

**Una exploración por los avances del Machine Learning que optimizan la agricultura
latinoamericana**

Jhonatan Andrés Alfonso Gamboa

Asesor

Edgar Felipe Ruiz Roberto

Universidad Nacional Abierta y a Distancia UNAD
Escuela de Ciencias Básicas, Tecnología e Ingeniería
Especialización en Ciencia de Datos y Analítica

2024

Agradecimientos

Quiero comenzar agradeciendo a Dios, quien me ha dado la fuerza y la perseverancia necesarias para alcanzar esta nueva meta académica en mi vida. Su guía ha sido fundamental en este camino.

Extiendo un especial agradecimiento a mi hermana Diana Alfonso por su invaluable apoyo durante el desarrollo de este ejercicio. Su experiencia como investigadora fue una contribución significativa y un pilar esencial para el logro de este objetivo.

Asimismo, quiero expresar mi profunda gratitud al ingeniero Edgar Felipe Ruiz Roberto, quien desempeñó un papel crucial como asesor de grado. Su experiencia, conocimientos y dedicación fueron clave para el éxito de esta monografía. Estoy enormemente agradecido por su orientación y por haberme acompañado en cada paso de este proceso.

Finalmente, agradezco de corazón a mi familia, quienes, en múltiples ocasiones, dedicaron su tiempo y esfuerzo para apoyar la organización y preparación de este proyecto. Su respaldo fue esencial en momentos críticos, y siempre valoraré profundamente su disposición para ayudarme en el desarrollo de este trabajo.

Resumen

El presente trabajo analiza los avances y aplicaciones del Machine Learning en la agricultura latinoamericana, destacando su impacto en la optimización de procesos productivos y la sostenibilidad ambiental. A través de una revisión documental exhaustiva, se identificaron casos de uso relevantes en áreas como la predicción meteorológica, el monitoreo de plagas y enfermedades, la optimización del riego y el impacto económico y medioambiental. La metodología incluyó la recopilación y análisis sistemático de fuentes científicas, organizando la información en cuatro categorías principales para una visión integral de las contribuciones tecnológicas en el ámbito agrícola.

Los resultados evidencian que el uso de modelos de Machine Learning, como redes neuronales y árboles de decisión, permite mejorar la toma de decisiones mediante la identificación de patrones complejos en grandes volúmenes de datos. Estas aplicaciones han optimizado el uso de recursos como el agua y los fertilizantes, reducido el impacto ambiental, y aumentado la productividad de los cultivos.

Este trabajo destaca la necesidad de superar las brechas tecnológicas y económicas que limitan la adopción de estas herramientas en la región. A través de un análisis crítico de los casos documentados, se presentan recomendaciones prácticas para la implementación efectiva de Machine Learning en la agricultura.

Palabras Claves: Agricultura, Machine Learning, Latinoamérica, Variables Target, Modelo predictivo.

Abstract

This study analyzes the advancements and applications of Machine Learning in Latin American agriculture, highlighting its impact on optimizing production processes and promoting environmental sustainability. Through an extensive literature review, relevant use cases were identified in areas such as meteorological prediction, pest and disease monitoring, irrigation optimization, and economic and environmental impacts. The methodology involved systematic collection and analysis of scientific sources, organizing the information into four main categories to provide a comprehensive view of technological contributions to the agricultural sector.

The results reveal that the use of Machine Learning models, such as neural networks and decision trees, enhances decision-making by identifying complex patterns in large datasets. These applications have optimized the use of resources like water and fertilizers, reduced environmental impact, and increased crop productivity. Moreover, Machine Learning-based technologies contribute to the economic development of rural communities by enabling the adoption of more sustainable and efficient agricultural practices.

This research underscores the need to bridge the technological and economic gaps that limit the adoption of these tools in the region. Through a critical analysis of documented cases, practical recommendations are provided for the effective implementation of Machine Learning in agriculture.

Keywords: Agriculture, Machine Learning, Latin America, Target Variables, Predictive Model.

Tabla de Contenido

Marco de Referencial	9
Planteamiento del Problema.....	9
Justificación.....	12
Objetivos	16
Objetivo General	16
Objetivos Específicos.....	16
Metodología	17
Marco Conceptual.....	23
Machine Learning	23
Técnicas Principales de Machine Learning.....	25
Algunos Modelos de Machine Learning.....	29
Árboles de Decisiones	29
Random Forest	30
Gradient Boosting.....	30
KNN (Vecinos Cercanos).....	31
SVM (Máquina de Soporte Vectorial)	31
Redes Neuronales	31
Aplicación de Machine Learning en la Agricultura.....	32
Predicción Meteorológica para el Rendimiento de Cultivos.....	33
Monitoreo de Plagas y Enfermedades	38
Optimización del Riego.....	41
Agricultura Inteligente y su Impacto en la Economía y el Medio Ambiente.....	43

Estado del Arte.....	48
Análisis de Resultados	52
Análisis de Resultados de la Categoría 1: Impacto del Machine Learning en la Predicción	
Meteorológica	54
Variables Climáticas	55
Variables del Suelo.....	56
Variables del Cultivo.....	56
Variables Espectroscópicas	56
Monitoreo de Plagas y Enfermedades.....	58
Optimización del Riego.....	60
Variables del Suelo.....	60
Variables Climáticas.....	61
Variables del Cultivo.....	61
Histórico	61
Impacto Económico y Medioambiental	62
Predicción en el Volumen de los Cultivos	62
Impacto en el Medio Ambiente	62
Conteos de Productos Obtenidos.....	63
Planificación de Personal	63
Oferta y Demanda Territorial	63
Conclusiones	64
Recomendaciones de Investigación	67
Referencias Bibliográficas	69

Lista de Tablas

Tabla 1 <i>Bases de Datos Consultadas para la Monografía</i>	19
Tabla 2 <i>Matriz de Contenido Aplicada para Obtener la Información de los Documentos</i>	21
Tabla 3 <i>Categorías de Aprendizaje de Machine Learning</i>	26

Lista de Figuras

Figura 1 <i>Elementos Revisados para la Selección de Documentos</i>	18
Figura 2 <i>Prisma de Filtración de la Documentación a Usar</i>	20
Figura 3 <i>Diferencias entre la Programación Clásica y el Aprendizaje Automático</i>	24
Figura 4 <i>Resultados de la Clasificación de los Documentos</i>	53
Figura 5 <i>Variables Categoría Impacto del Machine Learning en la Predicción Meteorológica</i>	55
Figura 6 <i>Modelos de Aprendizaje Categoría Impacto del Machine Learning en la Predicción Meteorológica</i>	57
Figura 7 <i>Variables Utilizadas en la Categoría Monitoreo de Plagas y Enfermedades</i>	58
Figura 8 <i>Modelos de Aprendizaje Aplicados en la Categoría 2</i>	59
Figura 9 <i>Variables que se Estudiaron en la Categoría Optimización del Riego</i>	60

Marco de Referencial

Planteamiento del Problema

La agricultura en América Latina se encuentra actualmente con problemas de sostenibilidad en gran medida a causa de la falta de actualización y adaptabilidad a los cambios tecnológicos y técnicos que se han ido desarrollando a través del tiempo. Podría llegar a decirse que estamos actualmente viviendo en un mundo de producción agrícola antiguo con necesidades y demandas de un mundo agrícola totalmente nuevo. Un ejemplo claro de esto es la actual demanda de alimentos y vegetales que no es la misma de hace algunos años en que el nivel de población no es de la misma magnitud que la del 2020.

Además, sabemos muy bien que los cambios climáticos producto de la contaminación actual son las causantes de los problemas de la salud y la inestabilidad en la calidad con la que están creciendo los cultivos, esto concluye en grandes pérdidas de los productos agrícolas, los cuales son esenciales para la sostenibilidad de las poblaciones; por otro lado, la actual demanda de agua para el uso de los cultivos es una de las problemáticas entre agricultores que buscan este recurso para lograr sus metas de oferta en cada región, y muchas otras situaciones que actualmente están ubicando a la productividad agrícola al borde de un colapso productivo y económico, afectado por dificultades sociales, económicas, sociales y medioambientales (Magrin, 2015).

El territorio latinoamericano es caracterizado porque sus extensiones de tierra son las adecuadas para llevar a cabo la actividad de la agricultura, la cual en muchas ocasiones se evidencia como el principal medio de ingreso económico en el PIB de los países que hacen parte de este territorio. No obstante, ese estancamiento tecnológico que se ha evidenciado frente a la posibilidad de aplicar tecnologías innovadoras que potencien en este campo ha dificultado la

optimización de la producción agrícola, en donde se puede observar dificultades al momento de gestionar los recursos que se necesitan en los cultivos, las prácticas no sostenibles que llevan a cabo algunos granjeros como aplicación que grandes cantidades de pesticidas y la baja productividad en comparación con otros países del mundo que no tienen a su disposición terrenos tan ricos y nutritivos para aplicar esta actividad (Carrillo-Rojas et al., 2020; FAO, 2019).

Podemos plantear que este problema radica, inicialmente por la gran limitación que hay en el acceso de estas nuevas tecnologías de la industria 4.0 por parte de los agricultores, normalmente por los altos costos iniciales que deben pagarse para su adquisición, algo que es casi imposible de lograr para estas poblaciones que normalmente se destacan por un poder adquisitivo bastante bajo. Por otra parte, también influye el desconocimiento por parte de los agricultores de estas nuevas tecnologías y la resistencia que tienen para hacer uso de estas debido a la adaptabilidad de técnicas que han usado de generación en generación en las familias. Esto ha llevado a que ellos no encuentren esas ventajas dentro del trabajo en el campo en donde facilitaría en gran medida su trabajo, disminuiría la tasa de pérdida de productos y lograría objetivos de optimización de calidad y duración de las plantas.

