation recognition for primary and secondary emotions	Does not assess the maintenance of acquired skills in the medium and long term
Zhao et al., (2022)	PEP-3 Cognitive Language comprehension Gross motor Mimicry Social Interaction Emotional expression	47 children were divided into groups: VR intervention and control. Aged 3-5 years old	Three times a week for 12 weeks	Cognitive behavioral therapy and social skills training	VR therapies for training: cognitive, emotional, gross motor, imitation, language understanding	Effectively promotes cognitive and social communication skills	No training guide to guide and support children in the virtual environment

Table 1. VR therapies for autism spectrum disorder

Note. ADOS = Autism diagnostic observation Schedule, ADOS-2 = Autism Diagnostic Observation Schedule, Ekman60 = Facial Expressions of Emotion Stimuli and Test, IQ = Intelligence Quotient, NEPSY-II AR = Second edition-facial affect recognition, PEP-3 = Psychoeducational Profile, PRI = Visual perceptual reasoning index, PSI = processing speed index, QIT = intelligence quotient total, SB = Stanford Bitnet, SCQ = Social Communication Questionnaire Lifetime, SRC = Social Responsiveness Scale, SRS-2 = Social Responsiveness Scale, Second Edition, Triangles = Social Attribution Task, VCI = verbal conversion index, WASI = Wechsler Abbreviated Scale of Intelligence, WISC = Wechsler Intelligence Scale for Children, WMI = working memory index.

Below, the characteristics of the VR therapeutic plan of the reviewed articles for anxiety disorders are presented (see Table 2).

Authors	Metrics, variables, scales, and tests used	Sample size	Duration of study	Traditional therapy	Therapy applied with VR	Study results	Limitations of the study
Wong et al., (2014)	ADIS-C/P DSM-IV Charleston Outpatient	11 child aged 8-12 years	Unknown	Social Effectiveness Therapy for Children, peer sessions	Provided children with intensive, customizable and flexible social skills practice therapy	Difficulties in video camera monitoring	Unknown
Kim et al., (2017)	MINI HADS LSAS	52 participants	four weeks, 12 sessions in total, duration	Cognitive behavioral therapy	Application of VR for exposure therapy	VR application was beneficial in reducing anxiety and improving social	Unknown

			15-30 minutes per module	Exposure therapy		interaction skills.	
Tarrant et al., (2018)	GAD-7 sLoreta	26 participants in two groups: VR and control	One session	Meditation therapy	Mindfulness-in-nature VR intervention	Virtual therapy helped to reduce anxiety and hyperexcitability Both groups increased alpha power	Small sample and only one session
Zainal et al., (2021)	MINI SPDQ SIAS MASI PHQ-9 PSWQ IPQ SUDS	44 participants Aged 19-69 years old	8 sessions	Group Exposure Therapy (EGT)	Self-directed Virtual Reality Exposure Therapy (VRE)	VRE was clinically effective in reducing fears of public speaking	Unknown
Shin et al., (2021) PDSS	PDSS, HRSD, BSQ, APPQ, ASI, STAI, HADS, k-SADS	54 patients in two groups: VR and traditional therapy Aged 19-60 years	Duration 4 weeks, 3 times per week, 12 sessions in total	Cognitive Behavioral Therapy (CBT) (including education about dysfunctional thoughts, cognitive restructuring, breathing re-education, and applied relaxation)	Self-directed VR CBT	The VR group showed significant improvements in psychological distress, concerning panic, anxiety, and depression Decreased heart rate and a balanced autonomic nervous system	High dropout rate Heart rate was not measured in low anxiety states
Arnfred et al., (2022)	LSAS, MIA, POMP, MINI, DSM-5, HAM-6, FNES, WSAS, CSQ, WHO-5, PSP, TLFB, WAI, SSQ	302 participants were divided into two groups: CBT-in vivo and CBT-in virtual Aged 18-75 years	14 two-hour sessions of group therapy, with 8 sessions of in-virtual exposure	Cognitive Behavioral Therapy with exposure therapy, using CBT-in vivo	Cognitive Behavioral Therapy with exposure therapy with virtual reality CBT in virtual	The study is still in progress	No interaction in the virtual environment, immersive 360-degree videos Therapy has not been investigated

							with two different disorders in the same group (agoraphobia and social anxiety)
--	--	--	--	--	--	--	---

Table 2. VR therapies for anxiety disorders

Note. ADIS-C/P = anxiety disorders interview schedule for DSM-IV, APPQ = Albany Panic and Phobia Questionnaire, ASI = Anxiety Sensitivity Index, BSQ = Body Sensations Questionnaire, CSQ = Client Satisfaction Questionnaire, DSM-IV = Diagnostic and Statistical Manual of Mental Disorders, DSM-5 = Diagnostic and Statistical Manual of Mental Disorders, FNES = Fear of Negative Evaluation Scale, GAD-7 = Generalized Anxiety Disorder 7-item scale, HADS = Hospital Anxiety and Depression Scale, HAM-6 = Hamilton Depression Rating Scale, 6, HRSD = Hamilton Rating Scale for Depression, IPQ = I group presence questionnaire, k-SADS = Korean Inventory of Social Avoidance and Distress Scale, LSAS = Liebowitz Social Anxiety Scale, MASl = Measure of Anxiety in Selection Interviews, MIA = Mobility Inventory for Agoraphobia, MINI = Mini International Neuropsychiatric, PDSS = Panic Disorder Severity Scale, PHQ-9 = Patient Health Questionnaire, POMP = Percentage maximum possible, PSP = Personal and Social Performance Scale, PSWQ = Penn State Worry Questionnaire, SIAS = Social Interaction Anxiety Scale, sLoreta = low-resolution electromagnetic, SPDQ = Social Phobia Diagnostic Questionnaire, SSQ = Simulator Sickness Questionnaire, STAI = State-Trait Anxiety Inventory, SUDS = Subjective Units of Distress Scale, TLFB = timeline, follow back, WAI = Working Alliance Inventory, WHO-5 = WHO Well-Being Index, five items, WSAS = Work and Social Adjustment Scale.

A comparative summary is shown in Table 3 of the technologies used in each of the psychotherapies reviewed. Among the data presented are the author and year of publication, application of Virtual Reality, other technologies implemented, software and hardware used during VR therapy (see Table 3).

Autism spectrum disorders				
Author and year	Application of Virtual Reality	Other technologies implemented	Software	Hardware
Bekele et al., (2014)	Interactive	Head maps and masked scene maps Avatars	Unity 3d Maya	Tobi-eye x120 eye tracker Desktop computer
Didehbani et al., (2016)	Interactive	Morph Vox (voice transformer) Avatars	Second life with 3d designs	Computer, keyboard, mouse
Yuan and Ip. (2018)	Immersive and interactive	Interactive cave with virtual reality	Unknown	Head-mounted goggles
Zhao et al., (2018)	Interactive	Distributed systems Skype Intelligent agent	Unity 3d	Tobii-eye x, Camera, headsets, Leap Motion

Zhang et al., (2020)	Interactive	Intelligent agent Natural language processing Machine learning Finite state machine	Natural language processing and machine learning technologies Speech recognition software (Google Cloud Speech API)	Microphone, headset, cameras
Amat et al., (2021)	Interactive	Finite State Machine (FMS) Matlab with the EyeMMV toolbox Avatars	Unity Autodesk Maya	Tobii eyeX and Hearing aids
Frolli et al., (2022)	Immersive	3d photographs Statistical software spss 26	3D videos	3D VR viewer
Zhao et al., (2022)	Immersive and interactive	Statistical software spss 25	Unity 3d	VR Glasses
Anxiety disorders				
Author and year	Application of Virtual Reality	Other technologies implemented	Software	Hardware
Wong et al., 2014	Interactive immersive	Avatars	Virtual Reality Video Games by Virtually Better, Inc.	Computer, camera, usb
Kim et al., (2017)	Immersive and interactive	Avatars	Unity 3D 3d s Max 2014	Galaxy s6 phone Samsung Gear S2 Insta360 pro
Tarrant et al., (2018)	Immersive	Algorithm sLoreta (low-resolution tomography analysis) Electroencephalogram (EEG) BrainAvatar software Qeeg.pro (website for the service: reports)	360-degree photography and video by storyUP VR	Samsung Gear VR Smartphone Samsung Android s7 BrainMaster Discovery
Zainal et al., (2021)	Immersive interactive	Machine learning optimization algorithms, biometrics, and programming	360-degree videos Worked with companies: Beha VR and Limbix	pico goblin VR headset
Shin et al., (2021)	Immersive interactive	Arterial SA-3000P	3ds max 2014 Unity 3D	Camera insta360 Samsung phone Samsung Gear VR
Arnfred et al., (2022)	Immersive and interactive	Not mentioned	360-degree videos	Oculus go Headset

Table 3 Technologies Applied in VR Psychotherapies

5. Discussion

Among the findings found in this review, it is worth highlighting that of all the studies reviewed, 78% of VR therapies were implemented immersive, and 85% were implemented interactively, involving active user participation in virtual environments using voice, gaze, and body movements.

The challenges faced by children with ASD can be effectively addressed by VR therapies, which focus on building social skills, facial expression recognition, emotion recognition, social cognitive development, and verbal and non-verbal communication. 87% of VR therapies for autism were interactive, and developed through fun, enjoyable, and safe play. 38% of these therapies were implemented in an immersive way, while the remaining 62% were not, using desktop computers, devices that detect the movement of the hands in front of the screen (leap motion), and eye-tracking devices (Tobii-eye). In this way, they avoid the problems caused by immersion, such as dizziness, imbalance, and nausea. They also prevent the adjustment of controls in the hands of young children.

Technologies that helped to complement the intervention plan for children with ASD were: speech recognition with natural language processing, speech transformer, client-server architecture, and distributed systems to work collaboratively on different computers. They also used Skype and Zoom to maintain real-time communication. In addition, they used Machine Learning intelligent agents or avatars to guide the children in their therapy. Unlike therapies for children with ADS, the VR therapies for treating anxiety were 100% immersive and focused on young people and adults. 83% were interactive, with patients facing feared situations and interacting safely in virtual environments.

Anxiety is treated in different ways because there are different types, for example, Kim et al., (2017) treated social anxiety patients with virtual scenarios to face different situations from home. Tarrant et al., (2018) used meditation through 360-degree videos to reduce anxiety levels, monitored with brainwave recording. While Zainal et al., (2021) was without therapist supervision (self-guided), this helped to build patient confidence and reduce anxiety symptoms. Arnfred et al., (2022) used VR group therapies with 360-degree videos to treat anxiety. Shin et al., (2021) treated panic disorder, with progressive muscle relaxation, breathing to lessen and control symptoms, with the guidance of avatars.

The technologies implemented in the anxiety therapies were diverse, ranging from virtual environments with Avatars, 360-degree photography and video, tomography reading and analysis for regions of interest, web page for sloreta reports (Qeeg.pro), machine learning optimization algorithms, biometrics and programming.

The similarity between the studies includes teams of medical specialists, therapists, VR app developers, and incorporates traditional therapies applied for decades in the treatment of psychological disorders. The requirements considered in the design of the VR applications were: the patient's condition, safety, situation tolerance, usability, duration and level of difficulty, and above all co-morbidity. Those involved in the study contributed ideas, performed tests and adjustments together with the medical team, to ensure usability and patient safety. Some studies conducted comparative studies, dividing participants into groups of traditional vs. VR psychotherapies.

VR was complemented by Artificial Intelligence and its branches, Machine Learning with speech recognition algorithms for training intelligent agents, computer vision that implements algorithms for object detection, gaze, and facial feature classification, as well as intelligent agents and avatars. The VR psychotherapies that have been most enriched by these technologies are those of ASD.

VR psychotherapies should be implemented as a support tool that innovates in the way therapies are taken, without replacing the drugs that the patient is taking, as well as the face-to-face monitoring and follow-up visits with the therapist. The ideal is to include intelligent agents to guide and instruct the patient during VR therapy from home, without the supervision of the therapist.

6. Conclusions

VR in the field of psychology is positioning itself as a support tool in remote psychotherapy, where the patient feels comfortable and is motivated by avatars or intelligent agents to advance in their treatment. This is especially valuable for those who have difficulty accessing traditional therapy due to distances or physical limitations.

With VR it is possible to provide a controlled and safe environment for patients to confront and work through their problems. This has been useful for the disorders analyzed in this study such as anxiety, and autism. Disorders that in the real world can trigger situations that are difficult to expose and treat.

It is important to mention that early detection of ASD is crucial to improve its development; there are several subtypes of autism so each child requires different treatments. Virtual reality therapies focus on improving social, communicative, and cognitive skills, which improve the quality of life of the child and his family. These VR therapies show relevant support at this stage, predominantly interactive activities in creative, eye-catching, safely designed virtual environments, which lead children in a fun way to improve their development. Most of these therapies incorporate games, facilitating and motivating their implementation. However, immersive studies in children with ASD are few due to concerns such as motion sickness and lack of adaptation of the equipment to the anatomy of young children.

It is worth mentioning that, although these issues were addressed separately, there is a 40% probability that patients with autism develop social anxiety due to a deficit in social skills. In this context, cognitive behavioral therapies (CBT) have proven to be effective. In addition, virtual reality (VR) therapies, when applied in the treatment of social anxiety in conjunction with CBT, are effective in exposing patients to situations that they must face to overcome their condition (Kerns & Kendall (2012).

The implementation of this technology is attractive as there are different brands of head-mounted glasses that contain or install the VR application to implement therapies in an immersive way. Another option is to use devices with sensors that detect hand movements, gestures, and gazes to implement non-immersive therapies. The least expensive option is with VR goggles and a mobile phone, where the application is installed and used immersive.

Without a doubt, the COVID-19 pandemic has triggered an appreciation of physical and mental health, which has led us to look for technology-supported alternatives that allow medical treatment (telemedicine) and Virtual Reality therapies to be carried out from home. Technology allows us to enrich the alternatives that can be implemented to improve the mental health of the patient, every day more progress is being made in this area, we can see that several researchers are working on it, and are interested in supporting and reducing these mental disorders, which impact a large number of people in our society.

References

- Amat, A. Z., Zhao, H., Swanson, A., Weitlauf, A. S., Warren, Z., & Sarkar, N. (2021). Design of an interactive virtual reality system, InViRS, for joint attention practice in autistic children. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 1866-1876.
- Arnfred, B., Bang, P., Hjorthøj, C., Christensen, C. W., Moeller, K. S., Hvenegaard, M., ... & Nordentoft, M. (2022). Group cognitive behavioral therapy with virtual reality exposure versus group cognitive behavioral therapy with in vivo exposure for social anxiety disorder and agoraphobia: a protocol for a randomized clinical trial. *BMJ open*, 12(2), e051147.
- Beck, J. S. (2011). Cognitive-behavioral therapy. *Clinical textbook of addictive disorders*, 491, 474-501.
- Bekele, E., Crittendon, J., Zheng, Z., Swanson, A., Weitlauf, A., Warren, Z., & Sarkar, N. (2014). Assessing the utility of a virtual environment for enhancing facial affect recognition in adolescents with autism. *Journal of autism and developmental disorders*, 44(7), 1641-1650.
- Bell, I. H., Nicholas, J., Alvarez-Jimenez, M., Thompson, A., & Valmaggia, L. (2020). Virtual reality as a clinical tool in mental health research and practice. *Dialogues in clinical neuroscience*, 22(2), 169-177. <https://doi.org/10.31887/DCNS.2020.22.2/lvalmaggia>
- Didehbani, N., Allen, T., Kandalaf, M., Krawczyk, D., & Chapman, S. (2016). Virtual reality social cognition training for children with high functioning autism. *Computers in human behavior*, 62, 703-711., <https://doi.org/10.1016/j.chb.2016.04.033>.
- Frolli, A., Savarese, G., Di Carmine, F., Bosco, A., Saviano, E., Rega, A., ... & Ricci, M. C. (2022). Children on the autism spectrum and the use of virtual reality for supporting social skills. *Children*, 9(2), 181. <https://doi.org/10.3390/children9020181>
- Gray, C. A., & Garand, J. D. (1993). Social stories: Responses of students with autism with accurate social information. *Focus on Autistic Behavior*, 8(1), 1-10. doi: 10.1177/108835769300800101

- Jerdan S, Grindle M, van Woerden H, Kamel Boulos MN (2018). Head-Mounted Virtual Reality and Mental Health: Critical Review of Current Research. *JMIR Serious Games*, 6(3): e14 URL: <https://games.jmir.org/2018/3/e14> DOI: 10.2196/games.9226.
- Higgins JPT, Green S (editors). *Manual Cochrane para Revisiones Sistemáticas de Intervenciones*. Versión 5.1.0 [updated March 2011]. La Colaboración Cochrane, 2011. Disponible en www.cochrane-handbook.org.
- Kerns, C. M., & Kendall, P. C. (2012). The presentation and classification of anxiety in autism spectrum disorder. *Clinical Psychology: Science and Practice*, 19(4), 323.
- Kim, H. E., Hong, Y. J., Kim, M. K., Jung, Y. H., Kyeong, S., & Kim, J. J. (2017). Effectiveness of self-training using the mobile-based virtual reality program in patients with social anxiety disorder. *Computers in Human Behavior*, 73, 614-619.
- Mulas, F., Ros-Cervera, G., Millá, MG, Etchepareborda, MC, Abad, L., & Téllez de Meneses, M. (2010). Modelos de intervención en niños con autismo. *Revista de neurología*, 50 (3), 77-84.
- NICHHD (2021, 4 marzo). What treatments are there for autism? Eunice Kennedy Shriver National Institute of Child Health and Human Development. Recuperado 14 de marzo de 2023, de <https://espanol.nichd.nih.gov/salud/temas/autism/informacion/tratamientos>
- OMS, Trastornos mentales. (2022, 8 June). Organización mundial de la salud. <https://www.who.int/es/news-room/fact-sheets/detail/mental-disorders>
- Phelan, I., Furness, P.J., Matsangidou, M. et al. (2021). Playing your pain away: designing a virtual reality physical therapy for children with upper limb motor impairment. *Virtual Reality*. <https://doi.org/10.1007/s10055-021-00522-5>
- Shin, B., Oh, J., Kim, B. H., Kim, H. E., Kim, H., Kim, S., & Kim, J. J. (2021). Effectiveness of self-guided virtual Reality-based cognitive behavioral therapy for panic disorder: a randomized controlled trial. *JMIR mental health*, 8(11), e30590. <https://doi.org/10.2196/30590>
- Tarrant, J., Viczko, J., & Cope, H. (2018). Virtual reality for anxiety reduction demonstrated by quantitative EEG: a pilot study. *Frontiers in Psychology*, 9, 1280. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6066724/#B24>
- Wong S. N., Beidel, D. C., & Spitalnick, J. S. (2014). The feasibility and acceptability of virtual environments in the treatment of childhood social anxiety disorder. *Journal of Clinical Child & Adolescent Psychology*, 43(1), 63-73.
- Yuan, S. N. V., & Ip, H. H. S. (2018). Using virtual reality to train emotional and social skills in children with autism spectrum disorder. *London journal of primary care*, 10(4), 110-112. <https://doi.org/10.1080/17571472.2018.1483000>
- Zainal, N. H., Chan, W. W., Saxena, A. P., Taylor, C. B., & Newman, M. G. (2021). Pilot randomized trial of self-guided virtual reality exposure therapy for social anxiety disorder. *Behavior research and therapy*, 147, 103984. <https://doi.org/10.1016/j.brat.2021.103984>, <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8759454/>
- Zhang, L., Weitlauf, A. S., Amat, A. Z., Swanson, A., Warren, Z. E., & Sarkar, N. (2020). Assessing social communication and collaboration in autism spectrum disorder using intelligent collaborative virtual environments. *Journal of Autism and Developmental Disorders*, 50(1), 199-211. <https://doi.org/10.1007/s10803-019-04246-z>
- Zhao, H., Swanson, A. R., Weitlauf, A. S., Warren, Z. E., & Sarkar, N. (2018). Hand-in-hand: A communication-enhancement collaborative virtual reality system for promoting social interaction in children with autism spectrum disorders. *IEEE Transactions on human-machine Systems*, 48(2), 136-148.
- Zhao, J., Zhang, X., Lu, Y., Wu, X., Zhou, F., Yang, S., ... & Fei, F. (2022). Virtual reality technology enhances the cognitive and social communication of children with autism spectrum disorder. *Frontiers in Public Health*, 10. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9582941/>



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-CompartirIgual 2.5 México.

Aplicaciones de la Inteligencia Artificial en Microbiología

Agroambiental

Applications of Artificial Intelligence in Agro-Environmental

Microbiology

Brayan Steven Cruz Florez^{1*}
Blair Ricardo Gomez Torres¹
Ligia Consuelo Sanchez Leal¹

*Contacto correspondencia: bcruz@unicolmayor.edu.co

¹Colombia

Resumen

La inteligencia artificial (IA) ha pasado de ser un concepto futurista a ser una realidad que ha emergido en la última década como uno de los avances más significativos, transformándose así en una gran herramienta que ha visto un incremento en su uso en distintos campos de la ciencia y tecnología marcando un hito en el paso a una nueva revolución tecnológica. Entre estas áreas del conocimiento, las ciencias ambientales particularmente la microbiología agroambiental se ha convertido en uno de los campos donde las aplicaciones de la IA han tenido relevancia. De esta forma, esta nueva tecnología a partir de diferentes métodos como el aprendizaje automático o el aprendizaje profundo ofrece soluciones innovadoras que son aplicables para monitorear y gestionar los distintos sistemas que se pueden encontrar dentro de lo que comprende la microbiología agroambiental. Esta investigación se centró en la búsqueda de las distintas aplicaciones que puede tener la IA y que pueden ser aplicables en procesos propios de la microbiología ambiental, la agricultura y sanidad de los cultivos, la biorremediación y la sostenibilidad ambiental, todos ellos considerados parte fundamental para la comprensión de lo que es el área agroambiental. En esta investigación, se realizó la búsqueda en distintas bases de datos para encontrar la información, logrando así establecer los principios básicos para la comprensión de las herramientas de la IA y cuál es su aplicabilidad dentro de la microbiología agroambiental esta área, resaltando los beneficios de la incorporación de estas tecnologías y sus perspectivas futuras.

Palabras claves:

Inteligencia artificial; Aprendizaje Automático, Aprendizaje Profundo, Microbiología Ambiental, Agricultura, Biorremediación, Sostenibilidad Ambiental

Abstract

Artificial intelligence (AI), a concept that has emerged in the last decade as one of the most significant advances, thus becoming a great tool that has seen an increase in its use in different fields of science and technology, marking a milestone on the road to a new technological revolution. Among these areas of knowledge, environmental sciences, particularly agri-environmental microbiology, have become one of the fields where AI applications have been relevant. In this way, this new technology based on different methods such as machine learning or deep learning offers innovative solutions that are applicable to monitor and manage the different systems that can be found within what comprises agro-environmental microbiology. This research focused on the search for the different applications that AI can have and that can be applicable in different processes such as studies of environmental microbiology, agriculture and crop health, bioremediation and environmental sustainability, all of them, processes that are considered a fundamental part to understand what the agro-environmental area is. In this research, an exhaustive search was carried out in different databases to find the information, thus establishing the basic principles to understand AI tools and what their applicability is within this area, highlighting what the benefits have been of the incorporation of these technologies and the future perspectives on them.