De acuerdo con Montaña (2002), las aplicaciones de tecnologías en los campos agrícolas aún no han alcanzado su pleno potencial debido a diversos factores como la dificultad para acceder a datos de alta calidad, la persistente brecha tecnológica en áreas rurales y la falta de conocimiento sobre estas alternativas tecnológicas entre la población dedicada a la agricultura. Una de las principales razones por las que ocurre esto es porque gran parte de la población agricultora es de personas de edad avanzada que están adaptadas a métodos tradicionales agrícolas y, por el desconocimiento de las actuales tecnologías, no pueden o no quieren acceder a estas para mejorar los resultados de sus cultivos. Esta brecha tecnológica obstaculiza el

desarrollo de estrategias que contribuya con un rendimiento óptimo y control sobre las condiciones climáticas, del manejo de cultivos, del monitoreo de plagas y enfermedades, entre otros (FAO, 2020; Moriasi et al., 2019). Este aspecto es importante teniendo en cuenta que la diversidad de condiciones climáticas, suelos y sistemas de cultivo en América Latina demanda enfoques adaptativos y específicos para cada contexto agrícola con herramientas tecnológicas adecuadas que consideren estas particularidades para la adopción de prácticas agrícolas más eficientes y sostenibles (Ruíz et al., 2018).

Innovadores de la sociedad latinoamericana ha encontrado en el Machine Learning una estrategia accesible, adaptativa y escalable para los agricultores, no obstante, a pesar de sus avances y la creciente disponibilidad de datos agrícolas, su implementación efectiva en la región es limitada (Lu, 2017). Es esencial documentar las prácticas agrícolas que han incorporado el Machine Learning, analizando sus ventajas, desventajas, dificultades, casos de éxito y fracasos en diferentes territorios, así mismo, un breve estudio económico que tiene su aplicación en los resultados financieros de distintos productos. En este sentido, surge el interrogante sobre cómo aprovechar al máximo los avances en Machine Learning para optimizar la agricultura en América Latina. ¿Cómo se ha adaptado y aplicado el Machine Learning para mejorar la agricultura latinoamericana?

Justificación

La agricultura es una actividad que tiene gran trabajo en gran parte de los países latinoamericanos, en donde se busca el desarrollo adecuado de cultivos para producir alimentos y materia prima. Al reconocer que es una actividad de la que dependen mucho estos países, actualmente requiere una adopción innovadora apoyado en la tecnología que nos provee la industria 4.0 con el objetivo de mejorar considerablemente la productividad y sostenibilidad. Los planteamientos de Pérez (2019) resaltan esa importancia de la innovación tecnológica en el campo agrícola y los alcances que llegaríamos a obtener acorde a la implementación de estas, convirtiendo así en un campo competitivo y que aportaría sustentablemente a la economía de cada territorio latinoamericano. Por ende, es en el uso de las técnicas de Machine Learning, como una posible promesa que contribuya a la optimización de distintos factores, variables y sectores que influyen dentro de la agricultura, impulsando así el crecimiento de la comunidad agrícola que no ha logrado responder con las demandas consumistas actuales de la sociedad. Rodríguez (2019) señala que a través de algoritmos de Machine Learning, o también conocido como aprendizaje automático, se logra predecir con alta precisión variables fundamentales para que el crecimiento de los cultivos sea el adecuado. De igual manera, Pérez y Díaz (2021) indica que a través de estos algoritmos la optimización de los recursos es evidente, contribuyendo a la inversión que tienen que hacer los agricultores y aportando a la vez a disminuir el impacto que tienen las prácticas agrícolas en el medio ambiente. En esta misma línea, García (2021) argumenta que adoptar tecnologías de la industria 4.0 como el Machine Learning es decisión apropiada para aumentar el control del uso de los recursos naturales y reducir el daño que provocan prácticas como el uso de pesticidas o excesivo consumo de agua.

Es evidente que los avances continuos y apresurados que ha tenido en el machine Learning han causado una revolución en la forma en que se puede abordar la agricultura en Latinoamérica. Castro (2020), indica que la importancia de la implicación de esta tecnología en los campos agrícolas radica en la toma de decisiones basadas en evidencias y datos, algo que normalmente está acostumbrado a llevarse a través de deducciones y experiencias por parte de los granjeros, que en ocasiones son algo imprecisas. De igual manera, lograría establecer la cantidad adecuada de recursos que se deben suministrar a un volumen específico de cultivos, disminuyendo así el desperdicio de productos necesarios que se evidencia en ahorro económico y material para las poblaciones granjeras. García, coincide también al señalar que el Machine Learning ofrece esa capacidad de analizar los datos exactos de nuestro entorno, los cuales son útiles para encontrar esos patrones y tendencias en el comportamiento de los cultivos y los factores que influyen en estos, logrando así tomar decisiones basadas en evidencias exactas y científicas que permitan la correcta gestión de los cultivos y los recursos necesarios para el crecimiento de estos. Lo anterior, va a permitir que el sector agrícola tome decisiones informadas y a tiempo, concluyendo en una mayor productividad, gestión adecuada de las cantidades de productos a suministrar, y a la vez en la sostenibilidad ambiental para preservar la biodiversidad a través de la mitigación del cambio climático.

Por otra parte, un elemento importante a implementar a través del machine Learning es la posibilidad de inclusión y crecimiento económico que llegue a contribuir al desarrollo rural, logrando así una mayor oportunidad por parte de la población agrícola para acceder a nuevos recursos tecnológicos y oportunidades laborales. Según Fernández (2020), la accesibilidad a herramientas de análisis de datos y modelos predictivos puede nivelar el campo de juego para agricultores de todos los tamaños, permitiendo a pequeñas y medianas organizaciones competir

en igualdad de condiciones con grandes entidades. De igual manera, Soto y Mendoza (2018) indican que la implementación de tecnología basada en Machine Learning es una posibilidad tecnológica que contribuiría significativamente en la adquisición económica y monetaria de los agricultores y sus familiares, mejorando así la calidad de vida de estas poblaciones que tanto se identifican por sus altos niveles de pobreza. Además, García y Martínez (2022) destacan que el uso de algoritmos de aprendizaje automático puede ayudar a los agricultores esas necesidades actuales del mercado, logrado que ellos también innoven en los productos a cultivar acorde a las necesidades de las poblaciones y la demanda de productos que se soliciten por parte de ellos. Estos hallazgos han evidenciado el importante e innovador papel que tiene el Machine Learning para disminuir esa brecha económica y tecnológica que existe en las zonas rurales en comparación con las urbanas.

De ahí que, la relevancia de esta monografía radica en ofrecer ese documento que recopile todas esas experiencias que han tenido distintos investigadores e ingenieros aplicados en territorios agrícolas latinoamericanos, posibilitando así a una nueva mirada de cómo la implementación de esta tecnología en la agricultura puede mejorar desde el aspecto estratégico, táctico y operativo en el ámbito agrícola dotando de esta población de conocimientos innovadores y las herramientas necesarias para impulsarlo. La revisión y posterior análisis crítico de la literatura científica que se ha dispuesto a la comunidad puede entregar a la comunidad ingeniera y agrícola ejemplos prácticos que ilustren la aplicación exitosa de técnicas y modelos de machine Learning en la agricultura y la forma en que fueron implementadas, proporcionando así una comprensión más profunda de cómo implementar estas tecnologías en sus propias operaciones agrícolas. Al comprender mejor las aplicaciones prácticas de Machine Learning en la agricultura, se pueden tomar decisiones informadas y adoptar prácticas más eficaces y

sostenibles en sus actividades diarias, promoviendo así un desarrollo agrícola más eficiente y respetuoso con el medio ambiente en Latinoamérica.

Objetivos

Objetivo General

Explorar los avances del Machine Learning en la optimización de la agricultura latinoamericana, evaluando su impacto a través de documentación científica y estudios de caso encontrados en diversas bases de datos especializadas.

Objetivos Específicos

Explicar algunos modelos de Machine Learning usados en la agricultura por los autores de los documentos analizados.

Interpretar cómo el machine Learning ha optimizado la agricultura y su contribución en factores económicos y ambientales.

Inferir los desafíos de adopción de tecnologías de Machine Learning en la agricultura de América Latina.

Proporcionar recomendaciones para aplicaciones prácticas de Machine Learning en la agricultura de América Latina.

Metodología

El enfoque de la presente investigación es de carácter cualitativo, caracterizado porque, según Sampieri (2012), “se busca examinar la forma en que los individuos perciben y experimentan los fenómenos que los rodean, profundizando en sus puntos de vista, interpretaciones y significados” (p.84). A través de estas percepciones, vivencias y el ejercicio experimental y práctico que llevaron a cabo varios investigadores en el campo del machine Learning aplicado a la agricultura, podremos obtener algunas tendencias en las estrategias aplicadas acorde a la situación, situaciones problema vividas en estas y consecuencias que trajeron para solventar las necesidades de una comunidad determinada.

Se aplica como herramienta de investigación el análisis documental, aprovechando que los recursos digitales que nos suministran las bases de datos de distintas universidades o centro de desarrollo que contienen información importante y sustancial para acercarnos a los datos que se están buscando, y que son una fuente importante de datos que nos puede ayudar a entender las tendencias al fenómeno de estudio que se desea conocer (Sampieri,2012).

La metodología se desarrolla dentro del análisis de contenido, en donde se busca examinar sistemáticamente documentos adecuados para identificar patrones, temas y situaciones problemas del contexto de trabajo, realizando la selección de los documentos adecuados a través de niveles de importancia en el tema de la siguiente forma:

Figura 1*Elementos Revisados para la Selección de Documentos*

Nota. Construcción de una pirámide jerárquica de evaluación de documentos en el contexto del machine Learning aplicado a la agricultura.

A través de bases de datos, se busca documentos que permitan comprender las aplicaciones del machine Learning y su relación con la agricultura. En la siguiente tabla podremos observar las bases de datos consultadas y la estructura de las consultas realizadas para obtener los documentos que mejor se pudieran ajustar a la propuesta monográfica.