Keywords:

Artificial intelligence; Machine Learning; Deep Learning; Environmental Microbiology; Agriculture; Bioremediation; Environmental sustainability

Introducción:

En la última década, la inteligencia artificial (IA) pasó de ser un concepto futurista para ser una realidad que ya tiene un impacto en distintos aspectos de la vida cotidiana, desde asistentes virtuales en los dispositivos móviles hasta algoritmos avanzados que impulsan decisiones en sectores de la medicina, la industria y la economía, entre otros. La IA se ha impuesto como un pilar fundamental de la era digital. El campo de interés en este artículo de revisión es la microbiología agroambiental, una rama de la microbiología que se centra en el estudio de los microorganismos presentes en el ambiente agrícola y su interacción con los cultivos, suelos y sistemas de producción agrícola, así como los efectos en los recursos naturales que componen un ecosistema y un agroecosistema. A través del uso de IA, es posible tener una mejor perspectiva de soluciones para mejorar la calidad de los procedimientos en esta área y comprender mejor las interacciones entre la agricultura y el desarrollo sostenible, así como la interacción que los seres humanos tienen con estos sistemas.

Los microorganismos hacen parte de la historia del planeta tierra mucho antes que cualquier otro ser vivo, este recorrido histórico, se torna interesante cuando el hombre empieza a entender el comportamiento bioquímico que le permite aprovechar una amplia variedad de fuentes de energía y que en esencia es lo que define su diversidad a nivel funcional, estructural y su capacidad de adaptabilidad eficiente en cualquier medio (Noé Manuel Montañón et al., 2010). Adicionalmente, sus características le permiten estar en cualquier tipo de ambiente y establecer una interacción de manera directa o indirecta con el medio, el cual puede modificar o influir ya sea en forma benéfica, neutra o perjudicial en el ambiente que utilice como hábitat. A manera conceptual, estas interacciones ambiente - microorganismo harán parte de lo que se denomina Microbiología Agroambiental (Kapur, 2019).

El ambiente como término, abarca mucho más de lo que se observa a simple vista en un medio natural, además de representar todo lo que hace parte en un entorno y por lo que se encuentra compuesto, incluirá también las interacciones que surgen por una variedad de factores encontrados en este espacio, que se encuentran interconectados entre sí y logran generar un impacto en él (Chu & Karr, 2017). Normalmente, hay una sinergia que permite establecer un equilibrio en estas interacciones y este estado en un ambiente se podría considerar normal, generando beneficios sin perjudicar algún proceso o interacción que hagan parte de él. Sin embargo, ya sea por la inclusión de un factor adicional o un desbalance en alguna interacción puede provocar que esta sinergia se desestabilice, provocando un desequilibrio que puede generar en un cambio radical en este entorno. De esta manera, este desequilibrio genera aquellas interacciones negativas que pueden causar impactos como la contaminación, el calentamiento global, afectaciones de distintos ecosistemas, cambios poblacionales o afectaciones de los cultivos. Es aquí donde, la microbiología agroambiental surge como aquella área en donde se abordan todas estas componentes, comprendiendo que todo se correlaciona y que tanto aquella vida microscópica como la vida de los seres humanos está íntimamente ligada y que cualquier acción de uno de sus componentes tiene un efecto en la otra (Gupta et al., 2017).

La inteligencia artificial (IA) actualmente representa uno de los avances más grandes en cuanto a la innovación tecnológica (Krenn et al., 2022) al simular la complejidad de la mente humana a través de sistemas computacionales y máquinas (Sheikh et al., 2023). Si se habla de cuál es el propósito en general de la IA, este sería el de simular las capacidades cognitivas humanas (Krenn et al., 2022), integrando desde la percepción hasta el razonamiento (Krenn et al., 2022), el aprendizaje (Krenn et al., 2022) y la toma de decisiones (Krenn et al., 2022). Este campo de estudio de la IA surge de la necesidad de crear tecnologías que puedan realizar distintas tareas complejas de manera autónoma, mejorando así la eficiencia y la precisión en diversos ámbitos donde se apliquen dichas tareas; por lo tanto, la IA se ha vuelto cada vez más relevante en la evolución tecnológica (Krenn et al., 2022), y, así como se han presentado momentos en la historia como el surgimiento de las máquinas de vapor o el uso de la electricidad y que han marcado un antes y un después en el camino hacia una nueva era de innovación y avances, la IA está marcando tendencias que a futuro tienen gran potencial.

En este contexto, la investigación en IA abarca una diversidad de áreas, incluyendo algoritmos de búsqueda (Mukhamediev et al., 2022), procesamiento de lenguajes naturales (Mukhamediev et al., 2022), aprendizaje automático (ML, por sus siglas en inglés, *Machine Learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022), aprendizaje profundo (DL, por sus siglas en inglés, *Deep Learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022), entre otras. Todos estos avances tecnológicos están soportados por una red de infraestructura que integra datos, almacenamiento, potencia informática y algoritmos avanzados, y es así como por

medio de estos factores se desarrollan aplicaciones más avanzadas y útiles que a su vez pueden ejecutar tareas más complejas que hacen aportes aún mayores en el área donde se utilicen.

Se podría decir dentro del ámbito de la IA, que se puede dividir en dos componentes importantes: el primero sería el aprendizaje automático (ML) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022) y el segundo, que sería aprendizaje profundo (DL) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022). Si bien, se puede entender que el aprendizaje profundo es parte del aprendizaje automático (Mukhamediev et al., 2022; Holzinger et al., 2023; Holzinger et al., 2023; Francisco Castillo Díaz, 2022), ambos tienen sus propios conjuntos de algoritmos, sus propias características y también su propio sistema de cálculo con el cual se desarrollan modelos expertos para proyecciones y clasificaciones con una mayor precisión (Holzinger et al., 2023).

Los sistemas de IA de igual manera se pueden categorizar en diferentes tipos y subcategorías (Holzinger et al., 2023), (Francisco Castillo Díaz, 2022). En esta clasificación, se destacan la IA débil o estrecha (en inglés, *Artificial Narrow Intelligence*, ANI) (Holzinger et al., 2023; Francisco Castillo Díaz, 2022), cuya función principal se centra en ejecutar tareas específicas y que es comúnmente encontrada en herramientas como los asistentes virtuales comunes en un dispositivo móvil (Francisco Castillo Díaz, 2022). Por otro lado, está la IA fuerte, modelo, la cual todavía se puede decir que se encuentra en fase de desarrollo y que se subdivide en IA fuerte general (en inglés, *Artificial General Intelligence*, AGI) (Holzinger et al., 2023; Francisco Castillo Díaz, 2022) e IA fuerte superior (en inglés, *Artificial Super Intelligence*, ASI) (Francisco Castillo Díaz, 2022). Idealmente, la AGI aspira a simular la mente y el razonamiento del ser humano (Holzinger et al., 2023; Francisco Castillo Díaz, 2022), mientras que con la ASI se espera superar incluso la capacidad intelectual humana, planteando así el gran potencial que podría abarcar para la próxima revolución industrial (Francisco Castillo Díaz, 2022) pero que a su vez es uno de los grandes problemas éticos que se pueden plantear cuando se piensa en la IA (Francisco Castillo Díaz, 2022).

El desarrollo de la IA, al estructurar varios campos de investigación (Xu et al., 2021), permite que se articulen en torno a la inteligencia perceptiva (Krenn et al., 2022; Xu et al., 2021), cognitiva (Krenn et al., 2022; Xu et al., 2021) y para la toma de decisiones (Krenn et al., 2022; Xu et al., 2021), comprendiendo así que la inteligencia perceptiva engloba las capacidades básicas de percepción (Xu et al., 2021), como la visión (Xu et al., 2021), audición (Xu et al., 2021) y tacto (Xu et al., 2021). Por su parte, la cognitiva se relaciona con la inducción, razonamiento y la adquisición de conocimientos. En cuanto a la inteligencia relacionada con la toma de decisiones (Xu et al., 2021), implica la aplicación de la ciencia de datos, las ciencias sociales y la teoría de la decisión se utilizan para optimizar las decisiones (Krenn et al., 2022; Xu et al., 2021). De esto último surgen problemas éticos, e incógnitas como ¿Cuál es el grado de fiabilidad en la toma de decisiones de una IA?. Este representa uno de los factores adversos al pensar en la aplicación de esta tecnología, por lo que se plantea como reflexión, en qué casos resulta viable aplicar la toma de decisiones de la IA y en cuáles no (Sheikh et al., 2023).

Resulta importante destacar que, si bien la IA ha logrado avances significativos, aún existen desafíos y debates sobre su desarrollo ético (Sheikh et al., 2023), así, otras problemáticas que surgen como el impacto en el empleo y cuáles son los potenciales riesgos de optar por el uso de estas tecnologías sobre tecnologías más tradicionales en distintas áreas (Mukhamediev et al., 2022). Sin embargo, ya no hay punto de retorno en el crecimiento continuo de este campo, el cual promete seguir impulsando la innovación y el progreso en el futuro (Krenn et al., 2022; Mukhamediev et al., 2022).

¿Podría entonces la inteligencia artificial ser aplicada en cualquier área? Sí, la IA se puede aplicar en cualquier área, gestionándola de manera adecuada; la IA tiene alcances prácticamente ilimitados y por ello en este artículo se revisará su aplicación en la microbiología agroambiental (Francisco Castillo Díaz, 2022). En un mundo donde se tiene un impacto que parece irreversible cuando se habla de seguridad alimentaria (Ding et al., 2023), calentamiento global, globalización, manejo de los residuos y la contaminación, la inteligencia artificial y su inminente llegada para quedarse (Holzinger et al., 2023), surgen como una forma inteligente para buscar soluciones a estas problemáticas y por eso la IA ofrece nuevas alternativas para dar respuesta en el área de la microbiología agroambiental (Holzinger et al., 2023).

En este artículo, se observarán los resultados de una revisión en la que se tuvo como objetivo establecer aplicaciones de la IA en la microbiología agroambiental. Se establecieron las distintas herramientas que ofrece la inteligencia artificial y que pueden ser utilizadas en la microbiología, las cuales aportan al estudio y análisis en la microbiología ambiental, comprendiendo el conocimiento sobre microbiomas y biodiversidad microbiana, así como la monitorización de la calidad de ambientes como agua y suelo y las aplicaciones de la IA en la agricultura y sanidad de los cultivos. También se analizó cómo la IA se utiliza en el modelado y asistencia en procesos de biorremediación y finalmente, utilización de la IA en la optimización y la predicción de decisiones de implementación en sostenibilidad ambiental.

Metodología

Se llevó a cabo una revisión exhaustiva en diversas bases de datos y en distintas fuentes de información que abarcaran aplicaciones de la inteligencia artificial en el nexo microbiología-ambiente – agricultura - desarrollo sostenible. Se buscaron, identificaron y leyeron artículos publicados, reportes de casos y capítulos de libros, que se obtuvieron específicamente en las bases de datos de Scienedirect (<https://www.sciencedirect.com/>), NCBI (<https://www.ncbi.nlm.nih.gov/>), MDPI (<https://www.mdpi.com/>), Nature (<https://www.nature.com/natrevphys/>), Frontiers (<https://www.frontiersin.org/>), Springerlink (<https://link.springer.com/>), Crossref (<https://www.crossref.org/>). Para la búsqueda se utilizó una serie de palabras clave, así como el uso de operadores booleanos para cubrir la búsqueda así: “artificial intelligence AND environmental microbiology”, “artificial intelligence AND corps”, “artificial intelligence AND plants AND microbiology”, “artificial intelligence AND plants AND microorganisms”, “artificial intelligence AND environmental microorganisms”, “artificial intelligence AND bioremediation”, “artificial intelligence AND ecology”.

Generalidades

¿Qué es la Inteligencia Artificial?

La inteligencia artificial es definida de muchas formas y por lo tanto no existe una única forma de denotar este término (Sheikh et al., 2023), pero si se puede tener una comprensión sobre que es una IA. De acuerdo con lo revisado, los autores de este artículo establecen que la IA consiste en una serie de distintos algoritmos los cuales tienen como finalidad imitar el actuar humano (Krenn et al., 2022; Mukhamediev et al., 2022), es decir, replicar su racionalidad y pensamiento (Krenn et al., 2022; Xu et al., 2021). En este sentido, se puede decir que la IA se basa en aprender, razonar, actuar y decidir (Krenn et al., 2022; Xu et al., 2021; Robinson, 2022). De hecho, comprender la IA de esta forma, permite establecer que esto funciona de manera cíclica (figura 1), a través de la cual se obtienen unos resultados los cuales, son usados en el área donde se aplica la IA. Un ejemplo de esto puede ser el uso actual del ChatGPT, donde a través de Prompts (Walsh et al., 2024) (comandos) se puede ejercer toda la actividad cíclica de aprender, razonar, decidir y actuar, a partir de un comando escrito por la persona que está usando ChatGPT. Los algoritmos de esta IA generan un resultado que es la respuesta de este chatbot, en donde puede aprender partiendo de los prompts que se le escriben y respecto a los mismos razona, decide y actúa, generando así el resultado esperado que va a ser la respuesta en el chat.

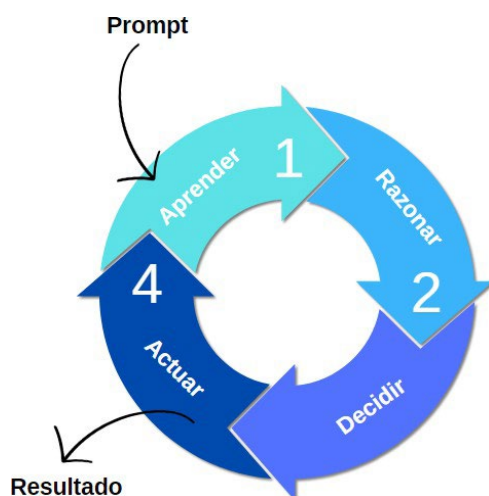


Figura 1. Funcionamiento cíclico de comprensión de la IA

Herramientas de inteligencia artificial

1. Aprendizaje Automático y Aprendizaje Profundo

La IA tiene dos ramas principales que son, el aprendizaje automático (ML) y el aprendizaje profundo (DL) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022). Cuando se habla de ML se refiere a un tipo de entrenamiento (Holzinger et al., 2023), mientras que cuando se habla de DL este se asocia más redes neuronales artificiales (en inglés, *Artificial neuronal networks*, ANNs). Su utilidad radica en el manejo de gran cantidad de datos (Holzinger et al., 2023; Pichler & Hartig, 2023), pero es importante tener en cuenta que estos conceptos no se consideran por aparte, sino que de hecho el DL hace parte del ML, por lo que se puede decir que el DL se establece como una alternativa para aumentar la efectividad del ML (Pichler & Hartig, 2023) y lograr el objetivo de la IA.

ML es una serie de métodos que permiten predicción de ciertas características de un grupo de datos a partir del entrenamiento que se ha tenido respecto a estos mismos datos, es decir, aprender y analizar los datos para posteriormente predecir eventos con ellos (Sun et al., 2022; Goodswen et al., 2021). De esta manera, tenemos que el ML sienta bases en el entrenamiento con datos (Goodswen et al., 2021; Walsh et al., 2024; Pichler & Hartig, 2023), por lo cual, para desarrollar un modelo de ML se entrena utilizando un grupo de datos y estos mismos contienen información para que el modelo aprenda a hacer su predicción. A lo largo de este proceso, se puede lograr ajustar el modelo para que a medida que aprenda se minimicen los errores y así a su vez se mejore la capacidad para predecir a partir de patrones (Goodswen et al., 2021, Zhao et al., 2023; Pichler & Hartig, 2023), todo esto con el fin de que cuando sea sometido a nuevos datos a partir del aprendizaje previo, tenga la capacidad de predicción.

El DL es considerado, en sí mismo, una rama del ML (figura 2) que se centra en el entrenamiento de modelos de IA para realizar tareas cada vez más complejas (Zhao et al., 2023; Jiang et al., 2022; Pichler & Hartig, 2023). Se le relaciona con el concepto de “profundo” porque implica el uso de redes neuronales, que son modelos con múltiples capas de procesamiento (Sun et al., 2022). Estas redes tienen la capacidad de aprender jerárquicamente la representación de un conjunto de datos, lo que les permite capturar características y patrones de manera automática a partir de conjuntos de datos extensos y complejos (Sun et al., 2022; Zhao et al., 2023; Liang et al., 2020).

Los métodos que utiliza el ML se pueden dividir según el método de aprendizaje y el propósito del algoritmo que se utiliza (Goodswen et al., 2021); entre estos está el aprendizaje supervisado (SL, por sus siglas en inglés, *supervised learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023; Zhao et al., 2023), el aprendizaje no supervisado (UL, por sus siglas en inglés, *unsupervised learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023), semi-aprendizaje supervisado (SSL, *semi-supervised learning*) (Mukhamediev et al., 2022), aprendizaje reforzado (RL, en inglés, *reinforcement learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023) y el aprendizaje profundo (DL) (figura 2) (Mukhamediev et al., 2022; Holzinger et al., 2023; Zhao et al., 2023)

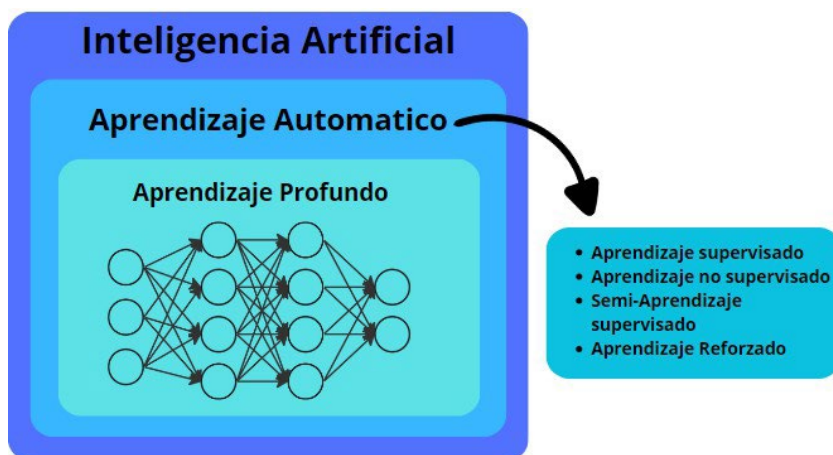


Figura 2. Diagrama que representa la relación entre la IA, el ML, DL, SL, UL, SSL y RL

El ML se posiciona así como un gran avance con amplios usos en diversas áreas entre ellos la microbiología y los estudios agroambientales, donde los modelos predictivos que se obtienen a partir del ML tienen una aplicación (Walsh et al., 2024), por ejemplo al permitir un análisis de rasgos microbianos (Ghannam & Techtmann, 2021; Peyman Namadi & Deng, 2023; Asala Mahajna et al., 2022), actores ambientales (Ali et al., 2023; Walsh et al., 2024; Liang et al., 2020; Asala Mahajna et al., 2022) y respuestas de las plantas al momento de la predicción de cepas microbianas en la relación de interacción planta-microbio-suelo (Miller et al., 2023; Ali et al., 2023, Walsh et al., 2024; Liang et al., 2020), así como también entra en juego el DL, ya que al gestionar el manejo de datos de microorganismos permite descubrir patrones y relaciones ocultos y hacer predicciones (Miller et al., 2023; Ali et al., 2023; Liang et al., 2020).

De esta manera, el uso de estos modelos basados en IA, permiten mejorar dos factores fundamentales en procesos experimentales dentro de investigaciones de cualquier área, incluyendo la microbiología, que son la eficiencia y eficacia (Miller et al., 2023; Ali et al., 2023; Zhao et al., 2023; Robinson, 2022; Kumar et al., 2023), ya que la aplicación de esta nueva tecnología facilita esa acción de prueba y error que es común en el trabajo de investigación y que requiere mucho tiempo. La utilización de estos modelos mejora estos procesos al facilitar la toma de decisiones, al predecir resultados y de esa manera gestionar una actividad (Ali et al., 2023), ya sea dentro de la investigación, o inclusive en la toma de decisiones en el área del desarrollo sostenible (Miller et al., 2023; Wu & Zhao, 2023; Chowdhury et al., 2024), sanidad ambiental (Asala Mahajna et al., 2022), diagnóstico en el laboratorio (Egli et al., 2020; Shelke et al., 2023; Ihsan et al., 2023; Ghannam & Techtmann, 2021; Peyman Namadi & Deng, 2023) y la agricultura (Miller et al., 2023; Wu & Zhao, 2023; Spyridon Mourtzinis et al., 2021; Lu et al., 2024). De esta manera, es como el ML toma un papel fundamental y el conocimiento de sus diversos modelos facilita su adecuación a cualquier actividad.

Estos modelos han generado con su implementación cambios en la manera de realizar las tareas que podían ser repetitivos promoviendo una automatización basada en IA, por tal razón, se puede hablar de la entrada en la época de la “microbiología digital” (Ali et al., 2023; Egli et al., 2020; Shelke et al., 2023; Kumar et al., 2023), en donde ya se ha puesto en marcha el apoyo de chatbots en el laboratorio (Egli et al., 2020), microscopía automatizada (Egli et al., 2020; Zhang, Li, et al., 2023), sistemas automatizados de lecturas de placas (Egli et al., 2020), lectura de pruebas en equipos electrónicos (Egli et al., 2020; Ihsan et al., 2023), aplicaciones de análisis en metagenómica (Kumar et al., 2023) y toma de decisiones post análisis (Miller et al., 2023; Egli et al., 2020; Shelke et al., 2023; Kumar et al., 2023), facilitando así la investigación microbiana (Jiang et al., 2022; Asala Mahajna et al., 2022) en cuanto al diagnóstico (Egli et al., 2020; Shelke et al., 2023; Ihsan et al., 2023; Ghannam & Techtmann, 2021), identificación (Shelke et al., 2023; Zhao et al., 2023; Walsh et al., 2024; Ihsan et al., 2023; Ghannam & Techtmann, 2021) y caracterización (Ihsan et al., 2023; Ghannam & Techtmann, 2021; Liang et al., 2020) de microorganismos particulares (Peyman Namadi & Deng, 2023) y comunidades microbianas (Ghannam & Techtmann, 2021; Kumar et al., 2023).

2. Redes neuronales

Cuando se habla de DL, se hace referencia a un grupo de ANNs que están compuestas por capas ocultas (Sun et al., 2022; Peyman Namadi & Deng, 2023). El DL se puede utilizar de forma supervisada, no supervisada y semisupervisada (Zhao et al., 2023).

En este orden de ideas, el DL es aquella rama de la IA que más crecimiento ha tenido en estos últimos años; estas ANN están inspiradas en el cerebro del ser humano y tratar de imitar lo que serían las conexiones neuronales, estas redes contienen unidades que trabajan en conjunto para procesar la información que conforman capas (Zhao et al., 2023; Zhang, Li, et al., 2023). Cuando se habla de capas en una ANN, que es la manera más común en que se organizan, representan el flujo de la información (Zhao et al., 2023), ya que existe una capa de entrada que recibe los datos y está a su vez transmite la información a través de una o varias capas que se denominan “ocultas” para finalmente llegar a una capa de salida que ya es el sitio donde se obtienen los resultados esperados (figura 3) (Zhao et al., 2023)




Figura 3. Diagrama de representación del funcionamiento básico de una ANN

Por lo tanto, se puede ver que cada unidad está conectada a través de enlaces, a través de los cuales se transmiten las señales (Zhang, Li, et al., 2023), a lo largo del paso por la red neuronal, la información de entrada sufre cierto tipo de alteraciones que generan los valores de nueva forma para su salida (Sun et al., 2022; Ali et al., 2023). El principal objetivo de una ANN se basaría en resolver los problemas imitando un cerebro humano, esto se entiende a manera de que, como seres humanos al recibir un estímulo por cualquiera de los sentidos se expresa una serie de reacciones bioquímicas que pasan por el sistema neuronal y acaban resultando en un efecto ya sea dolor, sorpresa, análisis, reflexión, entre otros. En concreto, en la ANN se busca imitar haciendo uso de millones de unidades neuronales por donde la información transita posterior a una entrada en el mismo sistema de la ANN (Mukhamediev et al., 2022, Zhao et al., 2023; Zhang, Li, et al., 2023).