Tabla 1*Bases de Datos Consultadas para la Monografía*

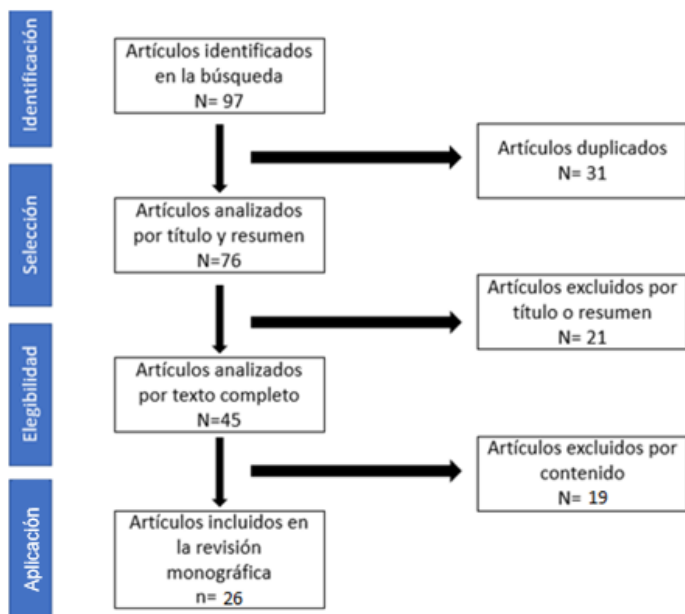
Nombre de la base de datos	Operaciones de búsqueda
Scielo	Machine Learning + Agricultura + Latinoamérica
Google académico	Machine Learning + Agricultura
Redalyc	Machine Learning + Agro ciencias
Dialnet	Machine Learning + Agricultura + Latinoamérica

Nota. Las bases de datos tomadas fueron a consideración y experiencia del investigador.

Posteriormente, se realiza un proceso de descarte de documentos que no cumpliera con los parámetros de la monografía, de tal forma que únicamente quedarán seleccionados aquellos documentos de los que se obtiene información que contribuya al cumplimiento de los objetivos del proyecto. A continuación, se evidencia en un PRISMA de selección la estructura de la revisión de los documentos extraídos. Es importante resaltar que el trabajo de filtrado y descarte de documentos se hizo manualmente sin uso de programas auxiliares para este proceso.

Figura 2

Prisma de Filtración de la Documentación a Usar



Nota. En el prisma se observa el proceso llevado a cabo para determinar los documentos que iban a apoyar la monografía.

A partir de los documentos tomados en cuenta para el desarrollo de la monografía, se elabora una matriz de estudio y contenido que consolida la extracción de la información de los documentos, permitiendo almacenar en esta matriz información relevante respondiendo a la necesidad de la monografía. Esta base de datos creada en Excel contiene los elementos presentados a continuación:

Tabla 2*Matriz de Contenido Aplicada para Obtener la Información de los Documentos*

Datos del documento elegido	Descripción
Referencia completa	Almacena la referencia completa en normas APA
Título del documento	Contiene el nombre completo del título
Año	Indica el año de publicación del artículo
Base de datos	Indica la base de datos en donde se extrae el documento
Topic o mix de búsqueda	Señala las operaciones realizadas para encontrar el documento en la base de datos
Palabras clave	Contiene las palabras clave indicadas por el autor del documento
Resumen	Almacena el resumen del documento por parte del autor.
Tipo de publicación	Señala qué tipo de publicación es el documento.
URL	Enlace para obtener el documento nuevamente
Nombre de la revista	Revista indexada en donde se encuentra el documento
Autor/Autores	Autores que participaron en la investigación
País	País en donde se desarrolla la investigación
Universidad	Universidad donde se produce el ejercicio de investigación
Técnica utilizada para el análisis de datos	Técnicas machine Learning utilizadas en la investigación
Objetivos	Objetivos que se proponían en el documento
Variables dependientes	Variables dependientes que eran tomadas en cuenta en el modelo machine Learning

VARIABLES INDEPENDIENTES	VARIABLES INDEPENDIENTES TENIDAS EN CUENTA EN EL MODELO machine Learning
CONCLUSIONES	CONCLUSIONES OBTENIDAS EN LA INVESTIGACIÓN.

Nota. Los elementos observados en la matriz fueron suministrados en el curso de Proyecto de grado I.

Finalmente, a partir de constantes lecturas en cada uno de los documentos seleccionados, se organiza la información para que responda adecuadamente a los objetivos de la monografía.

Para esto, se organiza en 4 categorías que estructuran la monografía. Estas son las siguientes:

- Predicción meteorológica para el rendimiento de cultivos
- Monitoreo de plagas y enfermedades
- Optimización del riego
- Machine Learning y su impacto en el medio ambiente y la economía.

Marco Conceptual

Machine Learning

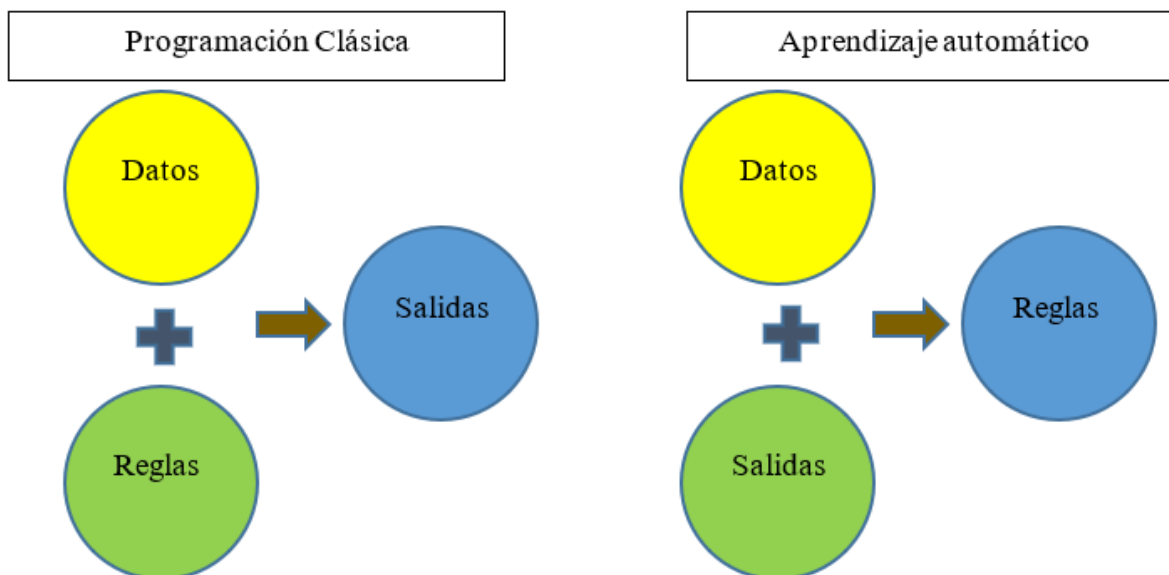
Machine Learning es el término que se utiliza para referirse al aprendizaje automático, un subcampo de la inteligencia artificial que se enfoca en desarrollar algoritmos y modelos que permiten a las computadoras aprender patrones y realizar tareas específicas sin necesidad de una programación detallada para cada paso. Este enfoque se basa en la premisa de que las máquinas pueden aprender de los datos y mejorar su desempeño con la experiencia, sin requerir una intervención humana directa (Russell & Norvig, 2022). Según Bishop (2006), el aprendizaje automático se fundamenta en la capacidad de los sistemas para aprender de los datos, identificar patrones y tomar decisiones con una mínima intervención humana.

En esta misma línea, podemos plantear que el trabajo dentro del aprendizaje automático se fundamenta esencialmente en el hecho de que el mecanismo de la máquina no está restringido en el algoritmo de entrada de datos que a través de procesos muy específicos se genera unos resultados y/o datos de salida, sino que estos datos resultantes y que resultan como salientes de los algoritmos indicados se convierten nuevamente en datos de entrada que permiten trabajar en un ciclo constante de aprendizaje para la máquina, prediciendo así el comportamientos de futuros datos de entrada.

Pineda (2022), nos comparte el siguiente gráfico que nos permite entender cómo se diferencia la programación clásica y el aprendizaje automatizado:

Figura 3

Diferencias entre la Programación Clásica y el Aprendizaje Automático



Nota. El gráfico elaborado está basado en la información suministrada por Pineda, en donde explica qué es el aprendizaje automático.

A partir de ese entrenamiento constante que observamos en la gráfica anterior, en donde la retroalimentación de los datos de entrada y salida son las que determinan los parámetros de nuestros algoritmos, se mejora la capacidad de generar predicciones precisas en futuros casos o datos que no se han visto antes. Este proceso de aprendizaje se basa en el principio de que la experiencia mejora el rendimiento. Por lo tanto, cuanto más información y mejor calidad tengan los datos proporcionados, más preciso será el modelo (Murphy, 2012).

Ahora bien, a pesar de sus ventajas, el machine Learning enfrenta varios desafíos y limitaciones. Uno de los principales retos es la calidad de los datos. Si los datos con los que se entrena un modelo son incompletos, sesgados o de baja calidad, los resultados obtenidos también

serán erróneos o poco fiables. Además, los modelos de machine Learning requieren grandes cantidades de datos para ser efectivos, lo cual puede ser un impedimento en áreas con datos limitados o costosos de obtener.

Otro desafío importante es la interpretabilidad de los modelos. Algunos algoritmos, especialmente los más complejos como las redes neuronales profundas, a menudo son considerados "cajas negras" debido a la dificultad para entender cómo llegan a una determinada conclusión. En ciertas industrias, como la salud o las finanzas, es crucial que los resultados de los modelos puedan explicarse y justificarse adecuadamente (Rudin, 2019).

A manera de conclusión, el machine Learning está revolucionando múltiples sectores al ofrecer soluciones más precisas, rápidas y automatizadas a problemas que antes requerían un enfoque manual y costoso. Sin embargo, su aplicación exitosa depende de la disponibilidad de datos de calidad. A medida que la tecnología avanza, es probable que el machine Learning continúe transformando industrias y modos de vida, siempre y cuando se superen sus desafíos inherentes.

Técnicas Principales de Machine Learning

Los algoritmos de aprendizaje son pilares esenciales en el campo del Machine Learning, y según Alpaydin (2020) se definen como "métodos o reglas que permiten a la máquina aprender a partir de los datos" (p.93). La función principal radica en procesar información y generar modelos que permitan predecir o clasificar nuevos datos con base en el conocimiento adquirido. Estos algoritmos se clasifican en tres categorías principales que se muestran en la siguiente tabla.