De esta manera, las ANN como eje fundamental del DL (Mukhamediev et al., 2022; Chowdhury et al., 2024), hacen parte del ML, razón por la cual su entrenamiento es fundamental para su correcto funcionamiento (Mukhamediev et al., 2022; Ihsan et al., 2023). Este entrenamiento radica en la utilización de datos de entrada conocidos con datos de salida conocida, en búsqueda de mejorar su sistema de procesamiento.

Las ANN han tenido un papel fundamental en distintas áreas de investigación al facilitar la simplificación de tareas, sin embargo, para aprovechar al máximo su uso se requiere el suficiente entrenamiento y una arquitectura adecuada de la ANN (Mukhamediev et al., 2022; García et al., 2024; Zhang, Li, et al., 2023). Cuando se habla de arquitectura se refiere a la organización de la ANN, ya que esto tiene un impacto en el procesamiento de la información (Mukhamediev et al., 2022; García et al., 2024). Los tres tipos de arquitectura básicos de una ANN son: Red neuronal de retroalimentación estándar (Mukhamediev et al., 2022; Zhao et al., 2023); Red neuronal recurrente (RNN, por sus siglas en inglés, *Recurrent Neural Networks*) (Mukhamediev et al., 2022; Zhao et al., 2023); Red neuronal convolucional (CNN, por sus siglas en inglés, *Convolutional Neural Networks*) (Mukhamediev et al., 2022; García et al., 2024; Ihsan et al., 2023; Zhang, Li, et al., 2023). También existen las arquitecturas híbridas que pueden incluir elementos de las arquitecturas básicas (Mukhamediev et al., 2022).

En conclusión, los modelos de ANN pueden analizar distintas fuentes de información (García et al., 2024), ya sea a partir de prompts, o a partir de datos obtenidos por distintas herramientas tecnológicas, por ejemplo, a partir de sensores (Muhammad et al., 2022), biosensores (Kobra Salimiyani rizi & Ashrafi, 2023) o la teledetección (RS, por sus siglas en inglés, *remote sensing*) (Chowdhury et al., 2024; Kobra Salimiyani rizi & Ashrafi, 2023).

3. Minería de datos

La minería de datos, otra herramienta de la IA, se relaciona con un proceso en el que principalmente se requiere descubrir patrones, tendencias, correlaciones y conocimientos dentro de un conjunto de datos (Mukhamediev et al., 2022). Por lo tanto, la minería de datos busca la conversión de datos en información que representa utilidad dependiendo de la finalidad de su uso y esto a su vez, resulta en una toma de decisiones, predicción de tendencias, futuras y la optimización de procesos (Zhao et al., 2023; James et al., 2022).

La minería de datos se basa en una serie de etapas: la extracción de datos, en donde se recopila la información necesaria para el análisis en el cual se implica a la fuente de obtención de datos, luego la exploración de datos en donde se busca su comprensión continua con un modelado y análisis, etapa en la cual se identifican patrones (Mukhamediev et al., 2022) y finalmente validar y evaluar la información y aplicarla en una área específica.

La minería de datos es un campo de aplicación de la IA en donde a partir del ML por medio de sus distintas ramas se puede ejecutar (Ali et al., 2023). Por lo tanto, la minería de datos resulta un área de interés en la investigación, en donde uno de los usos en microbiología es la identificación de microorganismos (Shelke et al., 2023, Zhao et al., 2023; Walsh et al., 2024; Ihsan et al., 2023; Peyman Namadi & Deng, 2023); es así como este ejercicio de la minería de datos es una aplicación importante en el área de la microbiología (Jiang et al., 2022; James et al., 2022). Su gran aporte radica en el uso de mecanismos generales de modelos ML/DL en donde se pueden generar resultados a partir de los datos, que en este caso serían secuencias del genoma completo (Ali et al., 2023; Walsh et al., 2024; Ghannam & Techtmann, 2021; Liang et al., 2020) y análisis en metagenómica (Zhang, Li, et al., 2023) en donde DL/ML predicen eventos a partir de esta información, como por ejemplo resistencia a antimicrobianos (Ali et al., 2023) o la caracterización de comunidades microbianas en un entorno (Ihsan et al., 2023; Jiang et al., 2022; Kobra Salimiyan rizi & Ashrafi, 2023).

4. Internet de las Cosas

El internet de las cosas (IoT, por sus siglas en inglés, *Internet of Things*) en los últimos años ha sido una de las tecnologías más importantes (Ubina et al., 2023), ya que su implementación se realiza desde objetos cotidianos, hasta para procesos más complejos a nivel tecnológico. Este concepto hace relación a la existencia de una interconexión de dispositivos físicos los cuales a su vez están integrados con tecnologías para recopilar y compartir datos por medio del internet, como los sensores (Terence & Geethanjali Purushothaman, 2020).

Existe una relación entre IoT y la IA y se refiere a que la IA se usa para procesar los datos generados por dispositivos IoT, siendo este el principio para automatización de procesos (Ubina et al., 2023; Terence & Geethanjali Purushothaman, 2020). Un ejemplo es su aplicación con el uso de sensores que en el área agroindustrial son fundamentales para múltiples procesos. Es así como los biosensores han tomado relevancia en ese proceso de automatización, algo que no es ajeno al área agroambiental (Ubina et al., 2023; Terence & Geethanjali Purushothaman, 2020); estos se rigen por el principio del IoT y sus datos pueden ser procesados por ANN para simplificar dicha automatización (Muhammad et al., 2022; Kobra Salimiyan rizi & Ashrafi, 2023), lo que también ha sentado las bases de la hoy conocida como agricultura inteligente (Terence & Geethanjali Purushothaman, 2020).

5. Procesamiento del lenguaje natural

Otra herramienta, el procesamiento del lenguaje natural (NLP, por sus siglas en inglés, *Natural Language Processing*) hace parte de la IA que se desarrolla principalmente en la interacción entre el lenguaje humano y la tecnología, es decir, su principal objetivo es permitir la comprensión, interpretación y generación de lenguaje humano (Molik et al., 2021). Por lo cual, tiene implicaciones en la minería de datos y el IoT, ya que aquí se establecen procesos como el reconocimiento del habla, la traducción, extracción de información y el análisis de generación de texto.

6. Bosque Aleatorio

Un bosque aleatorio (RF, por sus siglas en inglés, *Random Forest*) es un algoritmo de ML que generalmente es usado con la finalidad de clasificación y regresión, es una combinación de múltiples modelos de aprendizaje con el fin de mejorar la precisión predictiva (Ricardo Hernández Medina et al., 2022). Se le conoce con el término de bosque, porque se crean distintos tipos de árboles de decisión durante la fase de entrenamiento del ML en donde cada árbol se entrena con una muestra al azar del conjunto de datos que se usa para el ML, es decir, cada árbol es entrenado de forma independiente y cada uno tiene un subconjunto del conjunto de datos de entrenamiento (Ricardo Hernández Medina et al., 2022).

En este sentido, el RF tiene el ideal de diversificar los árboles, de tal manera que se reduce la correlación entre ellos; el conjunto del bosque genera datos nuevos y que no hayan estado previamente. De esta manera, al realizar una predicción con un RF, se combinan las predicciones individuales de cada árbol para llegar a una predicción final (Ricardo Hernández Medina et al., 2022).

7 Máquinas de Vectores de Soporte

Las máquinas de Vectores de Soporte (SVM, por sus siglas en inglés, *Support Vectors Machines*) hace parte de los algoritmos de ML y se basan en el SL, generalmente su uso se enfoca en la clasificación. El principio básico de este algoritmo consiste en funcionar como un clasificador en un hiperplano, en donde separa y clasifica según el lado en el que se encuentre (Hayati et al., 2024).

Inteligencia artificial aplicada a la microbiología agroambiental

De acuerdo con estos conceptos, la IA tiene un impacto en el proceso de digitalización de distintas actividades, dentro de ellas el ejercicio de la microbiología (Ali et al., 2023; Egli et al., 2020; Shelke et al., 2023; Kumar et al., 2023), pero si se habla específicamente de la microbiología agroambiental, la IA se podría concretar en cinco ejes principales (figura 4): 1. Eficiencia en el análisis de datos, 2. Predicción de patrones, 3. Optimización de procesos, 4. Diagnóstico y vigilancia y 5. Modelado y simulación.

Estos componentes se relacionan unos con otros y por ello, la IA facilita el manejo de conjuntos de datos complejos y permite la identificación de patrones en los datos, lo que a su vez impacta en la optimización de procesos, facilita procesos de monitoreo y además simplifica procesos experimentales.

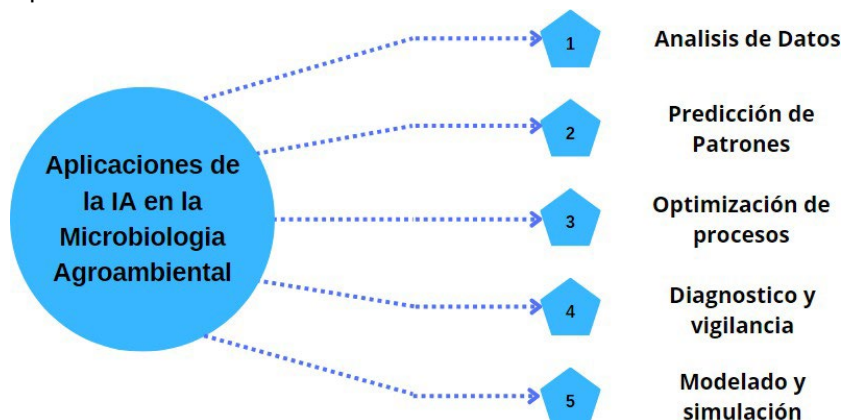


Figura 4. Principales finalidades de la implementación de la IA en la microbiología agroambiental

1. Modelado predictivo de cambios en la biodiversidad microbiana.

El modelado predictivo es una técnica que utiliza datos para predecir eventos futuros, siendo esta una de las aplicaciones más importantes de la IA. Se basa en la construcción de modelos que identifican patrones y relaciones en los datos para hacer proyecciones sobre lo que podría suceder en el futuro, de esta manera los modelos DL/ML son una herramienta de última generación para este proceso de modelado predictivo (Ali et al., 2023).

En este sentido, esta técnica puede ser de utilidad en el análisis de predicción de comunidades microbianas, algo que es fundamental en cualquier estudio de microbiología (Kumar et al., 2023). Un modelo predictivo permite el análisis de datos para caracterizar una comunidad de microorganismos y asociarlos según estas características (Kumar et al., 2023), como por ejemplo aquellos que tengan la capacidad de fijación de nitrógeno, o también aquellos que son solubilizadores de fosfatos (Kumar et al., 2023)

Además, para complementar esa acción de predicción, se pueden incluir más datos, que en el caso de microorganismos ambientales, serían las propiedades del suelo y las condiciones climáticas (Kumar et al., 2023) que van a facilitar la predicción y así determinar la efectividad de diferentes microorganismos en estos ambientes. Estos modelos mejoran la efectividad en la selección de cepas microbianas con distintos fines y a su vez facilitan el desarrollo de nuevas cepas con la finalidad de facilitar su adaptación a un medio específico (Kumar et al., 2023).

2. Metagenómica en el ML

En la metagenómica, se analizan conjuntos de datos masivos para identificar y clasificar la diversidad genética, este campo se enfoca en material genético de distintas muestras lo cual es de importancia en la microbiología ambiental, ya que permite el estudio de muestras ambientales como suelo, agua, lodos, entre otros. Los ensamblajes metagenómicos surgen como una alternativa viable al establecimiento de nuevas especies no cultivables, lo que ha permitido que se conozca la existencia de una diversidad de microbiomas en distintos ambientes (Liang et al., 2020).

La metagenómica hace parte de las ciencias ómicas, las cuales son conocidas por elaborar perfiles rápidos de poblaciones microbianas (James et al., 2022). Los datos que se obtienen a partir de estas ómicas tienen un alto flujo en información, lo que genera un volumen a gran escala de conjuntos de datos, los cuales propiamente tienen un potencial para la clasificación y la predicción ambiental (James et al., 2022). Estos datos traen consigo una complejidad, la cual a su vez oculta los patrones subyacentes a la información biológica, lo cual conlleva una gran problemática para su interpretación manual.

La utilización de algoritmos de IA permite identificar comunidades microbianas en términos de su abundancia y composición, así como constituye el reflejo del ambiente de dicha comunidad (Danijela Šantić et al., 2021; Zou et al., 2024) a partir de la aplicación de distintas ómicas, entre ellas la metagenómica. La ocurrencia de distintas variables ambientales pueden afectar la estructura de estas comunidades microbianas, se ha identificado que el uso de ANN permite generar modelos para predecir los impactos de estas variables en las comunidades relacionando las diversidades microbianas con variables que le dan estructura a esta diversidad (figura 6) (Sun et al., 2020).

Se puede ver como la IA empieza a jugar un papel fundamental en el área de la metagenómica, porque uno de los pasos de mayor importancia en la interpretación de datos metagenómicos es la clasificación taxonómica (Liang et al., 2020). Debido a que el desarrollo de métodos para investigar el papel de estos nuevos organismos no cultivados es de suma importancia para la comprensión de estos microbiomas (Liang et al., 2020), a raíz de que los genomas ensamblados en metagenomas suelen estar muy fragmentados en comparación con los genomas obtenidos mediante la secuenciación del genoma completo a partir de cultivos (Liang et al., 2020), dicha fragmentación dificulta la alineación de manera tradicional, porque estas herramientas sufren una pérdida de rendimiento en presencia de microorganismos desconocidos, razón por la cual estos procesos dependen de un árbol taxonómico recuperado de bases de datos de taxonomía. El DL como parte del ML se establece como una solución por su capacidad de modelado, lo que convierte dicha fragmentación en un problema que no repercute en esta técnica, ya que los genomas se cortan a la longitud de las lecturas de secuenciación que fueron establecidas para el entrenamiento (Liang et al., 2020).

Existe una secuenciación metagenómica que se conoce como “shotgun”, es una técnica usada para muestras ambientales complejas (Ricardo Hernández Medina et al., 2022). A través de diferentes algoritmos de ML, las lecturas metagenómicas de “shotgun” se pueden alinear con bases de datos seleccionadas para realizar anotaciones funcionales o taxonómicas (Ricardo Hernández Medina et al., 2022). El uso del NLP con datos metagenéticos, también es de importancia en esta área por su relación en el análisis de estos datos, ya que al tener esta parte de la IA en conexión con fuentes de datos donde tiene acceso a información de componentes como el ARN ribosómico 18S tiene la capacidad de comprender y analizar diversidades taxonómicas (Molik et al., 2021) basadas en el ML para su procesamiento.

Todos estos avances que se tienen en las distintas ómicas juntos con las técnicas a la vanguardia de secuenciación, han permitido que exista gran cantidad de datos respecto a lo que son los microbiomas y el uso del ML permite el reconocimiento de patrones en este tipo de datos, una

manera de representar estos mismos es por el uso de unidades taxonómicas operacionales (OTU, por sus siglas en inglés, Operational Taxonomic Units) que es de utilidad para categorizar microorganismos siguiendo como principio la similitud de sus secuencias de ADN. Se ha evidenciado que el uso de CNN y RNN para análisis filogenéticos basados en OTUs, ha permitido un mejor análisis de taxones microbianos (Ricardo Hernández Medina et al., 2022), debido a que estas ANN exploran patrones históricos y sus arquitecturas permiten que los estudios de microbiomas generen predicciones temporales y patrones dinámicos generando así los perfiles del microbioma

El ML se posiciona como uno de los modelos adecuados para abordar los desafíos subsecuentes de la metagenómica, de forma tal, que actualmente se están implementando en las ómicas el uso de ML para abordar los distintos desafíos ambientales (James et al., 2022). Dentro de estos desafíos ambientales están los impactos antropogénicos, los cuales están motivando el desarrollo de metodologías de bioevaluación ambiental, entrando así las ómicas y a su vez el ML en el desarrollo de estas actividades del área ambiental (James et al., 2022). Así pues, se reconocen los biosensores, los cuales permiten realizar ese monitoreo de los impactos humanos, los microorganismos son reconocidos por su capacidad de funcionar como dichos biosensores, por lo cual datos de metagenómica de poblaciones microbianas con su respectivo análisis por medio de ML, dan paso a la predicción del impacto y la presencia de contaminantes ambientales (James et al., 2022)

De esta forma, la implementación del ML es un apoyo a los metanálisis ambientales y a la minería de datos, ya que al manejar grandes volúmenes de datos ómicos, el ML simplifica el proceso para proporcionar una mejor visión de las funciones microbianas (James et al., 2022).

3. Herramientas de IA para la monitorización de la calidad del agua y suelo.

La monitorización de la calidad del agua y suelo es un estudio importante que se realiza en la microbiología ambiental, ya que permite establecer la condición de estos ecosistemas a nivel físico, químico y biológico (figura 5). Este monitoreo permite la predicción del deterioro ambiental además de la evaluación de medidas de mitigación de contaminantes, lo que resulta de importancia en la gestión ambiental (Cai et al., 2024).

De esta manera, los microorganismos surgen en la actualidad como bioindicadores del estado ambiental, por lo cual su seguimiento es fundamental en la comprensión del estado ambiental y la implementación del ML basado en ómicas permite realizar este monitoreo (James et al., 2022) y entender la dinámica de estos microorganismos para predecir diferentes impactos ambientales (James et al., 2022).

En cuanto a la monitorización de la calidad del suelo la implementación de herramientas de IA permite el análisis de la calidad del suelo, gracias a la identificación de patrones entre conjuntos de parámetros del suelo (Muhammad Awais et al., 2023), es posible la medición más precisa de dichos parámetros de manera independiente como la textura del suelo o su contenido de agua (Muhammad Awais et al., 2023). Los suelos al representar uno de los recursos naturales más importantes, requiere un adecuado mantenimiento fundamental para el desarrollo agrícola y la sostenibilidad ecológica, debido a que estos proporcionan distintos servicios ecosistémicos esenciales (figura 4) (Wang et al., 2023). Por tal razón, se han podido desarrollar distintos modelos basados principalmente en ML que permite predecir la calidad del suelos y así, actualmente, se están basando en este principio los sistemas agroindustriales. Usar estos modelos permite predecir el rendimiento de cultivos basándose en datos de indicadores químicos, físicos y biológicos del suelo, apoyados de tecnologías como sensores, vehículos aéreos no tripulados o plataformas satelitales que permiten determinar dichos indicadores. (Diaz-Gonzalez et al., 2022)

En cuanto a la monitorización de la calidad del agua, la IA tiene un papel importante (figura 5) en particular cuando se requiere agua potable. En cuanto a la utilización de esta tecnología en sistemas de distribución de agua potable (Soma Safeer et al., 2022; C.H. Pérez-Beltrán et al., 2024; El et al., 2023), el ML ha sido reportado en el procesamiento de datos metagenómicos para modelos predictivos en sistemas de potabilización de agua (Soma Safeer et al., 2022). De esta manera, el ML tiene aplicaciones en este proceso porque permite: modelado de interacciones entre comunidades microbianas (Soma Safeer et al., 2022), predicción de calidad biológica y química del agua (Soma

Safeer et al., 2022), soporte en la toma de decisiones para mantenimiento y operación (Soma Safeer et al., 2022) y optimización de sistema de potabilización (Soma Safeer et al., 2022).

Distintos protocolos de ML permiten por medio de sensores determinar los cambios en cuerpos de agua, los sensores por medio de cambios espectrales con diversos parámetros ambientales y el uso de IA permiten descubrir patrones en los datos del sensor (Staša Puškarić et al., 2024). La capacidad de predicción que tiene el ML puede monitorear así la calidad del agua, e inclusive establecer el origen y las características de una muestra, ya que puede reportar comunidades microbianas a partir de datos que se obtienen de muestras contaminadas con xenobióticos y por datos metagenómicos identificar estas comunidades. Esto resulta también de importancia en salud pública, ya que al usar modelos predictivos de microorganismos como bioindicadores de contaminación pronostica la calidad del agua para la actividad que se tenga destinada, en particular la que se utiliza para el consumo humano (James et al., 2022)

En cuanto a los xenobióticos, en vista de las distintas actividades antropogénicas que generan afectaciones de este ecosistema, las tecnologías de RS son fundamentales para ese proceso de seguimiento de la calidad del agua. Los distintos parámetros que se pueden medir de este ambiente son fundamentales para la monitorización, por lo cual resulta de importancia los datos de RS para su interpretación por medio de algoritmos de IA como SVM, RF, CNN, RNN (Wang et al., 2023).



Figura 5. Imagen generada con IA. Se observa que la monitorización de la calidad de agua y suelo se realiza a partir de parámetros idénticos en ambos casos, dicho monitoreo se hace con la finalidad de evitar la pérdida de usos en cada caso.

Inteligencia artificial aplicada a la agricultura y sanidad de cultivos

La agricultura y el cuidado de los cultivos a lo largo del tiempo se ha visto en constante evolución a la par con el desarrollo tecnológico e industrial y donde el ser humano ha sido protagonista porque ha venido acumulando todos los conocimientos y las prácticas que ofrece la agricultura tradicional. Sin embargo, existen aún problemáticas que conllevan a los distintos desafíos abordados en los tiempos actuales junto a la par de la revolución tecnológica. En este sentido, la agricultura moderna hace frente a las necesidades actuales y al mismo tiempo, aporta e innova, preocupándose por una mayor precisión respecto a las predicciones no solo a nivel de los cambios ambientales sino en las características y propiedades del cultivo. Como estrategia se fomenta el uso de las tecnologías modernas con la finalidad de optimizar la eficacia y productividad sin dejar de lado el nivel de producción, su calidad y el aporte para el cuidado de la sanidad ambiental (Mey et al., 2021; Holzinger et al., 2022; Innocent Kutyauro et al., 2023).

1. Predicción de rendimiento de cultivos mediante IA

Mediante IA es posible identificar el mejor momento para la plantación, permitiendo de esta manera que aumente la productividad, la adaptabilidad y la resistencia, como también, optimizar entre varios aspectos: la economía, el manejo del tiempo y la mano de obra, además de mejorar la sostenibilidad agrícola (Javaid et al., 2023; Huffaker et al., 2024). En el campo de la microbiología y acorde con las poblaciones microbianas y sus curvas de crecimiento es necesario tener en cuenta tres parámetros (el tiempo de retraso, la tasa de crecimiento y el tamaño de la población saturada) junto con los datos relacionados con distintos factores ambientales. Mediante el ML se puede obtener de manera eficaz la dinámica poblacional para poder controlar sus condiciones en un entorno (Aida et al., 2022). De

igual manera, mediante el ML se podrá dar una correcta identificación entre los elementos presentes, detectar impurezas o anomalías que se pueden llegar a presentar en las frutas y verduras, acorde con la medición de su forma, tamaño, color y características biológicas (Javaid et al., 2023; (Vaida Bačiulienė et al., 2023; Jafar et al., 2024; Mana et al., 2024; Chaudhary & Kumar, 2022).

Esta aplicación de algoritmos de ML para los cultivos demuestra ser una herramienta óptima, no solo para obtener información útil respecto a las propiedades de un cultivo en concreto acorde con su análisis morfológico sino que permite predecir y rastrear situaciones ambientales como el cambio climático que puede repercutir en el rendimiento de estos cultivos, mediante el aprendizaje de patrones climáticos históricos (Mey et al., 2021; Javaid et al., 2023; Jafar et al., 2024). En este sentido, mediante el uso de la IA los agricultores pueden llegar a adaptar la gestión agrícola con la finalidad de afrontar los desafíos que puede ofrecer un clima cambiante, incluyéndose en él, la temperatura, la humedad, el clima (Mey et al., 2021; Javaid et al., 2023; Vaida Bačiulienė et al., 2023; Jafar et al., 2024; Seyed Mostafa Biazar et al., 2024). Además, estas herramientas podrán ser aplicadas para identificar nuevas variedades de cultivos que sean más eficientes en el uso de recursos y resistentes acorde con las condiciones climáticas variables (Mey et al., 2021; Javaid et al., 2023; Xaimarie Hernández-Cruz et al., 2023; Divyanshu Tirkey et al., 2023).

Mediante técnicas de imagen junto a la ayuda de la IA se puede evaluar la identificación de las plantas con el fin de obtener una evaluación completa de sus características, entre ellas, las imágenes digitales/RGB, RGB-D, termografía, fluorescencia, tomografía computarizada de rayos X, herramientas que proporcionan información sobre el estado fisiológico de las plantas, la presencia de deficiencias nutricionales y un seguimiento preciso de la etapa de desarrollo de las plantas, su morfología, salud y respuesta al estrés (Nabwire et al., 2021; (SHEIKH et al., 2023; Guduru Dhanush et al., 2023; Xaimarie Hernández-Cruz et al., 2023).

Otros métodos como el mapeo de cultivos basado en datos históricos junto al uso de redes neuronales artificiales que superan a los algoritmos de regresión han sido referidos como capaces de la estimación de la tasa de crecimiento del arroz, la combinación de redes neuronales y algoritmos genéticos con los cuales se podrá determinar en forma precisa la edad del cultivo, optimizando así los recursos asignados garantizando una cosecha oportuna (Innocent Kutyauro et al., 2023; Javaid et al., 2023; Vaida Bačiulienė et al., 2023; Xaimarie Hernández-Cruz et al., 2023; Mana et al., 2024; Ding et al., 2023). Estas herramientas también permiten el Fenotipado de Alto Rendimiento en Plantas donde la integración de plataformas autónomas y drones en las granjas potenciarán la recopilación de datos espaciales y temporales para un análisis más detallado y preciso (SHEIKH et al., 2023; Abia Katimbo et al., 2023).

A través del IoT cognitivo mediante TCN y RNN se puede impulsar el crecimiento de los cultivos, haciendo uso de pruebas de suelo para el análisis de nutrientes y pH del ambiente en específico, teledetección, análisis de imagen y detección de proximidad, entre otros datos recopilados en distintos dispositivos para mejorar su rendimiento. Además, la CNN se considera que es uno de los algoritmos más confiables para estimar el rendimiento de los cultivos (Bhardwaj et al., 2022; Javaid et al., 2023; Seyed Mostafa Biazar et al., 2024; Mana et al., 2024). Por otra parte se han identificado nanoagroquímicos, que incluyen los nanopesticidas y nanofertilizantes que son productos que utiliza la nanotecnología para mejorar la eficiencia y sostenibilidad en la agricultura (Wahab et al., 2024; Ahmed et al., 2023).

2. Diagnóstico automatizado de enfermedades en plantas.

Se han visto desarrollos de aplicaciones móviles inteligentes para diagnosticar enfermedades del trigo con una precisión que ronda hasta el 99% (Innocent Kutyauro et al., 2023), como también el uso de sistemas de IA para identificar la gravedad de enfermedades en cultivos como la pimienta. Por otra parte, se utilizan vehículos aéreos no tripulados vinculados a la nube y algoritmos de IA para detectar plagas en el arroz (Innocent Kutyauro et al., 2023).

En lo relacionado con la identificación, habrá modelos de detección que podrán aprender de grandes conjuntos de datos etiquetados para identificar patrones y características asociadas con enfermedades específicas. Adicionalmente, combinando algoritmos de alto rendimiento con IA, se logra analizar imágenes o datos de sensores para detectar signos tempranos de enfermedades,

permitiendo intervenciones precisas y oportunas (SHEIKH et al., 2023; Vaida Bačiulienė et al., 2023; Jafar et al., 2024).

El uso de biosensores basados en IA puede actuar inclusive en plantas que se podrían considerar asintomáticas, ayudando a que se minimice la pérdida de cultivo basada en estresores bióticos (Bhardwaj et al., 2022). De igual manera, en el contexto de las tecnologías, se encuentran drones basados en IA como EfficientNetV2, ofreciendo una precisión mayor al 99% en la detección de enfermedades de plantas; también hay un modelo de IA híbrido, utilizando autocodificador convolucional y CNN, para la detección de enfermedades bacterianas (Bhardwaj et al., 2022).

Respecto a la IA se han utilizado diferentes modelos como ML, ANN, SVM, Red de Memoria a Corto Plazo (LSTM, por sus siglas en inglés, *Long short-term memory network*), Regresión logística (LR, por sus siglas en inglés, *Logistic regression*), KNN, RF, Clasificación de Máquina Vectorial de Soporte (SVC, por sus siglas en inglés, *Support Vector Machine Classification*), ANN, Función de Base Radial (RBF, por sus siglas en inglés, *Radial Basis Function*), Aprendizaje de Cuantificación Vectorial (LVQ, por sus siglas en inglés, *Learning Vector Quantization*), Perceptrón multicapa (MLP, por sus siglas en inglés, *Multi-layer Perceptron*), los cuales mediante ciertos parámetros meteorológicos históricos brinda datos con los cuales se pueden hacer predicciones ambientales (Gianni Fenu & Francesca Maridina Mallocci, 2021).

3. Aplicaciones de IA en el control de plagas y enfermedades agrícolas

La visión artificial (MV) se ha empleado para desarrollar un sistema inteligente de pulverización que rocía con precisión las malezas sobre cultivos como la pimienta y plantas artificiales, evitando daños a otras plantas no deseadas. Estas tecnologías logran asegurar el uso efectivo de agroquímicos, reduciendo las lesiones en los cultivos y minimizando el desperdicio de estos productos (Innocent Kutyauro et al., 2023; Javaid et al., 2023; Marios Vasileiou et al., 2024). Mediante la IA, es posible el reconocimiento de imágenes, obteniendo algoritmos los cuales, mediante una aplicación, además de identificar y erradicar malezas, hacen una precisa diferenciación entre lo que es un cultivo y una maleza. Es posible, además, detectar y pronosticar de manera temprana enfermedades de plantas y recomendar la medida más eficiente y óptima para brindar un adecuado control de insectos plagas y evidenciar sus ataques inminentes (Javaid et al., 2023; Marios Vasileiou et al., 2024; Vaida Bačiulienė et al., 2023; Jonak et al., 2024).

Por otra parte, el ML permite a los agricultores dar una identificación de las posibles artrópodos plaga y enfermedades que puedan repercutir en el sistema de raíces de la plantación específica en el cultivo (Javaid et al., 2023). Otros modelos, como Big Data, además de la IA y el ML permitirán detectar en tiempo real enfermedades y diferentes plagas, a través de imágenes satelitales (Javaid et al., 2023; Marios Vasileiou et al., 2024). Otros algoritmos avanzados de IA como el Fuzzy Logic, brindará una evaluación detallada y gradual de los datos, especialmente en casos donde las variables no se ajustan fácilmente a categorías binarias, como la presencia de plagas o las condiciones ambientales, esto junto a la ML tienen mucho potencial en la gestión de plagas (Komi Mensah Agboka et al., 2024).

4. Robótica agrícola basada en IA para tareas de cultivo y cosecha.

La robótica agrícola IA está revolucionando las tareas de cultivo y cosecha en la agricultura moderna usando distintos algoritmos como las SVM, los RF, el Vecino más Cercano (KNN, por sus siglas en inglés, *K-nearest neighbors*) y el Refuerzo Adaptativo con la finalidad de predecir la evapotranspiración de cultivos como la remolacha azucarera en regiones semiáridas, siendo el método SVM el más efectivo. Además, la integración del IoT (Vaida Bačiulienė et al., 2023) en sistemas de riego con agentes multi inteligentes y ciber físicos mejoran la eficiencia del uso del agua, permitiendo un suministro más preciso y controlado. La combinación de agentes robóticos y software de monitoreo en el campo optimizarán las operaciones agrícolas, mejorando así la productividad y la sostenibilidad en la agricultura (Vaida Bačiulienė et al., 2023; Xaimarie Hernández-Cruz et al., 2023; Divyanshu Tirkey et al., 2023).

Diversas tecnologías y algoritmos de IA junto con el uso de drones han sido empleados para diversas tareas; mediante las características geográficas del sitio en concreto y distintos criterios que lo componen, puede ayudar a los agricultores a mantener la sostenibilidad e integridad del suelo

mediante una variedad de indicadores biológicos, elegir lugares apropiados para plantar, así como la aplicación de pesticidas. Este monitoreo tiene como finalidad evaluar la salud y el mapeo de cultivos para lograr condiciones óptimas. La IA ha llegado a ser aplicada en robots autónomos de deshierba, utilizando láser de alta potencia mediante el uso de descargas eléctricas (Innocent Kutyauro et al., 2023; Javaid et al., 2023; Vaida Bačiulienė et al., 2023; Xaimarie Hernández-Cruz et al., 2023; Huffaker et al., 2024).

Otras herramientas sistemas de visión artificial como las cámaras de seguridad se usan con el fin de detectar y localizar frutos o cultivos para su seguimiento, además de reconocer tanto animales, humanos u cualquier invasor que pueda llegar a dañar los cultivos. Es un sistema que mediante una computadora analiza imágenes estáticas y en movimiento, proporcionando datos como la nube de puntos 3D, además de la posición de los cultivos o la fruta para cosechar y empacar (Guduru Dhanush et al., 2023; Javaid et al., 2023; Marios Vasileiou et al., 2024; Huffaker et al., 2024).

5. Optimización de sistemas de riego mediante algoritmos de IA.

La optimización de sistemas de riego mediante algoritmos de IA brinda un avance importante en la gestión agrícola pues permite analizar datos en tiempo real, como información sobre el suelo, el clima y las necesidades hídricas de los cultivos (Innocent Kutyauro et al., 2023), para tomar decisiones precisas (Innocent Kutyauro et al., 2023; Mana et al., 2024) y eficientes en cuanto a la cantidad y el momento adecuados para aplicar el riego. Además, cuando se integra la IA en los sistemas de riego (Innocent Kutyauro et al., 2023), se observa una gestión más inteligente y automatizada del agua, lo que permite maximizar el rendimiento de los cultivos y contribuye a la conservación de este recurso vital y a la sostenibilidad de la agricultura (Innocent Kutyauro et al., 2023; Vaida Bačiulienė et al., 2023; Mana et al., 2024).

Mediante estas herramientas se facilita la labor y se logra la economía por el acceso sencillo a la información, archivos y datos recolectados mediante la IA gracias a hardware especializado como las fotos satelitales, IoT, se ha podido optimizar para la mejor toma de decisiones en el riego de las plantas (Holzinger et al., 2023). Además, según el IoT junto a ciertos implementos como controladores, actuadores, sensores, módulos de comunicación, aplicaciones de dispositivos móviles y tecnología en la nube, entre otros, se puede llegar a implementar un sistema de riego inteligente y remoto (Mana et al., 2024).

Con la finalidad de aprovechar bien el recurso agua, se puede generar un análisis de datos en los patrones de riego que den un buen uso de este recurso natural, disminuya el riesgo de escasez y favorezca al ambiente (Javaid et al., 2023). De igual manera, y para dar un riego eficiente y efectivo, además de poder medirse en este suelo la humedad y los requisitos fundamentales para incorporarse en los cultivos se han llegado a dar innovaciones en la tecnología de la IA con la lógica difusa, los algoritmos metaheurísticos y las redes neuronales artificiales (Bhardwaj et al., 2022; Mana et al., 2024).

Inteligencia artificial en procesos de biorremediación

1. Modelado de la degradación de contaminantes con IA.

En el contexto de la contaminación por hidrocarburos, el uso de IA, como ANN, SVM y los ANFIS tiene gran relevancia debido a que estas herramientas avanzadas de modelado permiten predecir y optimizar los procesos de degradación de contaminantes; a través de ese monitoreo se pueden tomar medidas para remediar la calidad ambiental, optimizar condiciones de crecimiento para la degradación de hidrocarburos, identificar fuentes de contaminación en cuerpos de agua, y predecir propiedades reológicas de derivados del petróleo brindando de esta manera una mejor comprensión respecto a la complejidad de los procesos de biorremediación. Por otra parte, se puede hacer una prevención con cierto nivel de precisión sobre las condiciones óptimas para la degradación y eliminación eficiente de los hidrocarburos (Salgado et al., 2023; Matthew Ndubuisi Abonyi et al., 2023; Rupshikha Patowary et al., 2023; Dmitrii Shadrin et al., 2020).

Otras herramientas complementarias como la simulación de Monte Carlo (MCS, por sus siglas en inglés, *Monte Carlo simulation*), los Algoritmos Inmunes Artificiales (AIS, por sus siglas en inglés,

Artificial Immune Systems), los Árboles de regresión Potenciados (BRT, por sus siglas en inglés, *Boosted Regression Tree*) y los Algoritmos de Colonia de Hormigas (ACA, por sus siglas en inglés, *Ant Colony Algorithm*), además de RSM junto con algoritmos como la propagación posterior Levenberg-Marquardt, el algoritmo Otsu y el Algoritmo de Región Extrema Máximamente Estable (MSERA, por sus siglas en inglés, *Maximally Stable Extremal Region Algorithm*), ayudan en diversas tareas, incluida la simulación de procesos de degradación y la detección automática de derrames de petróleo. Estos enfoques mejoran la eficiencia y precisión de los procesos de restauración ambiental (Rupshikha Patowary et al., 2023; Dmitrii Shadrin et al., 2020).

Las tecnologías de imágenes microplásticas basadas en IA son una herramienta importante y con potencial en el modelado de la degradación de contaminantes, especialmente en los ecosistemas marinos, permitiendo la identificación y cuantificación precisa de este contaminante. Además, estas tecnologías están transformando la investigación tradicional sobre este tipo de contaminación, mejorando la eficiencia operativa y facilitando una comprensión más completa de este problema ambiental (Zhang, Zhang, et al., 2023).

2. Diseño asistido por IA de microorganismos modificados para la biorremediación.

Algunos microorganismos o sus productos cuando se modifican tienen la capacidad para biorremediar. Es el caso de la fucoxantina carotenoide presente en diversas microalgas, como las algas pardas y las diatomeas, la cual contribuyen en la biorremediación al mejorar la capacidad de los microorganismos para degradar contaminantes en aguas y suelos polucionados con metales pesados y compuestos orgánicos tóxicos (Roy et al., 2023). En este sentido, para optimizar la extracción y uso de fucoxantina en estos procesos, gracias a la IA se pueden utilizar diferentes modelos como la Metodología de Superficie de Respuesta (RSM, por sus siglas en inglés, *Response Surface Methodology*), ANN, Algoritmos Genéticos (GA, por sus siglas en inglés, *Genetic Algorithm*) y el Sistema de Inferencia Neuro-Fuzzy Adaptativo (ANFIS, por sus siglas en inglés, *Adaptive Neuro Fuzzy Inference System*), los cuales aumentan el rendimiento de extracción, permitiendo de esta manera reducir costos y mejorar la eficiencia del proceso, facilitando así su aplicación en la biorremediación (Roy et al., 2023).

Finalmente, mediante ANN para la optimización de la producción de una enzima fúngica denominada lipasa, es posible hacer más eficiente la producción de biodiesel mediante desechos aceitosos de origen agrícola y alimentario, logrando una mejor producción de Diesel con mejor eficiencia y a menores costos (El-Metwally et al., 2023).

3. Control automatizado de procesos de tratamiento de aguas residuales.

Las microalgas son organismos altamente eficientes en términos de crecimiento y fotosíntesis, lo que las hace valiosas para diversas aplicaciones, siendo las más importante, el tratamiento de aguas residuales, esto debido a su capacidad para eliminar eficientemente los contaminantes, al mismo tiempo que crecen de manera acelerada gracias al nitrógeno y fósforo que se encuentran en este medio. Sin embargo, el tratamiento tradicional de estas aguas residuales presenta limitaciones, que podría mejorarse empleando ciertos modelos, como ANN, para predecir y optimizar variables de proceso junto con GA, para brindar una mejor comprensión de los nutrientes que afectan el crecimiento de estas microalgas y cómo eliminan estos contaminantes para determinar las variables clave del proceso, su impacto en la productividad de la biomasa y la eliminación de nutrientes contribuyendo significativamente en la eficiencia y sostenibilidad de los sistemas de tratamiento de aguas residuales basados en microalgas (Salgado et al., 2023).

4. Simulación de escenarios de biorremediación con técnicas de IA.

Gracias a la integración de tres tecnologías, IA, ML y DL se pueden analizar extensos conjuntos de datos brindando una mejora en la comprensión de la contaminación, reduciendo la necesidad de muestreo y los costos en las pruebas de laboratorio, optimizando de esta manera la selección de técnicas de remediación. Los resultados mejoran notablemente y se logra de esta manera una limpieza más efectiva y eficiente, minimizando los riesgos para la salud humana y los ecosistemas (Jagadeesh Kumar Janga et al., 2023).

En lo referente a contaminación con plomo y zinc en suelos, la IA va a mejorar significativamente el control de la contaminación, utilizando varios enfoques: Modelado Predictivo de la IA que analiza factores geológicos, mineros y climáticos para identificar zonas de alto riesgo, facilitando una asignación eficiente de recursos, uso de sensores y drones impulsados por IA que permiten monitorear la calidad del suelo en tiempo real y detectar tempranamente la contaminación y la optimización de los esfuerzos de remediación, lo cual se logra mediante algoritmos que analizan datos del suelo y determinan las estrategias más eficaces. Se observa, entonces como la IA proporciona soluciones costo-efectivas al enfocar recursos en áreas críticas, ahorrando además materia prima (Atoosa Haghighizadeh et al., 2024; El-Metwally et al., 2023).

Inteligencia artificial en la sostenibilidad ambiental

Mediante el uso de la IA se busca mejorar los sistemas de gestión de recursos y la mitigación de efectos ambientales, debido a que estos impactos ambientales pueden tener un efecto en las distintas poblaciones biológicas incluidos los microbiomas. El manejo de gran cantidad de datos ambientales permite a través de la IA una toma de decisiones en pro de reducir distintas fuentes de impactos ambientales.

1. Análisis de impactos ambientales con modelos de IA.

La IA tiene un enorme impacto en el monitoreo y pronósticos en las ciencias de la tierra, ayudando a enfrentar problemáticas ambientales recientes (Sun et al., 2022). Se aplica en la atmósfera, geosfera, hidrología, criosfera, oceanografía y biosfera, facilitando el monitoreo a corto y largo plazo y la identificación de perturbaciones naturales y humanas (Figura 6) (Chowdhury et al., 2024). La IA analiza aspectos como condiciones climáticas, perturbaciones del ecosistema, calidad de aire, agua y suelo, actividades geológicas y principios de vida en la tierra (Sun et al., 2022), optimizando procesos y generando datos para comprender impactos ambientales y resolver problemas importantes (Sun et al., 2022). En cuanto a la contaminación del agua, la IA mejora el monitoreo y la toma de decisiones para el tratamiento del agua, analizando su impacto en la salud pública y ecosistemas (Staša Puškarić et al., 2024; Emmanuel Kwame Nti et al., 2023; El et al., 2023). Esto se relaciona directamente con los Objetivos de Desarrollo Sostenible de la ONU sobre agua potable y saneamiento (Emmanuel Kwame Nti et al., 2023).




Figura 6. Imágenes obtenidas con IA. Se representa la aplicabilidad para el análisis de impactos ambientales desde las ciencias de la tierra.

2. Optimización de la gestión de residuos mediante algoritmos de IA.

La gestión adecuada de residuos es clave para el desarrollo sostenible, tiene un impacto importante ya que de aquí surgen los xenobióticos que tienen efectos negativos ambientales y que representa en términos microbianos afectaciones en la composición de una comunidad microbiana. La IA optimiza este proceso determinando el destino final más adecuado de los residuos según diversos modelos de ML. Adicionalmente, facilita la conversión de residuos en energía y su clasificación para distintos fines, mejorando los planes de gestión y alineándose con los objetivos de desarrollo sostenible, especialmente en reciclaje (Fang et al., 2023).

En las "ciudades inteligentes", la gestión de residuos fomenta una "economía circular sin residuos" centrada en el reciclaje, la reutilización y el tratamiento adecuado de los residuos. La IA considera factores geográficos, tasas de generación de residuos, instalaciones, transporte y costos, mejora la toma de decisiones, posicionándola como una tecnología viable para la gestión de residuos (Fang et al., 2023).

Conclusiones y Perspectivas a futuro

La inteligencia artificial (IA) está transformando las ciencias agroambientales, especialmente la microbiología ambiental, con un potencial significativo para optimizar diversos procesos. Aunque todavía en fase de implementación, su llegada es inminente y promete mejoras en la precisión de análisis ambientales, sistemas productivos de cultivos, y la gestión sostenible de recursos naturales.

La IA se destaca por su capacidad para analizar grandes volúmenes de datos y generar patrones útiles, facilitando decisiones más acertadas en laboratorios de microbiología, cultivos y eco ciudades. En el futuro, la integración de IA con IoT, robótica, sensores y drones ampliará aún más sus aplicaciones en el campo agroambiental, respondiendo a nuevas necesidades y mejorando procesos.

El desarrollo de algoritmos más sofisticados y una creciente disponibilidad de datos ambientales impulsarán avances en microbiología y áreas afines. Para aprovechar plenamente estas tecnologías, científicos, ingenieros, agricultores y formuladores de políticas deben actualizarse constantemente. Con un enfoque multidisciplinario, la IA tiene el potencial de contribuir significativamente a la sostenibilidad ambiental, siempre considerando los aspectos éticos y sociales para asegurar soluciones inclusivas.