Tabla 3*Categorías de Aprendizaje de Machine Learning*

Categoría	Descripción
Aprendizajes supervisados	Se entrena el modelo utilizando datos etiquetados (es decir, datos que ya tienen la respuesta correcta), como resultado, puede asociar entradas con salidas conocidas.
Aprendizajes no supervisados	Se entrena el modelo utilizando datos no etiquetados (es decir, datos que ya tienen la respuesta correcta), como resultado, que debe descubrir patrones o estructuras de manera autónoma.
Aprendizajes por refuerzo	El modelo aprende a través de la interacción con un entorno, recibiendo retroalimentación positiva (recompensas) o negativa (castigos) en función de las acciones realizadas

Nota. La tabla evidencia los tipos de aprendizaje y las características de cada uno de estos.

Elaboración propia a partir de Goodfellow, Bengio, & Courville, 2016.

A partir de la tabla anterior, podemos inferir que el machine Learning se clasifica en varios tipos de aprendizaje, cada uno con características específicas que lo hacen útil para diferentes aplicaciones. A continuación, se presentan los tres tipos principales: supervisado, no supervisado y por refuerzo.

En el primer tipo de aprendizaje automático es el supervisado, el más común en la aplicación y se caracteriza por entrenar modelos utilizando conjuntos de datos etiquetados, es decir, ejemplos de entrada con salidas o respuestas conocidas. La idea es que el modelo aprenda a asociar las características de entrada con las salidas correspondientes. Este tipo de aprendizaje

es adecuado para problemas como la clasificación, proceso mediante el cual se asigna una etiqueta a cada entrada a través de parámetros específicos: Un ejemplo es el ingreso de distintas imágenes que permitan a la máquina identificar a través de patrones si es un animal o una planta.

Por otra parte, una regresión lineal trata de predecir un valor continuo que podemos denominar variables dependientes, a través de variables que son independientes. Un ejemplo es predecir el precio de una vivienda en función de variables como el tamaño, la ubicación y el número de habitaciones.

De ahí, según Alpaydin (2016), el proceso de entrenamiento dentro del aprendizaje supervisado permite que el modelo aprenda la relación entre las características de entrada y las salidas, ajustando sus parámetros a medida que recibe retroalimentación de los errores cometidos. Esto conduce a una mejora en la precisión del modelo conforme más datos son procesados.

Por otra parte, en el aprendizaje no Supervisado el modelo trabaja con datos no etiquetados. Su tarea es identificar patrones, agrupaciones o estructuras ocultas dentro de los datos sin que se proporcionen respuestas predefinidas. El objetivo principal es descubrir estructuras internas o relaciones entre las variables. El método más conocido es el de agrupamiento o clustering, en donde el algoritmo organiza los datos en grupos o clústeres basándose en similitudes entre ellos.

El aprendizaje no supervisado es útil cuando no se tiene un conocimiento previo de los datos o se busca explorar nuevas relaciones que no son evidentes a simple vista. Sin embargo, uno de los principales desafíos es interpretar los resultados, ya que la falta de etiquetas puede dificultar la evaluación de la calidad de las agrupaciones o patrones descubiertos (Murphy, 2012).

Finalmente, el aprendizaje por refuerzo se basa en la interacción de un agente con un entorno, donde el agente toma decisiones y recibe recompensas o penalizaciones según el resultado de sus acciones. El objetivo del agente es maximizar la recompensa acumulada a lo largo del tiempo. Este tipo de aprendizaje es especialmente útil en situaciones donde las decisiones deben ser tomadas de manera secuencial, y las consecuencias de una acción pueden no ser inmediatas.

Un ejemplo clásico de este enfoque es el entrenamiento de agentes para jugar videojuegos o controlar robots. Aquí, el modelo no aprende directamente de ejemplos predefinidos, sino que explora diferentes acciones y observa los resultados obtenidos. A lo largo del tiempo, el agente ajusta su estrategia para mejorar su desempeño general. (Sutton & Barto, 2018).

Cada uno de estos tipos de aprendizaje tiene aplicaciones específicas. El aprendizaje supervisado es ideal cuando se tiene una gran cantidad de datos etiquetados y se busca predecir o clasificar nuevas observaciones. Por otro lado, el aprendizaje no supervisado es útil cuando se quiere explorar los datos sin una idea clara de los resultados esperados. Finalmente, el aprendizaje por refuerzo es adecuado para entornos dinámicos y secuenciales donde las decisiones influyen en futuras recompensas.

A manera de conclusión, el aprendizaje supervisado, no supervisado y por refuerzo representan los tres pilares del machine Learning, cada uno con sus características y aplicaciones. La selección del tipo de aprendizaje adecuado depende de la naturaleza del problema y los datos disponibles. A medida que los datos continúan creciendo en volumen y complejidad, es probable que veamos un aumento en la combinación de estos enfoques para abordar problemas cada vez más sofisticados.

El campo del Machine Learning se fundamenta también en técnicas estadísticas y matemáticas, que van desde la optimización hasta el cálculo de probabilidades para entrenar y evaluar modelos (Bishop, 2006). Estas técnicas posibilitan el ajuste de los parámetros del modelo con el fin de minimizar errores y potenciar su desempeño, destacando así su relevancia en la creación y perfeccionamiento de modelos. La integración de estas técnicas proporciona un marco robusto para adaptar los modelos a la complejidad de los conjuntos de datos y a las tareas específicas, lo cual facilita la toma de decisiones fundamentadas en diversas aplicaciones (Goodfellow, Bengio, & Courville, 2016).

Algunos Modelos de Machine Learning

En la actualidad, existen muchos modelos de machine Learning que se han ido aplicando para responder a las necesidades de un determinado problema. Esos modelos se establecen acorde a la cantidad de datos, a la forma en que se extraen estos datos y forma como tienden relacionarse matemáticamente estos datos a distintas respuestas.

En el presente espaciado vamos a observar algunos de estos modelos que se aplicaron en los distintos documentos observados, resaltando las características de cada uno de estos y las razones por las que se usan frente a distintas situaciones:

Árboles de Decisiones

Este modelo de Machine Learning supervisado no paramétrico son utilizados para procesos de clasificación y regresión. Acorde a la información entregado por Scikit-learn (2024), busca crear un modelo de una variable target mediante el aprendizaje de técnicas de decisiones simples inferidas a partir de las características de los datos. La principal ventaja que tiene este modelo es la facilidad de visualización e interpretación del modelo, organizado por nodo raíz, nodos internos, ramas y hojas, lo cual permite su entendimiento sin conocimientos tan técnicos

sobre el tema. No obstante, es un modelo demasiado sensible, en donde pequeños cambios en los datos puede crear múltiples posibilidades de modelos.

Random Forest

Apoyándonos en la información suministrada por Scikit-learn (2024), los bosques aleatorios son meta-estimadores que se ajustan a una serie de clasificadores de árboles de decisiones que realizan múltiples muestras de árboles de decisiones y a través de la ejecución de promedios se busca mejorar la precisión predictiva y el control del sobreajuste. La ventaja que tiene el uso de este modelo de Machine Learning es que se usan con procesos de regresión y clasificación. También se utilizan mucho debido a su gran versatilidad que permite utilizar datos con muchas variables, que no sean lineales o conjuntos que son desbalanceados. No obstante, la cantidad de recursos computacionales que utiliza este modelo es bastante alto, debido a la cantidad de árboles de decisiones que se pueden llegar a usar para lograr una predicción alta.

Gradient Boosting

Es otro modelo que funciona a través de los árboles de decisiones, que construye modelos aditivos de forma progresiva, optimizando funciones de pérdida diferenciables. Scikit-learn (2024), nos indica que en este modelo se ajustan árboles de regresiones de una cantidad específica de clases al gradiente negativo de la función de pérdida, en otras palabras, el modelo se va construyendo progresivamente a través de la corrección de modelos anteriores, esto permite dar una gran precisión y productividad del modelo. No obstante, al trabajar de manera secuencial, el proceso es bastante lento y este problema se agrava cuando la cantidad de datos es demasiada.

KNN (Vecinos Cercanos)

Es un modelo base y funcional caracterizado por encontrar una cantidad predefinida de muestras de entrenamiento más cercanas en distancia a un punto y que a través de esta cercanía logre predecir una etiqueta de funcionamiento. La ventaja de este modelo es la simplicidad que tiene, la poca necesidad en recursos computacionales, la capacidad de usarse para clasificar y hacer regresiones lineales y su posibilidad de trabajarse en variables discretas y continuas. No obstante, al ser un modelo bastante simple, no es muy útil cuando existe un volumen de datos o si la escalabilidad de estos es enorme, ya que depende de la cercanía que hay entre cada uno de los datos.

SVM (Máquina de Soporte Vectorial)

Según Scikit-learn (2024), las máquinas de soporte vectorial son un conjunto de métodos de aprendizaje supervisados que se utilizan para la clasificación, regresión y detección de valores atípicos. Una de las mayores ventajas que tiene este modelo de aprendizaje es el uso del Kernel, capaz de ayudar a resolver esos problemas no lineales que son bastante habituales en los datos, pero esto se dificulta cuando tiene una gran cantidad de datos donde el modelo se comporta bastante lento para responder a todos estos.

Redes Neuronales

Las redes neuronales es una forma de aprendizaje bastante compleja en donde se trata de interpretar el funcionamiento del cerebro humano y ponerlo en funcionamiento en una máquina para que esta reconozca patrones de la misma forma que lo hacemos los humanos. Es habitual encontrar que los modelos que utilizan estos algoritmos se utilizan para tareas de alta complejidad como lo son el reconocimiento de imágenes, el procesamiento del lenguaje corporal,

la predicción de series temporales, etc.; en otras palabras, es usado en gran medida cuando los datos que se obtienen no son de características estructuradas.