Referencias:

- Abia Katimbo, Rudnick, D. R., Zhang, J., Ge, Y., DeJonge, K. C., Franz, T. E., Shi, Y., Liang, W., Qiao, X., Heeren, D. M., Kabenge, I., Hope Njuki Nakabuye, & Duan, J. (2023). Evaluation of artificial intelligence algorithms with sensor data assimilation in estimating crop evapotranspiration and crop water stress index for irrigation water management. *Smart Agricultural Technology*, 4, 100176. <https://doi.org/10.1016/j.atech.2023.100176>
- Ahmed, A., He, P., He, P., Wu, Y., He, Y., & Munir, S. (2023). Environmental effect of agriculture-related manufactured nano-objects on soil microbial communities. *Environment International*, 173, 107819. <https://doi.org/10.1016/j.envint.2023.107819>
- Aida, H., Hashizume, T., Kazuha Ashino, & Ying, B.-W. (2022). Machine learning-assisted discovery of growth decision elements by relating bacterial population dynamics to environmental diversity. *ELife*, 11. <https://doi.org/10.7554/eLife.76846>
- Ali, T., Ahmed, S., & Aslam, M. (2023). Artificial intelligence for antimicrobial resistance prediction: Challenges and opportunities towards practical implementation. *Antibiotics (Basel, Switzerland)*, 12(3). <https://doi.org/10.3390/antibiotics12030523>
- Asala Mahajna, Dinkla, I. J. T., Euverink, J. W., Keesman, K. J., & Bayu Jayawardhana. (2022). Clean and safe drinking water systems via metagenomics data and artificial intelligence: State-of-the-art and future perspective. *Frontiers in Microbiology*, 13, 832452. <https://doi.org/10.3389/fmicb.2022.832452>
- Atoosa Haghhighizadeh, Rajabi, O., Arman Nezarat, Zahra Hajyani, Haghmohammadi, M., Soheila Hedayatikhah, Soheila Delnabi Asl, & Ali Aghababai Beni. (2024). Comprehensive analysis of heavy metal soil contamination in mining Environments: Impacts, monitoring Techniques, and remediation strategies. *Arabian Journal of Chemistry*, 17(6), 105777. <https://doi.org/10.1016/j.arabjc.2024.105777>
- Bhardwaj, A., Kishore, S., & Pandey, D. K. (2022). Artificial intelligence in biological sciences. *Life (Basel, Switzerland)*, 12(9). <https://doi.org/10.3390/life12091430>
- C.H. Pérez-Beltrán, Robles, A. D., Rodriguez, N. A., F. Ortega-Gavilán, & A.M. Jiménez-Carvelo. (2024). Artificial intelligence and water quality: From drinking water to wastewater. *TrAC Trends in Analytical Chemistry*, 172, 117597. <https://doi.org/10.1016/j.trac.2024.117597>
- Cai, D., Aziz, G., Sarwar, S., Majid Ibrahim Alsaggaf, & Sinha, A. (2024). Applicability of denoising-based artificial intelligence to forecast the environmental externalities. *Geoscience Frontiers*, 15(3), 101740. <https://doi.org/10.1016/j.gsf.2023.101740>
- Chaudhary, B., & Kumar, V. (2022). Emerging technological frameworks for the sustainable agriculture and environmental management. *Sustainable Horizons*, 3, 100026. <https://doi.org/10.1016/j.horiz.2022.100026>
- Chowdhury, M., Alejo Martínez-Sansigre, Mole, M., Alonso-Peleato, E., Nadiia Basos, Jose Manuel Blanco, Ramirez-Nicolas, M., Caballero, I., & Ignacio. (2024). AI-driven remote sensing enhances Mediterranean seagrass monitoring and conservation to combat climate change and anthropogenic impacts. *Scientific Reports*, 14(1), 8360. <https://doi.org/10.1038/s41598-024-59091-7>
- Chu, E. W., & Karr, J. R. (2017). Environmental impact: Concept, consequences, measurement ☆. In *Reference Module in Life Sciences*. Elsevier. <https://doi.org/10.1016/B978-0-12-809633-8.02380-3>
- Danijela Šantić, Kasia Piwosz, Frano Matic, Ana Vrdoljak Tomaš, Jasna Arapov, Jason Lawrence Dean, Mladen Šolić, Koblížek, M., Grozdan Kušpilić, & Stefanija Šestanović. (2021). Artificial neural network analysis of microbial diversity in the central and southern Adriatic Sea. *Scientific Reports*, 11(1), 11186. <https://doi.org/10.1038/s41598-021-90863-7>
- Diaz-Gonzalez, F. A., Vuelvas, J., Correa, C. A., Vallejo, V. E., & Patino, D. (2022). Machine learning and remote sensing techniques applied to estimate soil indicators – Review. *Ecological Indicators*, 135, 108517. <https://doi.org/10.1016/j.ecolind.2021.108517>
- Ding, H., Tian, J., Yu, W., Wilson, D. I., Young, B. R., Cui, X., Xin, X., Wang, Z., & Li, W. (2023). The application of artificial intelligence and big data in the food industry. *Foods (Basel, Switzerland)*, 12(24). <https://doi.org/10.3390/foods12244511>
- Divyanshu Tirkey, Kshitiz Kumar Singh, & Tripathi, S. (2023). Performance analysis of AI-based solutions for crop disease identification, detection, and classification. *Smart Agricultural Technology*, 5, 100238. <https://doi.org/10.1016/j.atech.2023.100238>
- Dmitrii Shadrin, Mariia Pukalchik, Ekaterina Kovaleva, & Fedorov, M. (2020). Artificial intelligence models to predict acute phytotoxicity in petroleum contaminated soils. *Ecotoxicology and Environmental Safety*, 194, 110410. <https://doi.org/10.1016/j.ecoenv.2020.110410>

- Egli, A., J Schrenzel, & G Greub. (2020). Digital microbiology. *Clinical Microbiology and Infection : The Official Publication of the European Society of Clinical Microbiology and Infectious Diseases*, 26(10), 1324–1331. <https://doi.org/10.1016/j.cmi.2020.06.023>
- El, A., Mandi, L., Aya Kammoun, Naaila Ouazzani, Monga, O., & Moulay Lhassan Hbid. (2023). Artificial intelligence and wastewater treatment: A global scientific perspective through text mining. *Water*, 15(19), 3487. <https://doi.org/10.3390/w15193487>
- El-Metwally, M. M., Abdel-Fattah, G. M., Al-Otibi, F. O., Dina K.H.EL. Khatieb, Helmy, Y. A., Mohammed, Y. M. M., & Saber, W. I. A. (2023). Application of artificial neural networks for enhancing *Aspergillus flavipes* lipase synthesis for green biodiesel production. *Heliyon*, 9(9), e20063. <https://doi.org/10.1016/j.heliyon.2023.e20063>
- Emmanuel Kwame Nti, Samuel Jerry Cobbina, Eunice Efua Attafuah, Lydia Dziedzorm Senanu, Amenyeku, G., Michael Amoah Gyan, Forson, D., & Safo, A.-R. (2023). Water pollution control and revitalization using advanced technologies: Uncovering artificial intelligence options towards environmental health protection, sustainability and water security. *Heliyon*, 9(7), e18170. <https://doi.org/10.1016/j.heliyon.2023.e18170>
- Fang, B., Yu, J., Chen, Z., Osman, A. I., Farghali, M., Ihara, I., Hamza, E. H., Rooney, D. W., & Yap, P.-S. (2023). Artificial intelligence for waste management in smart cities: a review. *Environmental Chemistry Letters*, 1–31. <https://doi.org/10.1007/s10311-023-01604-3>
- Francisco Castillo Díaz. (2022). Cinco aplicaciones de la inteligencia artificial en agricultura. In *Plataforma Tierra*.
- Ghannam, R. B., & Techtmann, S. M. (2021). Machine learning applications in microbial ecology, human microbiome studies, and environmental monitoring. *Computational and Structural Biotechnology Journal*, 19, 1092–1107. <https://doi.org/10.1016/j.csbj.2021.01.028>
- Gianni Fenu, & Francesca Maridina Mallocci. (2021). Forecasting plant and crop disease: An explorative study on current algorithms. *Big Data and Cognitive Computing*, 5(1), 2. <https://doi.org/10.3390/bdcc5010002>
- Goodswen, S. J., Barratt, J. L. N., Kennedy, P. J., Kaufer, A., Calarco, L., & Ellis, J. T. (2021). Machine learning and applications in microbiology. *FEMS Microbiology Reviews*, 45(5). <https://doi.org/10.1093/femsre/fuab015>
- Guduru Dhanush, Khatri, N., Kumar, S., & Praveen Kumar Shukla. (2023). A comprehensive review of machine vision systems and artificial intelligence algorithms for the detection and harvesting of agricultural produce. *Scientific African*, 21, e01798. <https://doi.org/10.1016/j.sciaf.2023.e01798>
- Gupta, A., Gupta, R., & Ram Lakhan Singh. (2017). Microbes and environment. In *Principles and Applications of Environmental Biotechnology for a Sustainable Future* (pp. 43–84). Springer Singapore. https://doi.org/10.1007/978-981-10-1866-4_3
- Hayati, R., Agus Arip Munawar, Endang Lukitaningsih, Nanda Earlia, Taufiq Karma, & Rinaldi Idroes. (2024). Combination of PCA with LDA and SVM classifiers: A model for determining the geographical origin of coconut in the coastal plantation, Aceh Province, Indonesia. *Case Studies in Chemical and Environmental Engineering*, 9, 100552. <https://doi.org/10.1016/j.cscee.2023.100552>
- Holzinger, A., Keiblinger, K., Holub, P., Zatloukal, K., & Heimo Müller. (2023). AI for life: Trends in artificial intelligence for biotechnology. *New Biotechnology*, 74, 16–24. <https://doi.org/10.1016/j.nbt.2023.02.001>
- Holzinger, A., Saranti, A., Alessa Angerschmid, Carl Orge Retzlaff, Gronauer, A., Vladimir Pejakovic, Medel-Jimenez, F., Krexner, T., Gollob, C., & Stampfer, K. (2022). Digital transformation in smart farm and forest operations needs human-centered AI: Challenges and future directions. *Sensors*, 22(8), 3043. <https://doi.org/10.3390/s22083043>
- Huffaker, R., Muñoz-Carpena, R., & Migliaccio, K. W. (2024). Sensor records can be used to forecast complex soil moisture dynamics with symbiosis of empirical nonlinear dynamics and echo state neural network AI. *Computers and Electronics in Agriculture*, 222, 109031. <https://doi.org/10.1016/j.compag.2024.109031>
- Ihsan, A., Khairul Muttaqin, Rahmatul Fajri, Mursyidah Mursyidah, & Islam. (2023). Innovative bacterial colony detection: Leveraging multi-feature selection with the improved salp swarm algorithm. *Journal of Imaging*, 9(12), 263. <https://doi.org/10.3390/jimaging9120263>
- Innocent Kutyauro, Munyaradzi Rushambwa, & Lyndah Chiwazi. (2023). Artificial intelligence applications in the agrifood sectors. *Journal of Agriculture and Food Research*, 11, 100502. <https://doi.org/10.1016/j.jafr.2023.100502>
- Jafar, A., Bibi, N., Rizwan Ali Naqvi, Abolghasem Sadeghi-Niaraki, & Jeong, D. (2024). Revolutionizing agriculture with artificial intelligence: plant disease detection methods,

- applications, and their limitations. *Frontiers in Plant Science*, 15, 1356260. <https://doi.org/10.3389/fpls.2024.1356260>
- Jagadeesh Kumar Janga, Reddy, K. R., & K.V.N.S. Raviteja. (2023). Integrating artificial intelligence, machine learning, and deep learning approaches into remediation of contaminated sites: A review. *Chemosphere*, 345, 140476. <https://doi.org/10.1016/j.chemosphere.2023.140476>
- James, Mary Krystelle Catacutan, Aurelie Mawart, Hasan, A., & Dias, J. (2022). Interfacing machine learning and microbial omics: A promising means to address environmental challenges. *Frontiers in Microbiology*, 13. <https://doi.org/10.3389/fmicb.2022.851450>
- Javaid, M., Haleem, A., Ibrahim Haleem Khan, & Suman, R. (2023). Understanding the potential applications of artificial intelligence in agriculture sector. *Advanced Agrochem*, 2(1), 15–30. <https://doi.org/10.1016/j.aac.2022.10.001>
- Jiang, Y., Luo, J., Huang, D., Liu, Y., & Li, D. (2022). Machine learning advances in microbiology: A review of methods and applications. *Frontiers in Microbiology*, 13. <https://doi.org/10.3389/fmicb.2022.925454>
- Jonak, M., Mucha, J., Jezek, S., Kovac, D., & Kornel Cziria. (2024). SPAGRI-AI: Smart precision agriculture dataset of aerial images at different heights for crop and weed detection using super-resolution. *Agricultural Systems*, 216, 103876. <https://doi.org/10.1016/j.agsy.2024.103876>
- Kapur, R. (2019). *Environmental microbiology and components of the environment*.
- Kobra Salimiyan rizi, & Ashrafi, A. (2023). Biosensors, mechatronics, & microfluidics for early detection & monitoring of microbial corrosion: A comprehensive critical review. *Results in Materials*, 18, 100402. <https://doi.org/10.1016/j.rinma.2023.100402>
- Komi Mensah Agboka, Henri, Abdel-Rahman, E. M., Odindi, J., Onesimo Mutanga, & Saliou Niassy. (2024). Leveraging computational intelligence to identify and map suitable sites for scaling up augmentative biological control of cereal crop pests. *Biological Control*, 190, 105459. <https://doi.org/10.1016/j.biocontrol.2024.105459>
- Krenn, M., Pollice, R., Si Yue Guo, Matteo Aldeghi, Cervera-Lierta, A., Friederich, P., Gabriel, Florian Häse, Jinich, A., Nigam, A., Yao, Z., & Alán Aspuru-Guzik. (2022). On scientific understanding with artificial intelligence. *Nature Reviews Physics*, 4(12), 761–769. <https://doi.org/10.1038/s42254-022-00518-3>
- Kumar, R., Yadav, G., Kuddus, M., Ghulam Md Ashraf, & Singh, R. (2023). Unlocking the microbial studies through computational approaches: how far have we reached? *Environmental Science and Pollution Research*, 30(17), 48929–48947. <https://doi.org/10.1007/s11356-023-26220-0>
- Liang, Q., Bible, P. W., Liu, Y., Zou, B., & Wei, L. (2020). DeepMicrobes: taxonomic classification for metagenomics with deep learning. *NAR Genomics and Bioinformatics*, 2(1). <https://doi.org/10.1093/nargab/lqaa009>
- Lu, Y., Lu, X., Zheng, L., Sun, M., Chen, S., Chen, B., Wang, T., Yang, J., & Chunli Lv. (2024). Application of multimodal transformer model in intelligent agricultural disease detection and question-answering systems. *Plants*, 13(7), 972. <https://doi.org/10.3390/plants13070972>
- Mana, A. A., A. Allouhi, A. Hamrani, Rehman, S., I. el Jamaoui, & K. Jayachandran. (2024). Sustainable AI-based production agriculture: Exploring AI applications and implications in agricultural practices. *Smart Agricultural Technology*, 7, 100416. <https://doi.org/10.1016/j.atech.2024.100416>
- Marios Vasileiou, Leonidas Sotirios Kyrgiakos, Kleisiari, C., Georgios Kleftodimos, Vlontzos, G., Hatem Belhouchette, & Pardalos, P. M. (2024). Transforming weed management in sustainable agriculture with artificial intelligence: A systematic literature review towards weed identification and deep learning. *Crop Protection*, 176, 106522. <https://doi.org/10.1016/j.cropro.2023.106522>
- Matthew Ndubuisi Abonyi, Joseph Tagbo Nwabanne, Paschal Enyinnaya Ohale, Emmanuel Chinagorom Nwadike, Igbonekwu, L. I., Monday Morgan Chukwu, & Emeka Michael Madiebo. (2023). Application of RSM and ANFIS in the optimal parameter evaluation for crude oil degradation in contaminated water amended with PES. *Case Studies in Chemical and Environmental Engineering*, 8, 100483. <https://doi.org/10.1016/j.cscee.2023.100483>
- Mey, F., Clauwaert, J., Kirsten Van Huffel, Willem Waegeman, & Marjan De Mey. (2021). Improving the performance of machine learning models for biotechnology: The quest for deus ex machina. *Biotechnology Advances*, 53, 107858. <https://doi.org/10.1016/j.biotechadv.2021.107858>
- Miller, T., Grzegorz Mikiciuk, Kisiel, A., Małgorzata Mikiciuk, Paliwoda, D., Sas-Paszt, L., Cembrowska-Lech, D., Krzemińska, A., Agnieszka Kozioł, & Brysiewicz, A. (2023). Machine

- learning approaches for forecasting the best microbial strains to alleviate drought impact in agriculture. *Agriculture*, 13(8), 1622. <https://doi.org/10.3390/agriculture13081622>
- Molik, D. C., Tomlinson, D., Davitt, S., Morgan, E. L., Sisk, M., Roche, B., Meyers, N., & Pfrender, M. E. (2021). Combining natural language processing and metabarcoding to reveal pathogen-environment associations. *PLoS Neglected Tropical Diseases*, 15(4), e0008755. <https://doi.org/10.1371/journal.pntd.0008755>
- Muhammad Awais, Syed, Zhang, H., Li, L., Zhang, W., Awwad, F. A., Ismail, E. A. A., M Ijaz Khan, Raghavan, V., & Hu, J. (2023). AI and machine learning for soil analysis: an assessment of sustainable agricultural practices. *Bioresources and Bioprocessing*, 10(1), 90. <https://doi.org/10.1186/s40643-023-00710-y>
- Muhammad, Wang, S., Wang, J., Ahmar, S., Saeed, S., Shahid Ullah Khan, Xu, X., Chen, H., Javaid Akhter Bhat, & Feng, X. (2022). Applications of artificial intelligence in climate-resilient smart-crop breeding. *International Journal of Molecular Sciences*, 23(19). <https://doi.org/10.3390/ijms231911156>
- Mukhamediev, R. I., Popova, Y., Kuchin, Y., Zaitseva, E., Almas Kalimoldayev, Adilkhan Symagulov, Vitaly Levashenko, Farida Abdoldina, Viktors Gopejenko, Kirill Yakunin, Muhamedijeva, E., & Yelis, M. (2022). Review of artificial intelligence and machine learning technologies: Classification, restrictions, opportunities and challenges. *Mathematics*, 10(15), 2552. <https://doi.org/10.3390/math10152552>
- Nabwire, S., Suh, H.-K., Kim, M. S., Baek, I., & Cho, B.-K. (2021). Review: Application of artificial intelligence in phenomics. *Sensors*, 21(13), 4363. <https://doi.org/10.3390/s21134363>
- Noé Manuel Montaña, Sandoval, A., Camargo, S., & Sánchez, J. (2010). Los microorganismos: pequeños gigantes. *Elementos: Ciencia Y Cultura*, 17, 15–23.
- Oscar Leonardo García-Navarrete, Correa-Guimaraes, A., & Luis Manuel Navas-Gracia. (2024). Application of convolutional neural networks in weed detection and identification: A systematic review. *Agriculture*, 14(4), 568. <https://doi.org/10.3390/agriculture14040568>
- Peyman Namadi, & Deng, Z. (2023). Deep learning-based ensemble modeling of *Vibrio parahaemolyticus* concentration in marine environment. *Environmental Monitoring and Assessment*, 195(1), 229. <https://doi.org/10.1007/s10661-022-10836-9>
- Pichler, M., & Hartig, F. (2023). Machine learning and deep learning—A review for ecologists. *Methods in Ecology and Evolution*, 14(4), 994–1016. <https://doi.org/10.1111/2041-210X.14061>
- Ricardo Hernández Medina, Kutuzova, S., Knud Nor Nielsen, Johansen, J., Lars Hestbjerg Hansen, Nielsen, M., & Rasmussen, S. (2022). Machine learning and deep learning applications in microbiome research. *ISME Communications*, 2(1). <https://doi.org/10.1038/s43705-022-00182-9>
- Robinson, S. L. (2022). Artificial intelligence for microbial biotechnology: beyond the hype. *Microbial Biotechnology*, 15(1), 65–69. <https://doi.org/10.1111/1751-7915.13943>
- Roy, W., Ying, D., Hui Yi Leong, Kuan Shiong Khoo, Pau Loke Show, & Kit Wayne Chew. (2023). Bridging artificial intelligence and fucoxanthin for the recovery and quantification from microalgae. *Bioengineered*, 14(1). <https://doi.org/10.1080/21655979.2023.2244232>
- Rupshikha Patowary, Devi, A., & Mukherjee, A. K. (2023). Advanced bioremediation by an amalgamation of nanotechnology and modern artificial intelligence for efficient restoration of crude petroleum oil-contaminated sites: a prospective study. *Environmental Science and Pollution Research*, 30(30), 74459–74484. <https://doi.org/10.1007/s11356-023-27698-4>
- Salgado, E. M., Esteves, A. F., Gonçalves, A. L., & Pires, J. C. M. (2023). Microalgal cultures for the remediation of wastewaters with different nitrogen to phosphorus ratios: Process modelling using artificial neural networks. *Environmental Research*, 231, 116076. <https://doi.org/10.1016/j.envres.2023.116076>
- Seyed Mostafa Biazar, Shehadeh, H. A., Mohammad Ali Ghorbani, Golmar Golmohammadi, & Saha, A. (2024). Soil temperature forecasting using a hybrid artificial neural network in Florida subtropical grazinglands agro-ecosystems. *Scientific Reports*, 14(1), 1535. <https://doi.org/10.1038/s41598-023-48025-4>
- Sheikh, H., Prins, C., & Schrijvers, E. (2023). *Artificial intelligence: Definition and background* (pp. 15–41). https://doi.org/10.1007/978-3-031-21448-6_2
- SHEIKH, M., Farooq IQRA, Hamadani AMBREEN, PRAVIN, K. A., Manzoor IKRA, & Yong Suk CHUNG. (2023). Integrating artificial intelligence and high-throughput phenotyping for crop improvement. *Journal of Integrative Agriculture*. <https://doi.org/10.1016/j.jia.2023.10.019>
- Shelke, Y. P., Badge, A. K., & Bankar, N. J. (2023). Applications of artificial intelligence in microbial diagnosis. *Cureus*, 15(11), e49366. <https://doi.org/10.7759/cureus.49366>

- Soma Safeer, Pandey, R. P., Rehman, B., Safdar, T., Ahmad, I., Hasan, S. W., & Ullah, A. (2022). A review of artificial intelligence in water purification and wastewater treatment: Recent advancements. *Journal of Water Process Engineering*, 49, 102974. <https://doi.org/10.1016/j.jwpe.2022.102974>
- Spyridon Mourtzinis, Esker, P. D., Specht, J. E., & Conley, S. P. (2021). Advancing agricultural research using machine learning algorithms. *Scientific Reports*, 11(1), 17879. <https://doi.org/10.1038/s41598-021-97380-7>
- Staša Puškarić, Mateo Sokač, Živana Ninčević, Danijela Šantić, Skejić, S., Tomislav Džoić, Prelesnik, H., & Knut Yngve Børshem. (2024). Extracted spectral signatures from the water column as a tool for the prediction of the structure of a marine microbial community. *Journal of Marine Science and Engineering*, 12(2), 286. <https://doi.org/10.3390/jmse12020286>
- Sun, R., Tu, Z., Fan, L., Qiao, Z., Liu, X., Hu, S., Zheng, G., Wu, Y., Wang, R., & Mi, X. (2020). The correlation analyses of bacterial community composition and spatial factors between freshwater and sediment in Poyang Lake wetland by using artificial neural network (ANN) modeling. *Brazilian Journal of Microbiology* : [Publication of the Brazilian Society for Microbiology], 51(3), 1191–1207. <https://doi.org/10.1007/s42770-020-00285-2>
- Sun, Z., Sandoval, L., Crystal-Ornelas, R., S. Mostafa Mousavi, Wang, J., Lin, C., Cristea, N., Tong, D., Wendy Hawley Carande, Ma, X., Rao, Y., Bednar, J. A., Tan, A., Wang, J., Sanjay Purushotham, Gill, T. E., Chastang, J., Howard, D., Holt, B., & Chandana Gangodagamage. (2022). A review of earth artificial intelligence. *Computers & Geosciences*, 159, 105034. <https://doi.org/10.1016/j.cageo.2022.105034>
- Terence, S., & Geethanjali Purushothaman. (2020). Systematic review of Internet of Things in smart farming. *Transactions on Emerging Telecommunications Technologies*, 31(6). <https://doi.org/10.1002/ett.3958>
- Ubina, N. A., Lan, H.-Y., Cheng, S.-C., Chang, C.-C., Lin, S.-S., Zhang, K.-X., Lu, H.-Y., Cheng, C.-Y., & Hsieh, Y.-Z. (2023). Digital twin-based intelligent fish farming with Artificial Intelligence Internet of Things (AIoT). *Smart Agricultural Technology*, 5, 100285. <https://doi.org/10.1016/j.atech.2023.100285>
- Vaida Bačiulienė, Bilan, Y., Navickas, V., & Lubomír Cívín. (2023). The aspects of artificial intelligence in different phases of the food value and supply chain. *Foods (Basel, Switzerland)*, 12(8). <https://doi.org/10.3390/foods12081654>
- Wahab, A., Muhammad, M., Ullah, S., Abdi, G., Ghulam Mujtaba Shah, Zaman, W., & Ayaz, A. (2024). Agriculture and environmental management through nanotechnology: Eco-friendly nanomaterial synthesis for soil-plant systems, food safety, and sustainability. *Science of the Total Environment*, 926, 171862. <https://doi.org/10.1016/j.scitotenv.2024.171862>
- Walsh, C., Elías Stallard-Olivera, & Fierer, N. (2024). Nine (not so simple) steps: a practical guide to using machine learning in microbial ecology. *MBio*, 15(2). <https://doi.org/10.1128/mbio.02050-23>
- Wang, J., Zhen, J., Hu, W., Chen, S., Lizaga, I., Mojtaba Zeraatpisheh, & Yang, X. (2023). Remote sensing of soil degradation: Progress and perspective. *International Soil and Water Conservation Research*, 11(3), 429–454. <https://doi.org/10.1016/j.iswcr.2023.03.002>
- Wu, J., & Zhao, F. (2023). Machine learning: An effective technical method for future use in assessing the effectiveness of phosphorus-dissolving microbial agromediation. *Frontiers in Bioengineering and Biotechnology*, 11. <https://doi.org/10.3389/fbioe.2023.1189166>
- Xaimarie Hernández-Cruz, Villalobos, J. R., Runger, G., & Neal, G. (2023). Building an intelligent system to identify trends in agricultural markets. *Journal of Cleaner Production*, 425, 138956. <https://doi.org/10.1016/j.jclepro.2023.138956>
- Xu, Y., Liu, X., Cao, X., Huang, C., Liu, E., Qian, S., Liu, X., Wu, Y., Dong, F., Qiu, C.-W., Qiu, J., Hua, K., Su, W., Wu, J., Xu, H., Han, Y., Fu, C., Yin, Z., Liu, M., & Roepman, R. (2021). Artificial intelligence: A powerful paradigm for scientific research. *Innovation (Cambridge (Mass.))*, 2(4), 100179. <https://doi.org/10.1016/j.xinn.2021.100179>
- Zhang, J., Li, C., Yin, Y., Zhang, J., & Marcin Grzegorzek. (2023). Applications of artificial neural networks in microorganism image analysis: a comprehensive review from conventional multilayer perceptron to popular convolutional neural network and potential visual transformer. *Artificial Intelligence Review*, 56(2), 1013–1070. <https://doi.org/10.1007/s10462-022-10192-7>
- Zhang, Y., Zhang, D., & Zhang, Z. (2023). A critical review on artificial Intelligence—Based microplastics imaging technology: Recent advances, hot-spots and challenges. *International Journal of Environmental Research and Public Health*, 20(2), 1150. <https://doi.org/10.3390/ijerph20021150>

- Zhao, L., Walkowiak, S., & Dilantha, G. (2023). Artificial intelligence: A promising tool in exploring the phytomicrobiome in managing disease and promoting plant health. *Plants*, 12(9), 1852. <https://doi.org/10.3390/plants12091852>
- Zou, H., Alexandros Sopasakis, Maillard, F., Karlsson, E., Duljas, J., Silwer, S., Ohlsson, P., & Hammer, E. C. (2024). Bacterial community characterization by deep learning aided image analysis in soil chips. *Ecological Informatics*, 81, 102562. <https://doi.org/10.1016/j.ecoinf.2024.102562>



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-CompartirIgual 2.5 México.

**Generación de comportamientos autónomos para
ambientes virtuales basados en steering. Caso de
estudio: Evacuación de espacios en situaciones de
riesgo.**

**Generation of Autonomous Behaviors for Virtual
Environments Based on Steering. Case Study: Space
Evacuation in Risk Situations.**

**Sabino Hernández Paulino^{1*}
Vianney Muños Jiménez¹
Marco Antonio Ramos Corchado¹
Adriana Herlinda Vilchis Gonzales¹**

***Contacto correspondencia: shernandezp916@alumno.uaemex.mx**

¹Facultad de Ingeniería de la Universidad Autónoma del Estado de México

Resumen

Los entornos virtuales son herramientas altamente utilizadas para el desarrollo de sistemas de entrenamiento médico, industrial, educativo, entretenimiento, entre otras. El avance tecnológico permite que los ambientes virtuales sean realistas y que la interacción con el usuario permita una adecuación o mejora a los ambientes para realizar una tarea.

La inteligencia artificial propone la creación de entidades autónomas capaces de acompañar al usuario interactuando con él para el cumplimiento de objetivos (tareas). De ahí, el desarrollo de sistemas autónomos que puedan interactuar y adaptarse de manera efectiva a los usuarios y al entorno en el que se encuentra, exhibiendo un comportamiento realista similar al del mundo real.

En este artículo se propone una metodología para la implementación de comportamientos autónomos en entidades virtuales (entornos virtuales) basada en una recombinación de inteligencia artificial y *steering* (flujos), con el propósito de exhibir comportamientos durante la evacuación de zonas en riesgo, permitiendo anticiparse a posibles contingencias y que los seres humanos puedan actuar de forma adecuada cuando se encuentren en este tipo de situaciones.

Los resultados obtenidos utilizando la metodología propuesta permiten observar comportamientos deseados en la evacuación de espacios confinados, así como diferentes tipos de formaciones que son difíciles de tratar utilizando la técnica de *steering*.

Palabras clave: Agentes, steering, comportamiento, realidad virtual, evacuación

Abstract

Virtual environments are widely utilized tools for developing medical, industrial, educational, and entertainment training systems. Technological advancements make virtual environments realistic, allowing user interaction for task adaptation or improvement.

Artificial intelligence proposes the creation of autonomous entities capable of accompanying users by interacting with them to achieve objectives. Hence, the development of autonomous systems that can effectively interact and adapt to users and their environment, exhibiting realistic behavior similar to the real world.

This article proposes a methodology for implementing autonomous behaviors in virtual entities (virtual environments) based on a combination of artificial intelligence and steering flows. The goal is to exhibit behaviors during the evacuation of high-risk zones, allowing anticipation of potential contingencies and enabling humans to respond appropriately in such situations.

The results obtained using the proposed methodology demonstrate desired behaviors in confined space evacuation and different types of formations that are challenging to handle using steering techniques.

Keywords: Agents, steering behaviours, virtual reality, evacuation

1 Introducción

Los sistemas de simulación creados por computadoras son actualmente utilizados por las diferentes áreas del conocimiento, ejemplos de ello son: la medicina, la industria, la educación, el entrenamiento, entre otros. Hoy en día, se cuentan con diversos motores de física que permiten la creación de ambientes virtuales. La graficación por computadora se utiliza para generar escenarios lo más parecidos a los observados en la naturaleza, permitiendo la interacción con el usuario en tiempo real.

La realidad virtual es utilizada para generar ambientes donde los usuarios pueden interactuar de forma directa con el ambiente virtual mediante dispositivos hápticos (Reyes et al., 2014). Esto permite que el usuario este inmerso en el ambiente simulado. Por ejemplo, en el área médica se pueden generar modelos, tal como lo es el cuerpo humano, cuya finalidad es que los futuros médicos o pasantes cuenten con herramientas de entrenamiento para realizar procedimientos médicos no invasivos permitiendo la recuperación pronta de los pacientes.

Un componente básico para la construcción de un ambiente virtual es el uso de la inteligencia artificial que permita la creación de entidades que lo habiten, y que manifiesten comportamientos de acuerdo a su representación. Por ejemplo, si el ambiente virtual construido es un bosque, las entidades que lo pueblan son: ardillas, liebres, lobos, osos, etc., todas estas entidades deberán exhibir comportamientos acorde a la especie biológica en cuestión (Laumond et al., 2011).

Una de las dificultades que se observan y se identifican en los ambientes virtuales es el realismo de las entidades que acompañan al usuario durante su interacción en el ambiente virtual, dado que los comportamientos observados son estáticos. Es decir, que sus comportamientos son predefinidos sin posibilidad de modificarse y/o actualizarse, provocando que el comportamiento exhibido no sea realista. Esto mismo se observa con las representaciones de entidades de tipo humanoide, que por lógica son las entidades con las que el usuario pudiera interactuar dentro del ambiente virtual. Para solventar estos comportamientos estáticos, la inteligencia artificial propone el uso de agentes virtuales, es decir, entidades capaces de realizar tareas dentro del entorno gracias a mecanismos de adaptación y aprendizaje.

Los agentes virtuales tienen la característica de generar planes de acción de acuerdo a lo que observan del entorno virtual, para cubrir sus necesidades y los objetivos establecidos para el logro de una o varias tareas. Los agentes son capaces de exhibir comportamiento de diferentes tipos incluyendo los más complejos denominados sociales. La generación de comportamientos autónomos es uno de los temas abiertos dentro de la inteligencia artificial debido a la complejidad para que estos emerjan de forma autónoma, en la actualidad existen varias metodologías y arquitecturas que proponen generar comportamientos, sin embargo, estos siguen estando restringidos al tipo de contexto.(Camargo Boyacá, 2019)

2 Estado del arte

Craig Reynolds et al. (Reynolds et al., 1999) son unos de principales pioneros en la generación de comportamientos que data de 1999. Los comportamientos presentados por Reynolds et al. se basan en flujos y campos potenciales, logrando comportamientos vistos en aves y bancos de peces. Este tipo de comportamiento esta basado en direcciones, conocidas como *steering*. Reynolds fuerza a un conjunto de agentes a trasladarse a un objetivo, solo con la fuerza de dirección y sin importar las condiciones del entorno. Los comportamientos observados con *steering* son simples pero efectivos y se pueden combinar para crear movimientos complejos y realistas.

M. C. Lin et al. en 2002 (Lin et al., 2002), proponen la utilización de *steering* en conjunto con un sistema basado en reglas, para la generación de comportamientos en tiempo real de personajes virtuales en entornos urbanos. Sin embargo, la propuesta de Lin cubre únicamente entornos urbanos, lo que imposibilita trasladar este tipo de enfoque híbrido a un contexto general.

El estudio realizado por Thalmann et al. en 2007 (Thalmann et al., 2007), exploran el uso de comportamientos basados en *steering* para simular el comportamiento de multitudes en entornos virtuales complejos. Thalmann et al. proponen la implementación de algoritmos que se basan en la proximidad que hay entre los agentes y la orientación promedio del grupo, lo que permite a los agentes agruparse y mantener una cierta cohesión o unión mientras se mueven en conjunto (grupo). Thalmann propone un mecanismo que permite crear diferentes tipos de formación, sin embargo, este mecanismo es costoso computacionalmente, debido a que resulta necesario conocer con antelación el ambiente de forma completa, así como los cambios que se pudieran suscitar.

El trabajo presentado por Laumond en 2011 (Laumond et al., 2011), es una implementación de *steering* que se emplea en la animación de personajes virtuales para entornos 3D. Los comportamientos que se exhiben son: evasión, exploración, seguimiento de trayectorias, entre otros. Los comportamientos presentados por Laumond son basados en guiones, es decir, que se conoce la forma del cómo deben actuar los agentes dentro del medio ambiente.

Christie en 2015 (Christie et al., 2015), propone un enfoque asociativo que combina campos de fuerza y reglas de comportamiento para mejorar la adaptabilidad y eficacia de los comportamientos basados en la dirección en entornos virtuales complejos. El enfoque de asociación propuesto por Christie mejora la capacidad de respuesta de los comportamientos basados en la conducción. Una de las ventajas de su propuesta es el uso de reglas de comportamiento, sin embargo, estas están limitadas a solo poder exhibir comportamientos predefinidos, sin posibilidad de observar la aparición de nuevos comportamientos de acuerdo a la adaptación del ambiente. Adicionalmente, se presentan diversas técnicas para abordar la navegación en entornos virtuales donde aparecen obstáculos.

Clemente en 2018 (Clemente et al., 2018), utiliza los conceptos de *steering* y agentes para el desarrollo de un videojuego 2D llamado RedCell, en éste, los jugadores compiten dentro del cuerpo humano para contaminar células y derrotar a sus oponentes. Parte de este juego implica competir contra un agente controlado por computadora que busca también contaminar y vencer al jugador. El estudio se centra en el desarrollo del sistema de control de un agente autónomo, utilizando una máquina de estados y comportamientos basados en *steering* para su locomoción, el cual permitió una participación efectiva del agente en la competencia del juego. Clemente muestra la utilidad de *steering* en ambientes estáticos, como lo es, el ambiente 2D, pero una de las aportaciones es la construcción de la base de conocimientos que debe tener un agente que pueda exhibir comportamientos autónomos y su adaptabilidad a las condiciones del juego.

La investigación presentada por Aguilar en 2018 (Aguilar et al., 2018), se centra en el desarrollo de una simulación de multitudes y la generación de agentes mediante el uso de máquinas de estado finito (FSM) en formato XML. Los resultados preliminares expuestos indican que la simulación de multitudes puede ser representada utilizando una jerarquía de archivos XML, que consta de al menos dos esquemas XML. Uno de estos esquemas describe el escenario, es decir, el entorno en el que se desarrolla la simulación, mientras que el otro, establece el funcionamiento de la máquina de estados finitos, que controla el comportamiento de los agentes virtuales en la simulación. Sin embargo, una de las deficiencias que se presenta es la imposibilidad de que los agentes virtuales se adapten a las nuevas condiciones que presenta el medio ambiente.

Boyacá en 2019 (Camargo Boyacá, 2019), propone una herramienta informática para la evacuación de edificios e instalaciones, que permita a los brigadistas y encargados de la seguridad actuar de forma adecuada y definir las rutas de evacuación de los complejos industriales, con la finalidad de garantizar la integridad de las personas. La herramienta propuesta por Camargo, se basa en la optimización de rutas para alcanzar las salidas más próximas, sin contemplar el comportamiento individual de cada agente dentro de la simulación.

La investigación que presenta Martínez (Martínez Gutiérrez, 2021) se sitúa en el campo del desarrollo de videojuegos, donde aplica técnicas de inteligencia artificial de manera práctica para mejorar el desplazamiento en el campo de batalla. Se centra en el diseño y la implementación de un sistema de inteligencia artificial capaz de controlar las unidades de la base de operaciones del jugador cuan-

do se encuentra en el modo de defensa. Este sistema se basa en técnicas de planificación, lo que permite a las unidades tomar decisiones estratégicas y tácticas de manera autónoma. La aportación de Martínez permite tomar algunas de sus ideas en la conformación de grupos de agentes que puedan exhibir comportamientos de cohesión al momento de trasladarse a un punto objetivo.

La Tabla 1 resume los trabajos encontrados en el Estado del Arte que hacen uso de comportamientos basados en *steering* considerando ambientes estáticos y dinámicos, siendo estos últimos los de nuestro interés debido a que los entornos en los que habitan los seres humanos son dinámicos.

Tipo de simulación	Autor	Sistema de reglas	<i>Steering</i>	Ambiente Estático	Ambiente Dinámico	Manejo de formaciones
Comportamientos en tiempo real en entornos urbanos.	Lin et al. 2002	X		X		
Comportamiento de multitudes en ambientes complejos.	Thalmann et al. 2007	X	X		X	
Animación de personajes.	Laumond et al. 2011	X		X		X
Mejora en el desplazamiento de los agentes en el ambiente.	Christie et al. 2015	X	X		X	
Comportamiento de agentes en ambientes 2D.	Clemente et al. 2018		X	X		X
Comportamiento de multitudes en grandes volúmenes.	Aguilar et al. 2018	X		X		
Comportamientos para la evacuación de edificios.	Boyaca et al. 2019	X		X	X	

Tabla 1: Revisión del estado del arte, resumen.

Con base en la revisión realizada en el Estado del Arte, se observa que las técnicas en la mayoría de los trabajos presentados, se proponen comportamientos ad-hoc al contexto, es decir, exclusivo a un solo entorno virtual, lo que imposibilita poder trasladarlos a diferentes entornos o simulaciones de forma transparente.

En este trabajo de investigación se propone ampliar el estado del arte como se muestra en la Tabla 1, para generar comportamientos autónomos para la evacuación de espacios confinados en situaciones de riesgo, a través de la propuesta de una metodología que permita generar comportamientos autónomos en agentes virtuales, utilizando comportamientos basados en *steering*. Dicha metodología permite generar comportamientos autónomos según la dinámica del medio ambiente en el que se encuentren embebidos los agentes, con ello, se mejora la interacción con el usuario y consiguiendo simulaciones más realistas. Para determinar la eficiencia de la metodología se realizan pruebas sobre un caso de estudio, en donde se lleva a cabo la evacuación de espacios que se encuentren en situación de riesgo.

3 Marco Teórico

La *realidad virtual* es una representación de escenas o imágenes de objetos producida por un sistema informático, que da la sensación de su existencia real, esta ofrece la posibilidad de crear entornos virtuales inmersivos y no inmersivos en donde los usuarios pueden interactuar utilizando sistemas hápticos. Dentro de estos entornos se encuentran embebidos agentes virtuales que exhiben comportamientos de forma autónoma, lo que permite tener una dinámica en el medio ambiente donde el usuario tiene una sensación intuitiva y más realista.

La *realidad virtual no inmersiva* es en la que el usuario interactúa con el mundo virtual de manera sencilla utilizando periféricos visuales e interfaces como el teclado y el mouse. Mientras que, la *realidad virtual inmersiva* utiliza dispositivos que aíslan al usuario del mundo real mediante lentes, guantes, cascos, y otros accesorios para el cuerpo (Reyes et al., 2014).

Los *entornos virtuales 3D* están compuestos de modelos 3D que permiten aplicar aspectos importantes dentro de la realidad virtual como son: entornos interactivos, entornos inmersos y lo más importante, que todo ocurre en tiempo real; estos entornos se integran en uno solo y se denominan entorno virtual 3D, distinguido por contener detalles como la forma, el color, la iluminación y otras características físicas de los objetos incluidos en el mundo sintético. Estos mundos sintéticos están poblados de agentes autónomos (León Guerra et al., 2013). En la construcción de los entornos virtuales 3D se involucra la física del ambiente, por ejemplo, la gravedad.

Los *agentes autónomos* son entidades virtuales con capacidad para tomar decisiones y actuar de manera independiente tanto en ambientes virtuales como físicos. Los agentes autónomos pueden seguir diferentes enfoques, como agentes reactivos, basados en reglas, basados en objetivos, basados en aprendizaje, basados en conocimiento y multiagentes. Estos agentes pueden ser personajes virtuales, objetos animados u otros elementos interactivos.

La dinámica que presentan los agentes virtuales en los entornos se apoyan en algunas leyes de la física, como por ejemplo, la traslación, que es un movimiento relativamente sencillo donde se fija un punto de origen y un punto de destino. Sin embargo, existen algunas dificultades para llevar a cabo este tipo de movimiento, como pudiera ser la evasión de obstáculos. Para ello, se utilizan campos potenciales que permiten tratar este tipo de problemas, así mismo, se hace una recombinación de campos potenciales con dirección conocidos como *steering*.

Los comportamientos basados en *steering*, se pueden clasificar en movimientos básicos y comportamientos de grupo.

1. **Movimientos básicos:** se refiere a los comportamientos que permiten a los agentes moverse en un entorno virtual 3D. Los comportamientos de este tipo incluyen: Buscar y Huir, Perseguir, Evadir, Llegar, Evasión y Seguimiento de ruta.
2. **Comportamientos de grupo:** permiten a un conjunto de agentes formar y mantener una agrupación de diferentes tipos, tales como: Cohesión, Separación, Alineación, Enjambre, Seguir al líder.

La base fundamental de *steering*, es la simulación de fuerzas físicas que actúan sobre los objetos en el mundo real, como la gravedad, la fricción, la resistencia del aire, entre otras, permitiendo producir comportamientos realistas y dinámicos. En la Fig. 1 se ilustra el uso de vectores de dirección que actúan directamente sobre un objeto, logrando simular la fuerza de gravedad. En los ambientes virtuales existen diferentes objetos en los que la gravedad influye: los estáticos y los dinámicos, siendo los últimos los que son complicados a definir dado que se deben considerar diversas características como la masa del objeto.

Es indudable que la generación de comportamientos utilizando *steering* permite aplicar diversas fuerzas a los agentes virtuales en tiempo real. Estas técnicas implican cálculos vectoriales para la detección de colisiones. La Fig. 2 muestra el análisis del entorno y las fuerzas que se pueden aplicar

para que los agentes no colisionen al momento de aproximación, la toma de decisiones está basada en reglas predefinidas, esta limita el movimiento de los agente en caso de multitudes. Es por ello que, en este trabajo de investigación se estudia el comportamiento de los agentes para resolver las colisiones en caso de multitud.




Figura 1: Gravedad aplicada a un objeto mediante *steering*.




Figura 2: Evasión de agentes utilizando *steering*.

En la siguiente sección se propone la metodología para la creación de comportamientos autónomos basados en *steering*, así como una base de conocimientos extendida en los agentes virtuales para obtener comportamientos grupales con diferentes tipos de distribución en un entorno virtual 3D.

4 Metodología propuesta: Generación de comportamientos autónomos en agentes virtuales basados en *Steering*

Las entidades virtuales están embebidas en un ambiente virtual, el cual está basado en el contexto del problema o tarea a realizar. Estas entidades tendrán que adaptarse al medio ambiente con el propósito de lograr sus objetivos y cumplir con la tarea asignada.





Figura 3: Arquitectura básica de un agente.

La Fig. 3 muestra la arquitectura básica de un agente virtual. El agente virtual cuenta con una base de conocimientos iniciales que le permite actuar de acuerdo a la situación que se presente en el medio ambiente. Gracias a la percepción y a los actuadores le permite una autonomía al momento de realizar una tarea para alcanzar sus objetivos. Es en la base de conocimiento en donde se incluyen comportamientos basados en *steering* que permite al agente o a los agentes virtuales exhibir comportamientos individuales o grupales de acuerdo al contexto o problema a resolver dentro de su entorno virtual.

En la Fig. 4 se presenta la metodología propuesta a través de un diagrama de bloques para generar comportamientos autónomos basados en *steering* que son embebidos en la base de conocimientos inicial de los agentes que se encuentran en el medio ambiente. La metodología propuesta surge por la necesidad de generar comportamientos autónomos en ambientes dinámicos, en donde la cantidad de entidades dentro del ambiente virtual sean mayor a n agentes, los que deben exhibir comportamientos grupales.

En la metodología propuesta se resalta la forma del cómo se define el comportamiento grupal e individual haciendo uso de *steering* cuando se trate de comportamientos grupales o en masa, sobre todo en la evasión de obstáculos evitando colisiones y cambio de direcciones. Para lograr esto, se agrega otro elemento a la metodología que consiste en el ajuste de los parámetros que presentan los agentes virtuales, tales como: velocidad de desplazamiento, dirección, cohesión, seguimiento y trayectoria.



//7.5

Figura 4: Metodología propuesta: Generación de comportamientos autónomos basados en *steering*.

Con base a la metodología propuesta, el punto de partida, es la construcción del ambiente virtual con las características necesarias para evaluar los diferentes fenómenos que se deseen observar, esto incluye todos aquellos elementos que deben ser considerados por las entidades o agentes virtuales que los utilizarán para alcanzar sus objetivos o resolver sus tareas definidas previamente. También es necesario definir dentro del ambiente virtual aquellos elementos restringidos o de difícil acceso para los agentes, esto es tomar en consideración las diferentes leyes de la física por ejemplo: un agente no puede traspasar el tronco de un árbol, por lo cual debe rodearlo, al considerar las leyes de la física permite que los agentes exhiban comportamientos reales. En la Fig. 5 se observa la construcción de un ambiente virtual en el cual pueden ser embebidos los agentes virtuales.