Las ventajas que tienen estos algoritmos en la aplicación de modelos Machine Learning son demasiadas, entre las que se encuentra su posible aplicabilidad a cualquier tipo de datos, el uso frente a cualquier tipo de dato que sea suministrado y capacidad de adaptabilidad a nuevos datos ingresados. No obstante, para que su funcionamiento sea correcto a las predicciones resultantes necesita de muchos datos para el ejercicio de aprendizaje de estos modelos, lo cual tiene como obstáculo principal alcanzar esa cantidad de datos necesaria para lograr resultados predictores aptos. Así mismo, y reconociendo que maneja grandes volúmenes de datos para su funcionamiento, requiere de igual manera de costo computacional elevado para soportar los datos suministrados.

Aplicación de Machine Learning en la Agricultura

La agricultura ha sido un proceso que viene desde la antigüedad, en donde la necesidad de pasar de comunidades nómadas a ser una serie de sociedades estáticas se fundamentaba en la producción de los productos alimenticios por sí mismo. Smith (2018) definió la agricultura un el arte y la ciencia de cultivar la tierra para la producción de cultivos, en donde se evalúa todo tipo de factores ambientales, económicos, físicos y químicos.

Claramente, la agricultura es una industria cubierta de enormes tradiciones ancestrales y desarrollos comunitarios que implica el dominio de técnicas de siembra, cultivo y cosecha e influye en el comercio mundial y el desarrollo socioeconómico de las naciones, siendo fundamental para la supervivencia de la población mundial de seres humanos. Además, su influencia en el medio ambiente es fundamental, ya que el hecho de un desequilibrio en el uso de

grandes cantidades de terrenos utilizados para labores agrícolas pueden ser un factor adicional al cambio climático (Brown & Miller, 2020).

Es por esto por lo que, así como se ha comenzado a innovar tecnológicamente en distintos campos como la salud, arquitectura, etc., la agricultura también se ha ido tecnificando gracias a la implementación de tecnologías que se han ido desarrollando durante la industria 4.0. Investigaciones como las de Klein, Smith y Jones (2020) resaltan ese importante impacto que estas tecnologías han tenido en la productividad y eficiencia del sector agrícola, lo que ha contribuido en el equilibrio y subsistencia de la población global y su continuo crecimiento que exige de una fluctuante demanda alimenticia a través del tiempo. Esta situación es la principal causa de innovar y desarrollar prácticas tecnológicas más eficientes y sostenibles, así como, la urgencia de políticas y estrategias que promuevan la accesibilidad y la implementación efectiva de estas tecnologías en diferentes contextos agrícolas a nivel mundial.

Predicción Meteorológica para el Rendimiento de Cultivos

Para nadie es un secreto que el uso de tecnologías de Internet de las Cosas es de las tecnologías de la industria 4.0 que permite capturar, almacenar y analizar datos climatológicos que son clave para predecir el rendimiento de los cultivos. En el estudio de Chanchí-Golondrino. (2022), construye un sistema de inteligencia artificial en conjunto con sensores que monitorea las variables de temperatura, humedad y luz en los cultivos de lechuga. Utilizando estos sensores, se recolectan los datos del comportamiento de estas variables y la forma en que van afectando al vegetal, datos que son almacenados en una base de datos en la cual se aplica un modelo de aprendizaje no supervisado. A través del proceso de predicciones que surgen de este tipo de análisis, se logra identificar esas variables físicas del medio ambiente que afectan el rendimiento de los cultivos, de tal forma que esto permita que los agricultores puedan planificar las

temporadas de siembra y organizar los recursos agrícolas para disminuir la probabilidad de pérdida en los productos sembrados. De este proyecto, se puede resaltar esa importancia que hay en el análisis de estas variables anteriormente mencionadas que permitan automatizar de alguna forma el ejercicio de la siembra en los momentos adecuados para que la productividad tienda a ser la máxima y las pérdidas mínimas.

De igual manera, a través de uso de distintos sensores se ha logrado obtener los datos necesarios que permite realizar los procesos predictivos que contribuyan al rendimiento positivo de los cultivos evaluando también los nutrientes claves que adquiere una planta específicamente. Un ejemplo de esto es Perret. (2020), que a través de un análisis espectroscópico y combinado algoritmos de aprendizaje automático determina cuales son esos nutrientes clave que necesita la planta como el calcio, magnesio, etc., y a la vez ver también las magnitudes adecuadas de cada uno de estos para obtener un producto con alto índice de calidad, lo que es crucial para planificar las estrategias de abono en las plantas que conlleve al mejoramiento del crecimiento de los cultivos. En el caso de este estudio, modelos predictivos como la regresión de mínimos cuadrados parciales demostraron una alta precisión en la predicción de los componentes del suelo a partir de firmas espectrales. Esto facilita la toma de decisiones estudiando los componentes químicos que se encuentran en los suelos y los nutrientes necesarios que deben ser suministrados a partir del abono para que el agricultor determine el espacio adecuado de siembra que permita el equilibrio metabólico de la planta y disminuir el costo de fertilizantes que contengan nutrientes que ya la tierra por si sola puede suministrar.

El estudio anterior puede ser complementado con el que realiza Ceballos (2022), en donde se aplica la técnica de árbol de decisiones para clasificar los suelos que determinará la fertilidad de estos acordes al contenido de nutrientes, como nitrógeno, fósforo, potasio y

magnesio, muy similar al que se realizó por Perret a través del uso de sensores espectroscópico. Este algoritmo predijo el comportamiento de los nutrientes en diferentes muestras de tierra, facilitando así la toma de decisiones sobre los componentes fertilizadores que debía tener estos cultivos. El uso de algoritmos supervisados como estos es clave para identificar áreas que requieren una atención especial, lo que optimiza el uso de recursos y maximiza el rendimiento de los cultivos.

Aportando de igual manera a esta investigación, Alemán y Montes (2019) Realizan un ejercicio similar de revisión de los componentes de la tierra en el occidente del valle central de Costa Rica, en donde evidencian que la fertilidad del suelo es crucial para la productividad y sostenibilidad de los cultivos, y por lo tanto el mapeo digital de suelos puede presentarse como una herramienta valiosa para generar información precisa y actual sobre la variabilidad espacial de los suelos. El autor realiza un ejercicio de mapeo de tres atributos de la fertilidad del suelo, pH, acidez y capacidad de intercambio catiónico efectiva en una zona agrícola del Valle Central Occidental de Costa Rica. Posteriormente, utiliza el modelo scorpan-SSPFe, que incluye variables como el clima, organismos, relieve, material parental, edad y posición espacial. Los datos incluyeron 384 análisis químicos de suelos, un modelo de elevación digital, imágenes satelitales y registros climático, que luego se ajustaron modelos lineales para inferir la variabilidad espacial de los atributos del suelo. Los resultados mostraron que los modelos lineales pueden ser efectivos para predecir la variabilidad espacial de los atributos del suelo, con un desempeño aceptable en términos de error estándar residual y consistencia de la incertidumbre.

Otro estudio que nos permite evidenciar el trabajo realizado en el Machine Learning para la predicción del comportamiento de las distintas variables de los cultivos es el realizado por

García (2019), en donde aplica el modelo supervisado denominado random forest que, según el autor “es una técnica de regresión basada en árboles de decisión, que fue elegida debido a su capacidad para manejar grandes cantidades de datos y múltiples variables”, el uso de este modelo de aprendizaje supervisado permitió al autor realizar un proceso de entrenamiento entre las variables meteorológicas y relacionarlos con las variables del suelo a distintas profundidades, lo cual permitió al autor que su modelo logrará determinar las condiciones del suelo, no solo a través de los factores climáticos y químicos, si no también acorde a los comportamientos a los que tiene durante cada día y hora. La profundidad llevada a cabo por el autor en este documento radica en que el estudio se enfoca en cómo las variables meteorológicas de forma temporizada afectan a los suelos en distintos niveles de profundidad. Por lo cual la complejidad de los datos no puede ser resuelta únicamente por un modelo supervisado si no por el trabajo de un conjunto de estos.

Continuado con la revisión, otra aplicación de automatización machine Learning es la realizada por Lamos (2020), la cual busca observar esos factores que más influyen en la producción y calidad de cultivos de Cacao, esto lo justifica indicando que encontrar la exactitud y comportamiento del cultivo acorde a los factores que influyen en este es esencial para mejorar la productividad y los ingresos de los agricultores. Lamos aplica el método de aprendizaje de Máquinas de Soporte Vectorial (SVM), Random Forest y Gradient Boosting y el modelo de regresión LASSO. Utilizó como modelos predictores las condiciones climáticas, la variedad de cacao, el nivel de fertilización y la exposición al sol. No obstante, de todos los modelos que aplicó, el mejor modelo fue obtenido a través del Gradient Boosting en donde se concluyó que las variabilidades que más influyen en la rendición del cultivo son la radiación, la lluvia y la temperatura.

Por otro lado, un aporte importante que nos realiza Diaz y Galán (2021) al momento de realizar aplicaciones de modelos de aprendizaje automático es la creación de conjuntos de datos con valores verdaderos que permitían evaluar estos modelos, más conocidos como de datasets de ground truth. El desarrollo de este dataset por parte del autor es caracterizado por construirse con datos fenotípicos sin llevar a cabo factor de invasividad para que el desarrollo de algoritmos de inteligencia artificial en la agricultura sea adecuado. Este estudio se centró en el desarrollo de datasets de ground truth utilizando datos fenotípicos de flores de *Antirrhinum majus* para mejorar la precisión, el cual incluía imágenes y datos fenotípicos como longitud, anchura, peso y contenido de antocianinas de 114 flores. Los resultados mostraron que el peso es el mejor parámetro para determinar el estado de desarrollo floral y que a partir de este se pueden crear algoritmos de redes neuronales para un fenotipado automático y no invasivo. El propósito que tuvo el autor a momento del desarrollo del documento es la esencialidad del dataset al momento de aplicar modelos de machine Learning que busquen revisar el comportamiento de las flores, ya que se necesitaría revisar la planta desde su crecimiento natural y no desde la influencia del humano para su crecimiento y desarrollo adecuado.

Siguiendo esta misma línea, Garcia y Artega (2020) observan una gran preocupación dentro de los factores meteorológicos en Sudamérica, lo anterior debido a que las condiciones son muy variables debido al cambio climático de la actualidad y, reconociendo que la agricultura es altamente sensible a estos cambios, necesita de un sistema que contribuya a la adaptabilidad del sistema de producción agrícola a través de predicciones que responda a los cambios climáticos de los años.

Para lograr lo anterior, los autores utilizaron varios modelos de aprendizaje automático para predecir el rendimiento de los cultivos en Argentina, incluyendo redes neuronales

profundas, máquinas de soporte vectorial, random forest y árboles de decisión. Los datos utilizados incluyeron variables climáticas, geográficas y de cultivo. En donde se evidenció que el modelo random forest fue el más efectivo para realizar estas predicciones meteorológicas basado en datos obtenidos a través de sensores y su percepción del entorno a través del tiempo.

Aportando al análisis, Peña y Giraldo (2022) observan que la adopción limitada de tecnologías avanzadas en el sector agroindustrial impide el desarrollo de procesos de alta calidad en el cuidado del aguacate Hass. Para lograr contribuir a solventar esta situación, los autores implementan un dispositivo inteligente basado en 3 tecnologías: IoT (Internet de las cosas), la cual captaba los datos de las variables meteorológica como la humedad, la temperatura, el ph, etc. El Cloud computing, herramienta que permite el acceso a recursos informáticos a través de internet facilitando y disminuyendo considerablemente los recursos de Hardware de un servidor local, usándolo para el alto almacenamiento de datos y finalmente con modelos machine Learning analizaban los datos y tomaban las decisiones. Aunque el documento no especifica exactamente el modelo de machine Learning que utilizaron, el sistema creado por ellos indica sobre esa importancia que hay en el ejercicio de aplicación de varias tecnologías para lograr obtener resultados idóneos (En este caso IoT y Cloud computing), concluyendo en un sistema que aporato en tomar decisiones sobre agua y fertilizantes en el invernadero.

Monitoreo de Plagas y Enfermedades

La necesidad de aplicar modelos de machine Learning en los insumos agregados a los cultivos es un elemento que también se debe tener en cuenta y optimizar por parte del ejercicio de la siembra de los productos agrícolas, así como el análisis de las características de la planta que permiten deducir enfermedades causadas por bacterias, hongos o virus que puedes afectar posteriormente a la población objetivo de consumo. Ramírez (2020) es un ejemplo claro de la

importancia de este equilibrio, buscando ese punto entre el uso de pesticidas que no afecte las características nutritivas del producto, pero que tampoco permita que los insectos afecten a la planta y su fruto. En su ejercicio, aplico modelos predictivos de árboles de decisión y vecinos cercanos a los cultivos buscando como fin determinar los frutos que eran saludables, los que habían sido dañados por la cantidad de pesticidas y aquellos que estaban siendo dañados por factores externos (insectos, hongos, bacterias, etc.). Este estudio es crucial permitiendo determinar los niveles adecuados de químicos que deben ser aplicados a las plantas para que no se llegue a la pérdida del producto enfrentando estos elementos que atentan contra la calidad del producto.

De igual manera, Aguirre (2021) encuentra en las enfermedades de los cultivos un factor en el que se puede aplicar modelos de Machine Learning que logren predecir las fresas que tienen algunas enfermedades comunes, entre las que destaco la Botrytis Cinerea, Leaf Scorch y mildiu Polvoriento. El proceso de entrenamiento realizado por Aguirre fue organizado con modelos de detección basados en redes neuronales como Efficient Det y Single Shot Multibox Detector, complementado con Resnet y Mobil Net. Los modelos lograron predicciones que promediaban en el 88%, logrando avisar la posibilidad de frutas infectadas con las que se lograran tomar medidas correctivas para que no se llegara a una propagación de las enfermedades del cultivo.

Otra investigación que contribuye a las mencionadas anteriormente es la realizada por Vanegas (2023), es donde a partir de imágenes y modelos Machine Learning intenta realizar la identificación de anomalías en las plantas de lulo es fundamental para prevenir la propagación de enfermedades y asegurar la calidad de la producción. Esta necesidad la fundamentaba en esa tediosidad de detectar de forma manual esas anomalías que se caracteriza por una probabilidad

de errores humanos, especialmente en grandes extensiones de cultivo donde el cansancio del agricultor es un factor para tomar malas decisiones en la calidad del producto.

Vanegas utiliza modelos Machine Learning de redes neuronales convolucionales para desarrollar un sistema capaz de detectar las anomalías de plantas de lulo utilizando una base de datos de imágenes etiquetadas como sanas o enfermas. Los resultados mostraron que el sistema es fue efectivo para detectar anomalías con una precisión de hasta el 95%. Anexo a esto, el autor aplico esta herramienta de detección a dispositivos móviles para que los agricultores puedan identificar enfermedades de manera fácil y rápida.

Una de las investigaciones más cercanas en Colombia es la realizada por Santana y Rodríguez (2022), en donde se evidencia que la falta de aplicación de tecnologías en el campo agrícola ha causado una afectación de la productividad continua y de calidad de los cultivos para que respondan a la necesidad de la población de Cundinamarca. En este estudio se investiga la aplicación de tecnologías de deep learning en los cultivos del departamento de Cundinamarca para mejorar la productividad y la gestión ambiental. Lógicamente, el autor implementa tecnologías de deep learning para optimizar la información y el reconocimiento de patrones en los cultivos. Estas tecnologías, aplicadas mediante drones y software especializado, permiten un monitoreo y gestión más precisos de los cultivos. Los resultados mostraron que al hacer uso de redes neuronales en los cultivos ayudan predecir la salud de los cultivos y a tomar decisiones informadas para mejorar la productividad y reducir pérdidas debido a factores climáticos, de aquí lo resaltante es encontrar que el factor climático es influyente en gran medida frente al avance de enfermedades que adquieren los cultivos.

Continuando con el análisis, la investigación Jiménez (2020) nos muestra otra forma de aplicación de machine Learning que no tiene que ver como tal con la enfermedad propia del

cultivo sino con los parásitos vegetales que pueden afectar la calidad de estos. El autor resalta que la infestación de malezas es un factor significativo que reduce el rendimiento de los cultivos y causa pérdidas económicas y que el uso excesivo de herbicidas para acabar esta plaga no solo es costoso, sino que también tiene efectos negativos en el medio ambiente y la salud humana. Para esto, desarrolla un sistema inteligente para la detección de malezas y la aplicación de herbicidas en cultivos de piña utilizando conceptos de agricultura de precisión. El sistema utiliza visión artificial para adquirir imágenes de las plantas y un sistema embebido de cámaras de alta tecnología para procesar estas imágenes en tiempo real y altas velocidades que contribuyó a que se tomaran decisiones de forma inmediata. El prototipo incluye un sistema de fumigación automático implementado en un vehículo terrestre que recorre los surcos del cultivo. Aunque el autor no menciona como tal el algoritmo de detección de malezas que utilizó, se puede deducir que debe estar cercano al uso de redes neuronales por el uso de las imágenes, la cual se pueden traducir como bases de datos no estructurados. Los resultados de esta aplicación de sistemas robóticos y su combinación con algoritmos Machine Learning contribuyo a que se lograra mitigar en un 80% la invasión de la maleza en los cultivos.

Optimización del Riego

Acorde a Chanchí-Golondrino (2022) y su modelo de aprendizaje automático en donde se observa el comportamiento de los datos de los factores físicos del entorno en donde subsiste los cultivos de lechuga, nos entrega esa posibilidad de automatización y optimización del riego junto con sensores que monitorean continuamente la humedad del suelo y la temperatura del ambiente. En la industria 4.0, la automatización es una de las principales herramientas que se pueden aplicar en múltiples campos facilitando el trabajo de la mano del hombre y otorgando una exactitud específica de acciones a llevarse a cabo acorde a parámetros específicos evidenciadas a

través de variables eléctricas. En este caso, la automatización de los cultivos a partir de los modelos predictivos desarrollados permite aplicar la cantidad de agua adecuada y únicamente cuando los cultivos lo necesitan. Los modelos de agrupamiento basados en el análisis de datos de sensores, así mismo, determinar esa exactitud de la cantidad de recurso hídrico que necesita la planta para su correcto crecimiento permite el ahorro de este.

De igual manera, Perret (2022) sostiene la idea que los sensores juegan un papel crucial en la optimización del riego. En este caso, el estudio y posterior evaluación de los componentes químicos del suelo, junto con el nivel de humedad de este, se obtiene información sobre la cantidad de agua y propiedades que este dispone, lo que permite ajustar las estrategias de riego en función de las necesidades del suelo. Al integrar estos datos con sistemas de riego automatizados, se puede optimizar el uso del agua, reduciendo el desperdicio y mejorando la eficiencia del riego.

García (2019), nos aleja un poco de la revisión de los componentes químicos del suelo, y nos entrega un modelo basado en árboles de decisiones que permita entender las variables físicas del suelo para el riego de estos. Es bien sabido que para realizar procesos de riego automatizado lo habitual es realizar el estudio de la humedad de los niveles superiores del suelo pero el autor indica la gran importancia de realizar también un proceso de estudio en niveles inferiores a los superficiales. En su estudio, realiza un estudio predictivo que permite entender el comportamiento de la humedad del suelo, pero desde distintos niveles, permitiendo tomar decisiones acordes a como se va comportando el suelo a niveles de humedad y temperatura, no solo en la parte superior si no en distintos niveles, lo cual permite entender en realidad la necesidad del cuidado y atención a una planta. En otras palabras, el modelo predictivo desarrollado por García, no solamente se enfoca en determinar el comportamiento de niveles de

humedad, si no a la vez cómo se comporta esa humedad en los distintos niveles del suelo para reconocer en qué momento la planta necesita el apoyo del ser humano para su cuidado.

Otro ejemplo de análisis en la aplicación de Machine Learning es el trabajo desarrollado por Tovar (2023), iniciando su investigación con el problema de la gestión eficiente del agua para aumentar el rendimiento de los cultivos y contribuir a la sostenibilidad ambiental. La autora encuentra como problema esencial que escasez de agua y el uso ineficiente del riego son problemas críticos en la agricultura y que han ido solventándose poco a poco a través de las tecnologías de precisión.