Figura 5: Ejemplo de la construcción de un ambiente virtual.

Una vez construido el ambiente virtual, este debe ser poblado por entidades que interactúen con el medio ambiente, estas entidades se basan en agentes, un agente puede ser por ejemplo: una ardilla que vive en las copas de los árboles, por lo que el comportamiento que deberá exhibir es el desplazamiento por las ramas y troncos de estos. En nuestro caso, se utiliza la arquitectura básica para la generación de agentes, presentada en la Fig. 3.

Para definir el comportamiento del agente se construye la base de conocimientos iniciales mediante estados y acciones. Los actuadores del agente permite modificar los estados mediante las acciones que puedan ocurrir dentro del entorno E formado por un conjunto de estados $E = \{e_0, e_1, e_2, \dots, e_u\}$. A partir de los estados observados los agentes construyen un repertorio de posibles acciones Ac a realizar modificando el estado inicial: $Ac = \{\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_{u-1}\}$.

Los agentes realizan las acciones dentro del entorno mediante la construcción de una lista r , que corresponde a una secuencia de estados y acciones que pueden ser realizados dentro del entorno para el logro de sus objetivos como se muestra en la Ec.1.

$$r = e_0[r]^{\alpha_0} e_1[r]^{\alpha_1} e_2[r]^{\alpha_2} e_3[r]^{\alpha_3} \dots e_{u-1}[r]^{\alpha_{u-1}} \quad (1)$$

La base de conocimientos iniciales permite observar comportamientos autónomos de forma individual. El siguiente bloque de la metodología propuesta es integrar *steering* a la base de conocimientos de los agentes para observar comportamientos de tipo colaborativo como son desplazamientos grupales. Los mecanismos de *steering* permitirán observar desplazamientos con formaciones de tipo lineal, en cuadro, en rombo, circular, formación en V y en cuña, como se observa en la Fig. 6 es el contexto del ambiente que activará los comportamientos que deberán tomar los agentes.




Figura 6: Tipos de formaciones en grupo.

Steering considera la masa de los agentes, así como la aceleración, la dirección y el tiempo. Estas características se toman en cuenta para aplicar el movimiento de los agentes que se desplazan por el medio ambiente, la Ec. 2 muestra cada uno de los parámetros a considerar en el desplazamiento de los agentes.

$$m_{ag} \frac{dv_{ag}^0}{dt} = m_{ag} \frac{v_{ag}(t)e_{ag}^0 - v_{ag}(t)}{\tau_{ag}} + \sum_{\beta \neq ag} f_{ag\beta}(t) + \sum_i f_{agi}(t) \quad (2)$$

Cada agente representado por ag esta conformado por una masa m . El movimiento se define por la aceleración, dirección y el objetivo e_{ag}^0 con un flujo v_{ag} , en un intervalo de tiempo t , para que sea

igual al flujo de todos los agentes, el cambio de dirección τ es un factor de ajuste que controla la rapidez de cambio de dirección del agente.

Las interacciones de repulsión con los otros agentes β , depende de la distancia entre estos como del ángulo entre ellos, la repulsión con respecto a los muros se trata de forma análoga a la de otros agentes. Finalmente, la aceleración del flujo es afectada también por las fuerzas de atracción f a los puntos objetivo i a los que tienen que acceder los agentes, este tipo de representaciones se le conoce como *steering*, la Ec.2 muestra la composición de los diferentes parámetros para que los agentes se trasladen a los objetivos marcados dentro del ambiente (Amor et al., 2006).

Al momento de iniciar el sistema, los agentes ya cuentan cada uno con tareas a realizar dentro del ambiente virtual, definidas en su base de conocimientos. Adicionalmente, también conocen el contexto en el que se encuentran inmersos y tienen la capacidad de construir secuencias de estados para la toma de decisiones de acuerdo a las acciones que se pueden realizar dentro del ambiente, utilizando los actuadores.

La base de conocimientos incrementa a cada una de las acciones que realizan los agentes para el logro de sus objetivos y tareas. Por lo que en este caso, se debe guiar el aprendizaje mediante la observación y el tiempo utilizado para el logro de sus objetivos. Esto se lleva a cabo en la etapa de evaluación de tarea. Así mismo, se debe medir la eficiencia del sistema para diferentes contextos en los que los agentes deberán mostrar comportamientos llamados inteligentes. Por ejemplo: evasión de obstáculos, cohesión con otros agentes, mantener formaciones como se muestran en la Fig. 6.

Una vez que el grupo de agentes haya realizado de forma satisfactoria la primera tarea que se les asignó, los agentes virtuales podrán continuar con el siguiente objetivo asignado. Los agentes virtuales deben mantener la formación inicial asignada, sólo en aquellos casos en lo que las condiciones del entorno obliguen a romper la formación, estos deberán re-agruparse una vez que hayan superado el obstáculo.

En sistemas convencionales, una vez que los agentes logran sus objetivos pasan a realizar otra tarea, sin embargo, la propuesta busca que adicionalmente a lograr objetivos, los agentes exhiban comportamientos lo más parecido a los observados en los ambientes reales. Por ello, se agrega una etapa de *ajuste*. En esta etapa, los agentes pueden recalibrar sus parámetros de *steering* para evitar obtener comportamientos no deseados en las simulaciones.

La generación de comportamientos no es una tarea sencilla, dado que estos, deben exhibir comportamientos lo más parecido a los que producen en situaciones reales. Para validar la propuesta de la metodología se presenta un caso de estudios que consiste en la evacuación de un espacio en situación de riesgo.

5 Caso de estudio: Evacuación de espacios en situaciones de riesgo

Para evaluar la propuesta, se construye un ambiente virtual tipo oficinas como se presenta en la Fig. 7, en donde, los agentes realizan actividades propias del contexto y mediante una señal de alerta, estos deben desalojar los espacios en un tiempo determinado exhibiendo comportamientos lo más realistas posible.

El ambiente virtual esta poblado por n agentes virtuales que se encuentran ubicados en diferentes posiciones dentro del espacio, realizando actividades propias de oficina mediante su base de conocimiento inicial. Es cuando existe una señal de alerta que los sistemas de percepción del ambiente activan los comportamientos *steering* y de acuerdo al contexto se activa la señal de evacuación o desalojo, sea aleatoria o mediante un tipo de cohesión o formación.




Figura 7: Caso de estudio.

Los parámetros de *steering* permiten reducir comportamientos de tipo aleatorio que si bien existen en el mundo real, lo que se desea es poder contar con evacuaciones de forma organizada, grupal y cooperativa, si se utiliza como una herramienta de entrenamiento para la evacuación de espacios confinados en situación de riesgo, como lo muestra la Fig. 8.




Figura 8: Proceso de evacuación basado en *steering*.

Finalmente, se evaluó a la colaboración de agentes manteniendo cierto orden o tipo de formación para llegar a la zona segura, pudiendo en cualquier momento romper su formación inicial pero al momento de alcanzar la zona segura, poder reconstruir la formación indicada al inicio de la simulación. Esto se observa en la Fig. 9 teniendo formaciones tipo delta y cuadrado.




Figura 9: Evacuación en casos de emergencia.

6 Resultados

Durante las simulaciones realizadas para la evacuación de espacios se observaron resultados efectivos con respecto al flujo de evacuación y el comportamiento de los agentes. Los comportamientos observados presentaron similitudes notables con respecto a situaciones reales como conglomeraciones en los puntos de difícil acceso. Respecto a los movimientos individuales, como seguir una ruta en específico, moverse hacia diferentes destinos evitando los obstáculos, llegar a las zonas seguras, seguir diferentes rutas para huir de lugares o perseguir otros agentes el uso de *steering* ofrece buenos resultados haciendo más realistas los comportamientos. En cuanto a los comportamientos en grupos, se logró realizar diferentes tipos de formaciones complejas utilizando comportamientos como la cohesión, alineación y separación, permitiendo la colaboración para realizar diversas acciones dentro del entorno virtual en el cual están inmersos. La base de conocimientos de los agentes permitió ajustar su comportamiento en entornos estáticos como dinámicos, facilitando la colaboración entre ellos para crear diversas formaciones de acuerdo al contexto en el cual se encuentren, por ejemplo colocarse al rededor de una mesa de juntas con forma a su geometría o tomar diversas formas como la formación en cuadrado o la formación delta.

La metodología propuesta es aplicable en cualquier contexto que requiera la generación de agentes virtuales, ya que permite ajustar el comportamiento de los agentes y facilitar su colaboración en una amplia variedad de situaciones estáticas y dinámicas. Esta capacidad no se encuentra en las metodologías revisadas en el estado del arte, las cuales suelen definir reglas específicas adaptadas al contexto o problema que se desea abordar.

Las técnicas de inteligencia artificial, ofrecen mecanismos de aprendizaje automático y los algoritmos de optimización, contribuyen significativamente a mejorar la simulación y planificación de evacuaciones.

Se desarrolla un algoritmo 1 basado en la metodología propuesta que puede ser extendido a diferentes tipos de simulaciones en donde se requiera observar comportamientos de evacuación de espacios confinados.

El uso de *steering* como técnica de optimización para la generación de comportamientos autónomos garantiza la adaptación de los agentes de acuerdo al contexto del tipo de simulación que se desee realizar sobre todo, en la evacuación de espacios confinados.

Algorithm 1 Comportamientos de Steering para Simulación de Evacuación

Construcción del Ambiente Virtual:

Definir zona segura (*safe zone*)
Definir la cantidad de agentes a generar (*number of agents*)
Definir una lista de agentes (*agent list*)
Establecer una lista de objetivos (*goal list*)

Generación de Agentes y Comportamiento Inicial:

```
for  $i = 0$  to number of agents do
  Crear un agente virtual
  Asignar agente a una posición inicial
  Asignar destino aleatorio del goal list
end for
```

Actualización (Update):

```
if Se generó una señal de riesgo then
  Activar evacuación de los agentes hacia la safe zone
end if
for cada agente en la agent list do
  Actualizar comportamiento del agente:
  if agente moviéndose hacia un objetivo de la goal list then
    Establecer nuevo destino del agente desde la goal list
  end if
  if agente llega a su destino then
    Asignar nuevo destino aleatorio al agente desde la goal list
  end if
end for
```

7 Conclusiones

Con base en los resultados obtenidos durante las simulaciones realizadas, se concluye que la utilización de *steering* es viable para la generación de comportamientos autónomos en agentes virtuales que exhiban comportamientos apegados a la realidad.

La utilización de heurísticas y *steering* permite la generación de comportamientos de forma colaborativa e individual de acuerdo a las situaciones que se presenten en el medio ambiente, permitiendo observar comportamientos lo más parecidos a los que se observan en situaciones reales.

Una de las ventajas que presenta la metodología propuesta, es que, las etapas permiten una actualización o ajuste al comportamiento que exhiben los agentes dentro del ambiente virtual, así como, la colaboración entre ellos para crear diferentes tipos de formaciones dentro de un contexto dado, por ejemplo, si se tiene una mesa de juntas, los agentes deben situarse de acuerdo a la geometría de la mesa, ya sea redonda, cuadrada u oval. Así mismo, *steering* permite que los agentes puedan actuar en ambientes estáticos y dinámicos mediante el flujo o cambio de direcciones durante el proceso de evacuación.

La realidad virtual permite modelar ambientes virtuales lo más parecidos a la realidad en la cohabitación de los seres humanos. El uso de estas simulaciones permite anticiparse a contingencias no previstas dentro del medio ambiente, como lo son: los terremotos y otras incidencias de tipo natural. La evacuación de espacios es de vital importancia para garantizar la seguridad de las personas en casos de situación de riesgo, tales como: incendios, terremotos o amenazas de seguridad. Contar con sistemas que permitan observar comportamientos en espacios confinados puede ser una estrategia eficaz para guiar y orientar a las personas durante una evacuación.

Steering no restringe comportamientos adicionales como puede ser miedo o ansiedad, lo que

permite tener comportamientos diversos en situaciones de riesgo, estos comportamientos así como otros deberán ser definidos dentro de las bases de conocimientos de los agentes que se denominan personalidad, aspecto que no fue abordado en esta propuesta, sin embargo, se propone considerarla para futuros trabajos.

La generación de comportamientos autónomos sigue siendo un área abierta que presenta retos a resolver, como lo es, la personalidad de los agentes. Actualmente, se utilizan comportamientos únicos en el conjunto de agentes, sin embargo, la personalidad, así como otras características de los seres humanos son necesarios para la construcción de simulaciones que muestren un entorno real que permita anticiparse a los fenómenos naturales.

Referencias

- Aguilar, J. A. H., Goldberg, I. R., Díaz, J. C. Z., and Toledo, L. (2018). Implementación de agentes mediante máquinas de estado finito de comportamiento (mefc) aplicados a la simulación de multitudes. *Research in Computing Science*, 147(8):175–188.
- Amor, H. B., Murray, J., Obst, O., et al. (2006). Fast, neat, and under control: Arbitrating between steering behaviors. *AI Game Programming Wisdom*, 3:221–232.
- Camargo Boyacá, M. E. (2019). Herramienta de simulación basada en agentes para la evacuación de edificios e instalaciones. *Departamento de Ingeniería de Sistemas e Industrial*.
- Christie, M., Yannakakis, G. N., and Saldamli, G. (2015). Hybrid steering behaviors for autonomous virtual characters. In *Proceedings of the 2015 Annual Symposium on Computer-Human Interaction in Play*, volume 2015, pages 157–166. Citeseer.
- Clemente, A. Q., Furlong, H. A. D., Rivera, V. G., and González, J. J. C. (2018). Máquina de estados finita con comportamientos de dirección para manipular agentes de juego redcell. *Research in Computing Science*, 147(8):55–67.
- Laumond, J.-P., Pettré, J., Gallardo, J., and Lapeyre, M. (2011). A survey on steering behaviors for virtual characters. In *Computer Graphics Forum*, volume 30, pages 151–168. Citeseer.
- León Guerra, R., Torres Menéndez, F., Padilla Cuenca, J., and Nápoles Ávila, I. (2013). Entorno virtual para gestionar modelos 3d de piezas y mecanismos. *Revista Ciencias Técnicas Agropecuarias*, 22(4):69–74.
- Lin, M. C., Otaduy, M. A., Manocha, D., and O’Sullivan, C. (2002). Real-time steering behaviors for virtual humans. In *IEEE Computer Graphics and Applications*, volume 22, pages 42–50. Citeseer.
- Martínez Gutiérrez, M. A. (2021). *Juego de estrategia en tiempo real con agentes inteligentes y planificación*. PhD thesis, Universidad Politécnica de València.
- Reyes, J. d. J. A., Ortega, J. A. Z., Buñuelos, C. M., Ramírez, A. M., and Hernández, C. I. M. (2014). Desarrollo de un entorno virtual tridimensional como herramienta de apoyo a la difusión turística de la zona arqueológica de teotihuacán. *Acta Universitaria*, 24(4):34–42.
- Reynolds, C. W. et al. (1999). Steering behaviors for autonomous characters. In *Game developers conference*, volume 1999, pages 763–782. Citeseer.
- Thalmann, D., Musse, S. R., and Pelechano, N. (2007). Crowd simulation using steering behaviors. In *Computer Animation and Virtual Worlds*, volume 18, pages 3–16.



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-CompartirIgual 2.5 México.

Inteligencia Artificial en la Academia: Oportunidades y Desafíos

Artificial Intelligence in Academia: Opportunities and Challenges

Fernando Wario Vazquez^{1,2}
Ricardo Ramírez Romero³

¹ Centro Universitario de Ciencias Exactas e Ingenierías, Universidad de Guadalajara

² Correspondencia : fernando.wario@academicos.udg.mx

³ Centro Universitario de Ciencias Biológicas y Agropecuarias, Universidad de Guadalajara

RESUMEN

Aunque en los últimos años el uso de la inteligencia artificial (IA) se ha vuelto más común y accesible, especialmente con herramientas como ChatGPT, sus raíces se remontan a más de 50 años. Desde la década de 1950, cuando Turing propuso la primera prueba para evaluar la capacidad de las máquinas de emular el comportamiento humano, la IA ha tenido un desarrollo con altibajos. No obstante, en la última década, ha experimentado un crecimiento significativo, manifestándose en múltiples aspectos de la vida cotidiana, incluida la academia. El uso de la IA en la academia se ha popularizado recientemente, particularmente entre estudiantes de nivel medio y superior, con herramientas como ChatGPT. Sin embargo, hay otras aplicaciones destacadas, como Inciteful, Litmaps, Jenni, Wisio y Elicit, que facilitan la recopilación y el análisis de grandes volúmenes de información. Además, herramientas como Grammarly, Quillbot y Jarvis son auxiliares valiosos en la redacción y revisión de textos académicos. Dado este contexto, es crucial analizar tanto las oportunidades que la IA ofrece en el ámbito académico como las áreas que requieren una atención especial para asegurar un uso ético y responsable de estas herramientas. Este artículo examina los orígenes de la IA, su recorrido histórico, y presenta diversas herramientas aplicables en la academia. Se exploran los aspectos que demandan mayor cuidado para un uso ético y responsable y se discuten las posibles vías futuras en el desarrollo de estas herramientas tecnológicas.

Palabras clave: Inteligencia Artificial, Academia, ChatGPT, aplicaciones, regulación

ABSTRACT

Although artificial intelligence (AI) has become increasingly common and accessible in recent years, particularly with tools like ChatGPT, its origins date back over 50 years. Since the 1950s, when Alan Turing proposed the first test to evaluate a machine's ability to mimic human behavior, AI has experienced a series of advancements and setbacks. However, AI has grown substantially in the last decade, integrating into various aspects of daily life, including academia. The adoption of AI in academia has recently surged, particularly among high school and university students, through tools like ChatGPT. In addition to ChatGPT, other AI applications such as Inciteful, Litmaps, Jenni, Wisio, and Elicit have facilitated the efficient collection and analysis of large datasets. Tools like Grammarly, Quillbot, and Jarvis have also become valuable aids for drafting academic texts. Given this context, it is essential to examine both the opportunities that AI presents in the academic field and the critical areas that require attention to ensure these technologies' ethical and responsible use. This article explores AI's origins and historical evolution, highlights various AI tools applicable in academic settings, and examines the aspects requiring careful consideration for ethical and responsible use. It concludes by discussing potential future directions for developing these technological tools.

Keywords: Artificial Intelligence, Academia, ChatGPT, applications, regulation

1. INTRODUCCIÓN

Las nuevas herramientas basadas en tecnologías de inteligencia artificial (IA) parecieran cada vez acercarnos más a un futuro como los descritos en novelas de ciencia ficción. Para algunos usuarios, esto más que alentador es inquietante, pues más allá de problemáticas ya vividas con otros avances tecnológicos como la pérdida de puestos de trabajo y la concentración de poder por parte de las potencias mundiales, se encuentran nuevas preocupaciones, como la falta de comprensión global por parte del usuario. Particularmente, sobre el funcionamiento de muchos de los algoritmos, la privacidad de los datos con los que son entrenados los modelos detrás de las herramientas de IA, los sesgos mostrados por algunos modelos, reflejo de los datos con los cuales han sido entrenados, e incluso la potencial capacidad de la IA de autogestionarse y salirse de nuestro control. Estas preocupaciones han llevado a un amplio debate sobre las medidas que deberían tomarse para regular el uso y desarrollo de nuevas tecnologías de IA. Sin desestimar estas preocupaciones, es una realidad que las tecnologías de IA han impactado ya en menor o mayor medida a diversos sectores económicos y sociales, siendo la academia particularmente alcanzada con el reciente boom de la IA generativa.

En el presente artículo exploramos el camino que ha llevado a la IA a convertirse en el que probablemente sea el campo de estudio más relevante en la actualidad, y cómo diversas tecnologías a las que ha dado lugar están siendo utilizadas en la academia, evaluando sus potenciales beneficios, pero también los desafíos que plantean su uso responsable. Destacamos como con el paso del tiempo se ha vuelto crucial garantizar un desarrollo ético y supervisado de estas nuevas tecnologías para evitar dependencias perniciosas y permitir que la IA sea una herramienta segura y efectiva tanto en la academia como en otros sectores.

2. ORÍGENES E HISTORIA DE LA IA

Aunque el auge de las herramientas de Inteligencia Artificial (IA) es un fenómeno reciente, y cada vez es más frecuente encontrarlas en diversos aspectos de la vida cotidiana, la IA como campo de estudio tiene más de siete décadas de historia. En 1950, cuando las computadoras eran aún utilizadas principalmente como simples calculadoras a gran escala, Alan Turing abordó en su artículo “Computing Machinery and Intelligence” publicado en la revista *Mind* el problema de la IA (Turing, 1950). En este artículo, Turing buscaba establecer un estándar para indicar si una computadora puede ser considerada “inteligente”; para este fin propuso un juego llamado “El Juego de la Imitación” el cual posteriormente sería conocido como el “Test de Turing”. En este juego, un evaluador humano juzga las conversaciones en lenguaje natural entre un humano y una máquina, si el evaluador no es capaz de distinguir de manera confiable la máquina del humano, la máquina ha pasado la prueba. De esta manera Turing evita la pregunta de si las máquinas son capaces de pensar, la cual plantea el problema de definir la palabra pensar; en su lugar, la prueba propuesta por Turing respondería a la pregunta: ¿Pueden las máquinas actuar como entidades pensantes?

Después, durante el verano de 1956, en la universidad Dartmouth College, ubicada en Hanover, New Hampshire (Estados Unidos), tuvo lugar la conferencia organizada por John McCarthy, Marvin Minsky, Nathaniel Rochester y Claude Shannon (Moor, 2006). Esta conferencia es popularmente considerada como el evento seminal de la IA como campo de estudio, haciendo uso por primera vez del término “Inteligencia Artificial” para referirse a lo que hasta entonces era el campo de las “máquinas pensantes” y recibía nombres como cibernética, teoría de los autómatas y procesamiento complejo de la información.

El interés por las ideas discutidas durante la conferencia de Dartmouth, llevó a la IA a gozar de un primer periodo de apogeo durante las décadas de 1960 y 1970. Durante este periodo se dieron algunos desarrollos prometedores como el de ELIZA (Weizenbaum, 1966), una versión temprana de procesador de lenguaje natural (referido al habla y escritura humana y abreviado como NLP por sus siglas en inglés) (Nadkarni et al., 2011) desarrollado por Joseph Weizenbaum del MIT y el cual, es considerado como uno de los primeros chatbots de la historia. A finales de los años 70s surgieron los primeros esfuerzos por establecer un organismo que permitiera la comunicación continua entre las diferentes instituciones

trabajando en temas de IA, fue así como se llevó a cabo la conferencia conjunta en IA de 1977 y 1979. Posteriormente, se formaría la Asociación Americana de Inteligencia Artificial, la cual finalmente daría lugar a la actual Asociación para el Avance de la Inteligencia Artificial (AAAI por sus siglas en inglés).