Dentro de la documentación encontrada, determina que la tendencia actual en esta versión de la agricultura se implementan sistemas de riego inteligente basados en IoT y aprendizaje automático, entre los que más resalta las redes neuronales y convolucionales, el aprendizaje por refuerzo y algoritmos de Deep Learning, con la meta de optimizar el uso del agua en los riegos de los cultivos. Estos sistemas utilizaron sensores para monitorear la humedad del suelo y las condiciones climáticas, ajustando el riego en tiempo real. Los resultados que evidenció la autora en los documentos mostraron una reducción significativa en el consumo de agua y un aumento en la eficiencia del riego, mejorando así el rendimiento de los cultivos.

Agricultura Inteligente y su Impacto en la Economía y el Medio Ambiente

La aplicación de técnicas de machine Learning en la agricultura busca mejorar la productividad de los distintos tipos de vegetales que se logren sembrar en un espacio determinado y disminuir en gran medida las pérdidas económicas causadas por factores físicos, biológicos y químicos.

Un ejemplo de estos es el estudio que realizó Moreno (2019), que a partir de la utilización de redes neuronales evidenció parámetros clave de los cultivos, como el volumen de

madera en plantaciones forestales. En el estudio realizado se buscaba estimar el volumen de madera en plantaciones de eucalipto en Brasil, utilizando imágenes satelitales combinadas con índices de vegetación y texturas derivadas de las bandas espectrales. Este enfoque permitió una predicción precisa del volumen de madera en grandes áreas donde el monitoreo manual sería costoso y complicado.

Lo anterior tiene varios resultados positivos que contribuyen, inicialmente al medio ambiente, ya que el autor nos indica que al realizar estos estudios que adaptan el crecimiento de los árboles y su ubicación determinada para lograr cumplir la meta de integrar mayor cantidad de árboles en un espacio determinado disminuiría el espacio de deforestación de árboles que se necesitaría para cumplir con la demanda de adquisición de la madera. Así mismo, se mantendría equilibrada la oferta y demanda que requieren la comunidad como muebles, papel, energía, etc.

Por otra parte, documentos científicos nos permite entender la relación que existe en el equilibrio de uso y aplicación de químicos a los productos que los agricultores cultivan. Según la página de noticias DW (2022), “aproximadamente 385 millones de trabajadores agrícolas en todo el mundo sufren de intoxicación por exceso de pesticidas cada año, y alrededor de 11,000 muertes están relacionadas con estos incidentes”. La importancia radica en entender que, aunque es importante la aplicación de pesticidas que protejan un cultivo, es determinante conocer la cantidad exacta de estas para que disminuya considerablemente la afectación en la salud del agricultor, y lógicamente del consumidor. De igual manera, determinar la exactitud de aplicación de productos de un siembro permite ahorrar cantidades de estos productos contribuyendo a la vez a una mejora económica que tienen que realizar los agricultores adquiriendo pesticidas, a la vez que se tiene un cuidado en el medio ambiente, ya que disminuye considerablemente la cantidad de gases que se emiten a la capa de ozono.

Ahora bien, la influencia de las TIC (Tecnologías de la información y la comunicación) dentro del campo agrícola es parte fundamental para el desarrollo que cumpla con la demanda alimentaria y de materia prima en la sociedad. Rambauth (2022) nos indica que esa unión entre las TIC y el Machine Learning es el eje fundamental de la actual agricultura de precisión, la cual conllevaría a la toma de decisiones a partir de la BigData y la IoT aplicados al manejo de pesticidas, fertilizantes y uso adecuado del agua, para la reducción de los costos que actualmente tiene un agricultor en el cuidado de sus cultivos. Así mismo, Al realizarse un proceso de optimización en el uso de los recursos anteriormente mencionados, se contribuye a mitigar los efectos causados por parte del trabajo agrícola en el cambio climático. Finalmente, el autor nos indica que las TIC puede ser el elemento que contribuiría a la reducción de esa brecha tecnológica que se evidencia entre las zonas rurales y las zonas urbanas, pero a la vez menciona que la brecha principal entre esa brecha tecnológica y la agricultura está en los altos costos iniciales que implicaría el estudio de implementación de estas en los cultivos.

Uno de los propósitos de Machine Learning más interesante aplicados a las ciencias agrícolas y que contribuye en gran medida a aumentar la productividad económica, facilidad de la mano de obra y la toma de decisiones por parte de los agricultores sobre la oferta de sus productos, es el realizado por Medina (2021), que, aunque se enfocó únicamente en el Aguacate Hass, abre las puertas a realizar la aplicación de estos modelos en nuevos cultivos. En este trabajo, la autora entrena un modelo de Machine Learning para realizar el conteo de flores y frutos en cultivos de Aguacate Hass, logrando determinar la cantidad de productos que obtendrá el agricultor de su cultivo, y posteriormente tomar las decisiones correctas del cuidado de estos tanto en la oferta y la demanda de la cantidad de productos que se van a obtener. Del documento se destaca la importancia de utiliza algoritmos de detección, en este caso se utiliza el algoritmo

YOLOv5, “el cual es un modelo de detección de objetos basado en redes neuronales convolucionales (CNN), que son técnicas de aprendizaje profundo (deep learning)” (Medina,2021). El algoritmo, caracterizado por la detección de objetos a través de imágenes de baja resolución y con una velocidad adecuada para el proceso que se estaba llevando a cabo, justifica su aplicación por los costos computacionales que se necesitan para lograr un proceso de predicción adecuado, logrando predicciones del 80% en la detección de los aguacates y 39% para la detección de las flores.

De igual manera, muy similar lleva esta actividad de buscar mejor productividad económica dentro de la industria Guallazaca y Hernández (2024), en donde observan que las técnicas coloquiales utilizadas en la producción agrícola ecuatoriana no eran suficientes para alcanzar los estándares de calidad necesarios para satisfacer la demanda del mercado internacional. Para esto, enfocan su trabajo en un sistema capaz de supervisar, identificar y clasificar la calidad de productos agrícolas mediante la aplicación de técnicas de soft computing y el algoritmo de machine Learning de vecinos más cercanos (KNN) para etiquetar los productos según su calidad y enviar los reportes en tiempo real a una aplicación web. El uso de este modelo de aprendizaje, combinado con redes neuronales convolucionales (CNN), fue efectivo para clasificar productos agrícolas en categorías de calidad de 3 tipos: bueno, regular, malo. Situación que contribuye enormemente a la separación de los productos por calidad para su posterior consumo a la población a través de la clasificación correcta de estos por medio de análisis de imágenes.

Otra forma interesante de aplicación de machine Learning fue la realizada por Briceó (2022), en donde observan que la creciente demanda de alimentos debido al aumento de la población mundial requiere que las empresas agrícolas optimicen sus procesos de producción y

contratación de personal. En este caso, en la empresa Fundos Rejas SAC no han logrado establecer la cantidad de personal necesario para los cultivos de aguacate, arándano y mandarina por la variabilidad de la cantidad de producto que puede obtenerse en distintas temporadas del año. De ahí que se hace la aplicación de 3 modelos de aprendizaje dentro de la comprensión de las métricas del negocio para predecir la cantidad de trabajadores que se iban a necesitar para que se lograra obtener los resultados adecuados acorde a la demanda de productos. Los modelos aplicados fueron La regresión lineal múltiple, utilizada para predecir la cantidad de producción de palta; Árboles de decisiones, para obtener la cantidad de producción que se obtiene de mandarina y arándano; y finalmente, soporte de vectores de regresión para obtener la cantidad de trabajadores que había que contratar acorde a los resultados mencionados anteriormente. Al aplicar y verificar los resultados de los modelos aplicados, el autor indica que obtiene de manera efectiva la producción de cultivos y la cantidad de personal necesario, optimizando los recursos y mejorando la planificación operativa.

Finalmente, y de manera complementaría, un trabajo interesante fue realizado por Ipanaque (2022), donde se sale del factor productivo agrícola y se enfoca en el factor económico, en donde entrena y evalúa modelos predictivos para pronosticar la demanda del banano orgánico de Perú utilizando algoritmos de aprendizaje supervisado, específicamente redes neuronales. Esto permitía determinar cuáles son estas tendencias en tiempo y lugar para para determinar la cantidad de banano que se necesitaba en el país y proyectarlo también a las exportaciones.

Estado del Arte

Estamos en un momento tecnológico en el que el machine Learning se ha convertido en la herramienta revolucionaria de la agricultura por la facilidad que ha permitido al momento de realizar los procesos de predicciones del rendimiento de los cultivos agrícolas. Estos modelos, que tienen esa capacidad de procesar grandes volúmenes de datos, provienen de fuentes meteorológicas, historial del comportamiento de los cultivos las prácticas del manejo agrícola (Chávez & Gómez, 2018). Por lo tanto, la facilidad que tienen los modelos de identificar los modelos puede contribuir a estimaciones más precisas que van sustituyendo los métodos tradicionales que han pasado de generación en generación por agricultores que se basan en la estimación del rendimiento de los cultivos, más no en sus comportamiento exacto y científico. De ahí que, al contar con estas estimaciones más precisas sobre el comportamiento del circuito y las variables que influyen en este, los agricultores pueden tener una participación proporcional en el mercado debido a la optimización de los recursos que utilizan y la minimización de los riesgos al momento de tomar decisiones (Martínez & González, 2021).

Investigaciones como la de García, López, y Martínez (2020) han verificado que la eficiencia de los modelos predictivos basado en machine Learning han logrado muchas de estas mejoras significativas en la precisión del rendimiento de los cultivos, ofreciendo ventajas en términos de adquisición de información a los agricultores sobre el estado de sus productos fundamentada en variables físicas sensorizadas que establecen la base para la toma de decisiones sobre las acciones a llevar a cabo para el cuidado de sus cultivos (Smith & Pérez, 2019).

De igual manera, el Machine Learning ha evidenciado ser lo suficientemente contribuyente con la población dedicada a la agricultura para afrontar el problema de plagas y enfermedades que afectan los cultivos, logrando detecciones tempranas y precisas que posibilitan

respuestas inmediatas por parte de ellos para minimizar los daños en las cosechas y disminuir así las pérdidas económicas consecuencias de tomas de decisiones tardías (Gómez et al., 2020).