Este temprano auge de la IA comenzaría a desacelerar a finales de los años 70s y continuaría a la baja hasta inicios de los 90s en lo que es conocido como “Invierno de la IA”. Aunque la historia de la IA cuenta con varios periodos de gran entusiasmo seguidos por la desilusión de algunos ante los resultados de sus desarrollos en escenarios de la vida real y de fuertes críticas a la confiabilidad de sus tecnologías, este periodo fue particularmente difícil para los grupos de investigación trabajando en IA, los cuales sufrieron un severo recorte en el financiamiento de sus proyectos. Dicho recorte se debió principalmente a la evaluación sobre el estado de la investigación en IA que realizó el reconocido matemático Sir James Lighthill a petición del Parlamento del Reino Unido. En dicho reporte, Lighthill criticaba severamente los algoritmos de la IA, los cuales consideraba solo adecuados para resolver versiones de “juguete” de los problemas del mundo real (McCarthy, 1974).

Probablemente el evento que motivó la reactivación de grandes fondos para la investigación y desarrollo en IA fue el encuentro entre la supercomputadora desarrollada por IBM® “Deep Blue” y el maestro ajedrecista Gary Kasparov. El 10 de febrero de 1996, Deep Blue venció a Kasparov en la primera partida de seis pactadas. Aunque Kasparov terminó ganando el encuentro con un resultado de 4 - 2, la victoria de las partidas de Deep Blue sobre el campeón mundial de ajedrez vigente representó un hecho histórico en el campo de la IA.

Muchos años después del éxito de Deep Blue, IBM® desarrolló “Watson DeepQA”, un sistema computacional capaz de responder a preguntas formuladas en lenguaje natural. En febrero de 2011 Watson DeepQA participó en el popular concurso de televisión estadounidense “Jeopardy!”, resultando vencedor frente a dos destacados participantes del concurso. En una muestra más de los importantes avances logrados en temas de NLP (procesamiento de lenguaje natural), los gigantes de la industria Apple® y Amazon® presentaron sus asistentes virtuales en 2011 y 2014, respectivamente. A pesar de la sorprendente capacidad de estos asistentes virtuales para comprender y responder en lenguaje natural, sus limitaciones son evidentes, siendo incapaces de responder a preguntas o comandos diferentes a aquellos para los cuales han sido programados.

El siguiente gran avance en IA se dió como resultado de mejoras tanto en hardware como en los modelos de redes neuronales. En particular, los avances fueron evidentes en aplicaciones de visión por computadora, donde se encontró una enorme área de oportunidad al implementar los modelos de redes neuronales convolucionales (CNN por sus siglas en inglés) en unidades de procesamiento gráfico (GPU por sus siglas en inglés), reduciendo de manera drástica el tiempo requerido para entrenar las CNNs y permitiendo a su vez la implementación de modelos mucho más complejos (LeCun et al., 2015). Como resultado de esta convergencia de factores, la CNN nombrada AlexNet (Krizhevsky et al., 2017), resultó vencedora en el reto de clasificación de imágenes de la base de datos ImageNet. AlexNet, desarrollada por Alex Krizhevsky, Ilya Sutskever y Geoffrey Hinton de la Universidad de Toronto, obtuvo un porcentaje de error de tan solo el 15.3%, colocándose así a 10.8 puntos de distancia de su seguidor más cercano.

Dos décadas después de la victoria de Deep Blue sobre Kasparov, en marzo de 2016, el programa computacional AlphaGo (Silver et al., 2016) marcó otro hito en la historia de la IA al vencer al jugador profesional de Go nivel 9-dan, Lee Sedol, siendo esta la primera vez que un programa de Go vencía a un profesional del nivel más alto y sin piedras de ventaja (Figura 1). El juego de Go, a pesar de ser considerado fácil de aprender, resulta particularmente difícil para los programas computacionales por la gran cantidad de posiciones posibles en el tablero. Por este motivo, los desarrolladores de AlphaGo utilizaron un enfoque completamente distinto al de Deep Blue, el cual era un sistema experto (Jackson, 1998) operando a base de reglas y variables previamente ajustadas por expertos ajedrecistas. Por su parte, AlphaGo es un conjunto de redes neuronales y algoritmos de búsqueda entrenados a través de métodos de aprendizaje reforzado, incluyendo millones de partidas jugadas contra expertos y contra sí mismo. La victoria de AlphaGo al nivel más alto en un juego previamente considerado fuera del alcance de los sistemas computacionales renovó el entusiasmo en las nuevas tecnologías de IA.



Figura 1. Creada con la herramienta Copilot (DALL-E 3) con IA usando el prompt: “Genera una imagen donde se represente la histórica partida entre la IA y el campeón mundial de Go”

Así como la arquitectura de la CNN AlexNet marcó un antes y un después en el procesamiento de imágenes con redes neuronales, la arquitectura transformer (Vaswani et al., 2017) desarrollada por un grupo de investigadores en Google® permitió avances acelerados en la interpretación y generación de nueva información con redes neuronales. El tiempo de entrenamiento requerido por las redes neuronales basadas en la arquitectura transformer es significativamente menor al de otros modelos previos, pues estas no cuentan con unidades recurrentes. En la actualidad se pueden encontrar variaciones de la arquitectura transformer en modelos de lenguaje grande (LLM por sus siglas en inglés) y en la generación de imágenes a partir de descripciones en lenguaje natural (Radford et al., 2019). La compañía OpenAI® desarrolló los transformadores generativos preentrenados (GPT por sus siglas en inglés), los cuales se han convertido en los modelos de referencia LLM y de la IA generativa. Después de presentar su primer modelo GPT en 2018 (Radford et al., 2018), OpenAI ha lanzado nuevas iteraciones de este modelo, con la más reciente versión – GPT-4o – siendo lanzada en mayo de 2024. GPT-4o es un LLM-multimodal y multilingüe, el cual es capaz de procesar y generar texto, imágenes y audio.

3. LA IA EN LA ACADEMIA

El boom de los modelos generativos ha renovado el interés y la confianza en herramientas basadas en IA; como consecuencia, en la actualidad existe una gran variedad de desarrollos, tanto basados en modelos generativos como en otras tecnologías de IA, los cuales han sido rápidamente adoptados en diversos sectores, incluyendo la academia. Mientras que algunas de estas herramientas cumplen propósitos generales como la producción de textos e imágenes, otras han sido desarrolladas para solucionar problemáticas específicas del quehacer académico.

El mundo se encuentra cada vez más interconectado y el sector académico no es una excepción, razón por la cual los avances científicos y tecnológicos suceden cada vez con mayor rapidez. Para ser partícipes activos de estos avances es necesario identificar áreas de oportunidad, ya sea en la forma de temas poco explorados que se verían enriquecidos por nuevas perspectivas, o como desarrollos multidisciplinarios e interdisciplinarios de temas en boga. De cualquier manera, el primer paso para identificar estas áreas de oportunidad es contar con una visión global de los desarrollos existentes relacionados al tema de interés. Con esta finalidad se han creado herramientas como *Inciteful*, *Litmaps*, *Connected Papers* y *Open Knowledge Maps*, las cuales proyectan las conexiones existentes entre diferentes estudios en forma de grafos y mapas de conocimiento interactivos. Este tipo de visualizaciones permite al usuario comprender el contexto en el cual han ocurrido los estudios e identificar potenciales líneas de investigación.

Una vez que se cuenta con un tema de investigación definido, es necesario llevar a cabo un extenso estudio bibliográfico. Esta tarea suele consumir una gran cantidad de tiempo, y conforme el cuerpo de conocimiento aumenta puede tornarse en una tarea abrumadora, incluso para los más experimentados. Algunas plataformas de IA como *Jenni*, *Wisio*, *Elicit* y *OpenRead* permiten automatizar ya sea parte o en su totalidad este proceso de búsqueda extensa y procesamiento de información bibliográfica. Estas herramientas incluyen agentes semánticos que a través de NLP generan resúmenes de artículos científicos, destacando los hallazgos más importantes, encontrando contenido relacionado e indicando tendencias claves. Utilizadas de manera responsable, verificando la información y fuentes cuando es necesario, estas herramientas permiten ahorrar tiempo en la realización de estudios bibliográficos, la conceptualización de estudios o la actualización de información.

En la era de la información, con enormes y complejos bancos de datos a disposición, un problema recurrente es el arreglo y acomodo de estos para su análisis y presentación. Tradicionalmente llevar a cabo estas tareas ha requerido de amplios conocimientos de estadística y programación, sin embargo, algunas herramientas de IA están cambiando este escenario. La transición se está dando de diferentes maneras, en algunos casos, herramientas para análisis de datos como *Microsoft® Fabric* y *Cognos Analytics de IBM®* han ido incorporando módulos de IA para automatizar sus procesos y permitir instrucciones en lenguaje natural. Por su parte, asistentes de IA como *GPT-4o* han habilitado en su plataforma el análisis de datos ya almacenados en la nube. Por último, existen herramientas de IA desarrolladas exclusivamente para el análisis de datos, como *Julius* cuya interfaz puede resultar más intuitiva para el usuario final. Sin importar sus diferencias, todas estas herramientas permiten a los usuarios llevar a cabo sus análisis en una fracción del tiempo usualmente requerido y lograr visualizaciones de alta calidad, ayudándoles a comunicar de manera más efectiva sus resultados.

La producción de textos académicos es una tarea sumamente importante, pues es el medio principal a través del cual la comunidad académica se mantiene informada de los avances en su área. Lograr textos de alta calidad que presenten la información de manera clara y convincente requiere tanto de experiencia como del dominio de los recursos de redacción adecuados. Esta tarea, ya de por sí demandante, se vuelve aún más compleja si el texto debe ser escrito en un idioma diferente al nativo del autor. Con el fin de atenuar estas dificultades, herramientas basadas en IA como *Grammarly*, *QuillBot* y *Jarvis* han sido desarrolladas para fungir como asistentes de escritura. A diferencia de las herramientas de generaciones anteriores, que se limitaban a identificar y corregir errores ortográficos y gramaticales, las nuevas herramientas de IA sugieren modificaciones al texto que mejoran su coherencia y claridad (Figura 2). De similar manera, también pueden sugerir cambios en la estructura y selección de palabras para que permitan una comunicación más efectiva de las ideas principales.



Figura 2. Creada con la herramienta Copilot (DALL-E 3) con IA usando el prompt: “Crea una imagen donde se aprecien las diferentes herramientas con IA empleadas en la academia”

4. PROS Y CONTRAS DE LA IA EN LA ACADEMIA

¡Parece magia! ¡está increíble!, son algunas de las expresiones que surgen cuando a ChatGPT se le pide que haga un cuestionario con preguntas en diferentes formatos sobre algún tema en particular y lo genera con bastante acierto y de manera instantánea. Como hemos visto, la IA en la academia puede ofrecer diferentes beneficios como la generación instantánea de información (ChatGPT, *Inciteful*, *Litmaps*, *Jenni*, etc.), la interacción personalizada (que se refiere a que las aplicaciones responden a solicitudes específicas de cada usuario), el aprendizaje adaptativo y una creciente accesibilidad (Samala et al., 2024). Por ejemplo, ChatGPT puede proporcionar respuestas rápidas y estructuradas, escritos con un aparente buen nivel de contenido (Cotton et al., 2023) o bien, simplificar temas complejos a los usuarios. Adicionalmente y por lo general, logra entender el tema que se está abordando en una conversación y dar respuestas coherentes dentro del contexto. En la historia del desarrollo de ChatGPT esas habilidades son un avance significativo respecto a las primeras versiones que se desarrollaron en 2018 que no ofrecían esas posibilidades (Samala et al., 2024). También se postula que la IA podría ayudar a mejorar los procesos de enseñanza y aprendizaje, auxiliar en el desarrollo de habilidades en los estudiantes y hacer más eficientes las actividades académicas (Pisica et al., 2023). Por ejemplo, por la aproximación personalizada y asincrónica que permitiría un acceso al conocimiento en periodos más flexibles, por el uso de nuevas herramientas para transmitir el conocimiento de manera más lúdica o extensa como asistentes de voz y porque puede proveer diferentes recursos como traductores, programas de estudio, experiencias interactivas y retroalimentación instantánea.

Sin embargo, también hay algunos aspectos que necesitan ser atendidos por su falta de claridad o desarrollo, como la existencia de errores o inexactitudes. Por ejemplo, se sabe que algunos modelos extensos de lenguaje (LLM por sus siglas en inglés) como ChatGPT pueden inventar literatura científica e incluso construir detalles sobre esa literatura (las llamadas “alucinaciones”) (Bahrini et al., 2023). Como

podemos imaginar, tales alucinaciones y su uso representan un problema potencial en la academia si las personas usan esa información inventada sin verificarla. De hecho, si se observa con atención, ChatGPT presenta en su pantalla de chat un aviso de “descargo de responsabilidad” que indica “ChatGPT puede cometer errores. Comprueba la información importante”. A lo que podríamos preguntarnos ¿qué información es “importante”? y si toda la información obtenida por estos medios debería ser verificada por los usuarios.

Otro aspecto crítico es la falta de inteligencia emocional en la IA, lo que genera interacciones mecánicas desprovistas de empatía genuina. Existen también preocupaciones sobre la privacidad de la información, ya que los usuarios no solo obtienen información de las IAs, sino que también proporcionan información personal (por ejemplo durante el registro) y contribuyen al entrenamiento de estos sistemas con sus solicitudes específicas (Bahrini et al., 2023). Todos hemos escuchado que cuando alguien realiza búsquedas en la web o las redes sociales sobre algún tema o necesidad en particular (por ejemplo, un viaje), después empiezan a recibir anuncios publicitarios relacionados con lo buscado previamente. Se piensa incluso que en el ámbito de la academia, la retroalimentación de estudiantes y académicos es potencialmente más especializada e incluso útil, pero aún no está claro cómo se usa dicha retroalimentación y a quién beneficia.

La dependencia excesiva o gradual que se puede llegar a tenerse de la IA (Samala et al., 2024) es otro aspecto por cuidar. Por un lado, si se llegase a tener una dependencia excesiva de las herramientas con IA (como ChatGPT, *Inciteful*, *Litmaps*, *Jenni*, etc.), se corre el riesgo de fomentar una falta de autonomía del usuario pudiendo conllevar a una disminución del pensamiento crítico y de la motivación (Samala et al., 2024). Adicionalmente, si la mayoría de las personas empiezan a usar las herramientas con IA para realizar tareas y en consecuencia, las realizan más rápidamente que una persona que no las usa, se podría empezar a generar la presión de usar dichas herramientas con IA para mantener la competitividad, creando así la llamada “dependencia por competitividad” (Bahrini et al., 2023). Aunque no hay que perder de vista que hacerlo rápido no significa hacerlo bien y justo ahí es donde toma importancia la responsabilidad que cada persona puede dar al uso de las herramientas con IA.

Otro tema preocupante son los potenciales sesgos en las respuestas generadas por algunas herramientas con IA. En teoría, las respuestas generadas con IA deberían estar desprovistas de sesgos, discriminación y ser objetivas. Sin embargo, algunos expertos advierten que las respuestas podrían contener sesgos de origen debido al proceso de recopilación de datos y cómo se clasifica la información que se usa para generar las respuestas. Como dato curioso, se ha indicado que para el entrenamiento inicial de ChatGPT se utilizaron los artículos publicados por el New York Times, quien después demandó a ChatGPT (Bahrini et al., 2023), pero fuera de eso, podemos deducir que si basaron su entrenamiento (al menos inicial) en los artículos del New York Times, las respuestas basadas en esa información podrían contener la visión de ese diario estadounidense. Adicionalmente, el funcionamiento automático y predictivo de la IA puede llevar a generalizaciones incorrectas y su funcionamiento poco claro no se alinea con principios democráticos (Cossette-Lefebvre & Maclure, 2023) o de transparencia. Por lo anterior, resulta importante cuidar y garantizar que esos aspectos en la compilación y generación de datos y funcionamiento de la IA se enmarquen en regulaciones éticas, de justicia, equidad, objetividad y no discriminación.

De ahí que otros autores han identificado problemas adicionales a atender como el de las bases éticas (Bahrini et al., 2023) y legales (Regulation (EU) 2024/1689) del uso de la IA. Por un lado, se postula que son necesarias bases éticas como la aplicación de principios y prácticas que aseguren que el desarrollo, la implementación y el uso de las IAs de manera transparente, equitativa, sin discriminación, responsable y respetuosa de los derechos y el bienestar de todas las personas. Por otro lado, parece necesario disponer de leyes que regulen tanto a los desarrolladores como a las empresas que utilizan IA y que provean de lineamientos de uso claros a los usuarios. La Comunidad Europea (CE) ha tomado la delantera en ese sentido al publicar la primera legislación sobre IA, conocida como la Ley de IA, de la CE (Regulation (EU) 2024/1689) (Figura 3).




Figura 3. Creada con la herramienta Copilot (DALL-E 3) con IA usando el prompt: “Crea una imagen donde se aprecien los desafíos del uso de las herramientas con IA en la academia como la transparencia, la equidad, el marco legal, la privacidad, el uso ético y responsable”

5. PERSPECTIVAS

Como se describió previamente, el uso de la IA en la academia ofrece diferentes beneficios, como la generación rápida de información, la interacción personalizada, el aprendizaje adaptativo y una creciente accesibilidad. Existen muchas herramientas que pueden ayudar en diferentes etapas del quehacer académico. Sin embargo, antes de centrarse en mejorar estas herramientas y extender los beneficios, es fundamental atender los aspectos éticos y legislativos que regulen la creación y el uso de herramientas basadas en IA. La regulación puede provenir tanto de los gobiernos, como en el caso de la Comunidad Europea, como de las instituciones académicas. En efecto, algunos expertos proponen que las instituciones podrían desarrollar sus propias infraestructuras de IA, estableciendo lineamientos éticos y claros sobre su creación. Esto no solo fomentaría la transparencia, la independencia y el uso responsable (Bahrini et al., 2023), sino que también permitiría mejorar las herramientas de IA a través de la retroalimentación, permitiendo aplicaciones más versátiles, robustas, equitativas y útiles. Implementar modelos piloto y probarlos gradualmente ayudaría a fortalecer el uso responsable de estas tecnologías (Yawson, 2024). Adicionalmente, la integridad académica se robustecería frente al uso de la IA si se implementaran estrategias como el desarrollo de políticas de uso, la capacitación, el aprendizaje y la mejora de los métodos de detección de plagio (Cotton et al., 2023; Miao & Holmes, 2023). Con el establecimiento de bases éticas y jurídicas, el desarrollo de futuras mejoras o innovaciones relacionadas con la IA se harían en un marco de respeto, ética y responsabilidad.

En cuanto a la mejora de las herramientas con IA, se ha identificado que los sesgos presentes en los datos de entrenamiento y las limitaciones en el razonamiento de algunas herramientas son áreas potenciales por optimizar (Yawson, 2024). Los datos utilizados en el entrenamiento de la IA generativa es un componente clave que debería ser revisado y evaluado por expertos externos para evitar sesgos y

huecos de información. Además, aunque herramientas como ChatGPT pueden generar respuestas rápidas, aún tienen capacidad limitada para realizar análisis profundos y razonamientos complejos, lo que posiblemente lleva a las llamadas “alucinaciones” o inventos de literatura científica. Estas limitaciones deberían ser abordadas antes de que la IA generativa se adopte de manera generalizada en la academia.

Algunos expertos sugieren que la IA debe ser adoptada de manera gradual como herramientas complementarias (el principio de la equivalencia sustancial), sin reemplazar la labor de los usuarios y siempre respetando principios éticos y de responsabilidad. Sin embargo, esta estrategia podría seguir generando dependencia hacia las compañías que desarrollan estas tecnologías, sin garantizar la transparencia ni la ausencia de sesgos en los datos de entrenamiento (Yawson, 2024). Por otro lado, hay quienes proponen que se aplique el principio de precaución antes de integrar la IA en la academia. Esto implica evaluar primero los riesgos potenciales de la IA, no solo sus beneficios potenciales, antes de adoptarla de manera más generalizada. Lo cierto es que la IA ya se está volviendo común en el ámbito académico, con muchos estudiantes utilizando herramientas como ChatGPT. Por ello, es urgente establecer las bases éticas y legislativas que regulen su uso, así como capacitar a los integrantes de la comunidad académica para manejar estas tecnologías de manera ética y responsable. Esto permitirá ir a la par del desarrollo tecnológico y mantener los estándares académicos asegurando un uso consciente y regulado de estas herramientas en la educación superior.

6. REFERENCIAS

- Bahrini, A., Khamoshifar, M., Abbasimehr, H., Riggs, R. J., Esmaeili, M., Majdabadkohne, R. M., & Pasehvar, M. (2023). ChatGPT: Applications, Opportunities, and Threats. *2023 Systems and Information Engineering Design Symposium, SIEDS 2023*, 274–279. <https://doi.org/10.1109/SIEDS58326.2023.10137850>
- Cossette-Lefebvre, H., & Maclure, J. (2023). AI's fairness problem: understanding wrongful discrimination in the context of automated decision-making. *AI and Ethics*, 3(4), 1255–1269. <https://doi.org/10.1007/s43681-022-00233-w>
- Cotton, D. R. E., Cotton, P. A., & Shipway, J. R. (2023). Chatting and cheating: Ensuring academic integrity in the era of ChatGPT. *Innovations in Education and Teaching International*, 1–12. <https://doi.org/10.1080/14703297.2023.2190148>
- Jackson, P. (1998). *Introduction to Expert Systems* (3rd ed.). Addison-Wesley Longman Publishing Co., Inc.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- McCarthy, J. (1974). Artificial intelligence: a paper symposium: Professor Sir James Lighthill, FRS. Artificial Intelligence: A General Survey. In: Science Research Council, 1973. *Artificial Intelligence*, 5(3), 317–322. [https://doi.org/10.1016/0004-3702\(74\)90016-2](https://doi.org/10.1016/0004-3702(74)90016-2)
- Miao, F., & Holmes, W. (2023). *Guidance for generative AI in education and research*. UNESCO. <https://doi.org/10.54675/EWZM9535>
- Moor, J. (2006). The Dartmouth College Artificial Intelligence Conference: The Next Fifty Years. *AI Magazine*, 27(4), 87–91.
- Nadkarni, P. M., Ohno-Machado, L., & Chapman, W. W. (2011). Natural language processing: an introduction. *Journal of the American Medical Informatics Association*, 18(5), 544–551. <https://doi.org/10.1136/amiajnl-2011-000464>

- Pisica, A. I., Edu, T., Zaharia, R. M., & Zaharia, R. (2023). Implementing Artificial Intelligence in Higher Education: Pros and Cons from the Perspectives of Academics. *Societies*, 13(5), 118. <https://doi.org/10.3390/soc13050118>
- Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). Improving Language Understanding by Generative Pre-Training. In *OpenAI blog*.
- Radford, A., Wu, J., Child, R., Luan, D., Amodel, D., & Sutskever, I. (2019). Language Models are Unsupervised Multitask Learners. In *OpenAI blog* (Vol. 1).
- Samala, A. D., Rawas, S., Criollo-C, S., Bondarenko, O., Gentarefori Samala, A., & Novaliendry, D. (2024). Harmony in Education: An In-Depth Exploration of Indonesian Academic Landscape, Challenges, and Prospects Towards the Golden Generation 2045 Vision. *TEM Journal*, 2436–2456. <https://doi.org/10.18421/TEM133-71>
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., van den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lillicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., & Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484–489. <https://doi.org/10.1038/nature16961>
- Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind*, LIX(236), 433–460. <https://doi.org/10.1093/mind/LIX.236.433>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention Is All You Need. *Proceedings of the 31st International Conference on Neural Information Processing Systems*. <https://doi.org/10.5555/3295222.3295349>
- Weizenbaum, J. (1966). ELIZA—a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1), 36–45. <https://doi.org/10.1145/365153.365168>
- Yawson, R. M. (2024). Perspectives on the promise and perils of generative AI in academia. *Human Resource Development International*, 1–12. <https://doi.org/10.1080/13678868.2024.2334983>



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-CompartirIgual 2.5 México.