Investigaciones llevadas a cabo por López, García y Pérez (2019) han llevado a cabo la aplicación de modelos de aprendizaje que, a través de análisis de imágenes de cultivos, logran identificar patrones visuales que a través de los datos son incongruencia a la normalidad del crecimiento normal del fruto o la planta, lo que sugiere la posibilidad de plagas y enfermedades que están afectando posiblemente un cultivo determinado. Además, estos estudios que contribuyen a la detección de las plagas y las enfermedades en los cultivos contribuyen a la selección adecuada de pesticidas y a la cantidad de uso de estas, logrando reducir el uso de productos químicos, llegando así a prácticas agrícolas más sostenibles y que sean respetuosas con el medio ambiente (Martínez & Díaz, 2021).

Lo anteriormente mencionado, puede evidenciarse también en estudios que indican que la aplicación del machine Learning es fundamental para lograr la optimización de recursos vitales para estos como lo son el agua y los fertilizantes. Esta afirmación la respaldas Martínez (2021), donde evidencia cómo algoritmos de Machine Learning logran integrarse a los cultivos para la gestión exacta de los recursos a implementarse en estos. Según Smith y Jones (2020), el uso de modelos predictivos ha permitido ajustar considerablemente las dinámicas que determinan la cantidad de agua que se debe aplicar a un cultivo acorde al tipo de planta, de igual manera la cantidad de fertilizante que se debe suministrar para un crecimiento óptimo de la misma. De ahí que este enfoque, no solo se implica en la gestión precisa de los recursos en un cultivo, sino que también fomenta la sostenibilidad de estos, debido a las problemáticas actuales que se están vivenciado en cuanto a la escasez de agua en múltiples territorios agrícolas a causa del cambio climático del planeta (Brown et al., 2019).

De ahí que es evidente que la aplicación del machine Learning en varias áreas relacionadas con la agricultura latinoamericana se ha ido convirtiendo en la solución por la facilidad que da en el análisis de los suelos, la automatización de las actividades agrícolas que son exhaustivas e imprecisas en ocasiones por los agricultores y por la optimización al momento de conocer la exactitud de los suministros necesarios para estos. Primero que nada, reconociendo que los algoritmos de los modelos de aprendizaje logran analizar grandes volúmenes de datos que pueden proceder de distintas fuentes a través de sensores como lo son imágenes, sensores de humedad, térmicos, etc., permiten que la actividad de la cosecha sea mucho más precisa y eficiente al aplicar los actuadores apropiados que unifiquen a la siembra y el riego de manera exacta para resultados productivos satisfactorios (Smith, 2020). Por lo tanto, al momento de combinar datos históricos del crecimiento de los cultivos, las condiciones meteorológicas en donde crecen y el estado de los suelos, los modelos de machine Learning logran ofrecer esas recomendaciones sobre la exactitud de qué se necesita en los insumos agrícolas para lograr optimizar la calidad de los productos y disminuir el impacto ambiental de la práctica agrícola (García, 2019). Finalmente, mediante ese análisis de datos, también se pueden sumar otras actividades que se han de evaluar en el proceso agrícola como el inventario de productos, los medios necesarios para su transporte y comercialización, etc. Lo anterior a través de modelos que logren determinar las tendencias de producción agrícola, disminuyendo el desperdicio de productos obtenidos y proveer de productos de calidad a los mercados locales y nacionales (López, 2021).

A manera de cierre, la aplicación del machine Learning se ha extendido a múltiples áreas de la agricultura, evidenciando que estamos sujetos a conocer a través de este documento esas posibilidades de aplicación y resultados para contribuir positivamente al crecimiento tecnológico

en cultivos, no como una posibilidad de mejoramiento, sino como una necesidad a la demanda actual de la población.

Análisis de Resultados

En esta sección, se presentan los hallazgos más relevantes obtenidos a partir de la revisión de la literatura sobre la aplicación del Machine Learning en la agricultura latinoamericana. Los resultados se organizan en cuatro áreas clave: predicción meteorológica para el rendimiento de cultivos, monitoreo de plagas y enfermedades, optimización del riego, y el impacto económico y medioambiental. Cada subsección destaca los estudios más significativos y sus contribuciones al campo, proporcionando una visión integral de cómo estas tecnologías están transformando la agricultura en la región.

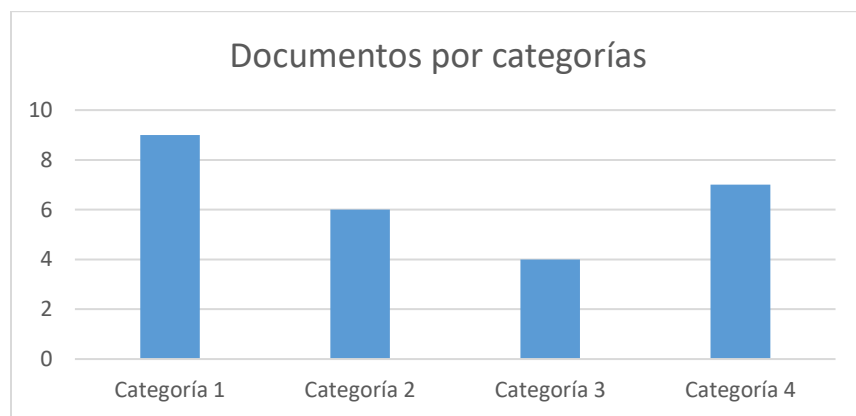
Primero nos enfocaremos en ver cómo es la tendencia de investigación acorde a la clasificación de las 4 áreas mencionadas anteriormente, esto permitirá reconocer cuál es la tendencia de aplicación y estudio de machine Learning en la agricultura. Primero reconoceremos cuales son las categorías en las que se diferenció la información obtenida:

- Categoría 1: Predicción meteorológica para el rendimiento de cultivos.
- Categoría 2: Monitoreo de plagas y enfermedades.
- Categoría 3: Optimización del riego.
- Categoría 4: Impacto económico y ambiental.

El siguiente gráfico nos presenta la cantidad de documentación que apporto información sustancial a las distintas categorías. Es importante resaltar que muchos de los documentos mencionaban a varias categorías y acorde al aporte que estos tenían se incluía o no la información relevante sobre estas.

Figura 4

Resultados de la Clasificación de los Documentos



Nota. La gráfica evidencia los resultados de la clasificación de los documentos en las 4 categorías después de haber leído los documentos.

Observemos que la tendencia de aplicación de Modelos Machine Learning se encuentra en la predicción de variables meteorológicas. Lo anterior es debido a que uno de los factores que claramente se resaltaba es la influencia que tienen estas variables para el nacimiento de la flor y su posterior madurez y crecimiento. Era evidente encontrar el estudio de factores como la temperatura del clima, el nivel de humedad del suelo, el ph de la tierra en donde se cultivaba, etc.

Seguida a esta tendencia, observamos que existen algunos estudios que hacen referencia a la aplicación de Machine Learning influenciando factores económicos y sociales. En esta categoría se resalta que hay distintas investigaciones en donde la aplicación del Machine Learning contribuye en estrategias económicas en donde resaltamos las siguientes:

- El estudio de los tamaños de los suelos para poder aumentar la productividad de cultivos a partir de predicciones de crecimientos por hectáreas.
- Contaminación producto de pesticidas excesivos en los cultivos.

- Contratación de personal acorde a la predicción de cantidad de cultivos.
- Predicción de demanda agrícola en un país.
- Necesitas tecnológicas para mejoramiento sustancial de la agricultura a partir del

ML.

La siguiente categoría es la de predicción de plagas y enfermedades, en donde se aplicaban muchos modelos para cuidar y determinar los parámetros adecuados de cada fruto obtenido determinado su nivel de calidad y salubridad.

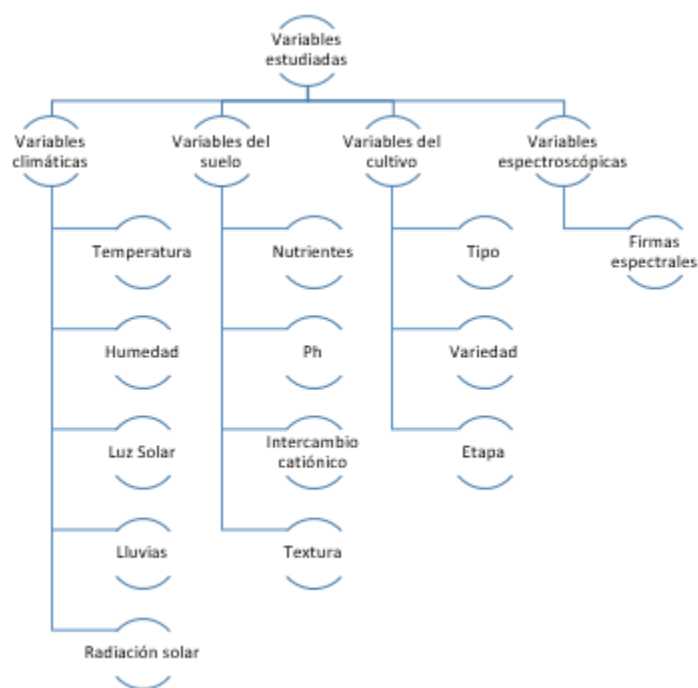
Finalmente, la categoría que menos estudios se evidenció fue aquellas que tenía que ver con la optimización de los riegos, con tan solo 4 documentos. Abriendo posibilidad a verificar cómo la predicción en cultivos facilitaría la labor del agricultor en mano de obra para determinar la cantidad de productos que deben ser agregador para su correcto crecimiento.

Análisis de Resultados de la Categoría 1: Impacto del Machine Learning en la Predicción Meteorológica

En la primera categoría, evidenciamos cuales son las variables que se tuvieron en cuenta para obtener resultados positivos en la predicción de las variables meteorológicas. A continuación, evidenciaremos a través del siguiente diagrama cuáles fueron estas:

Figura 5

Variables Categoría Impacto del Machine Learning en la Predicción Meteorológica



Nota. Variables usadas en los métodos machine Learning de la categoría 1.

El gráfico anterior destaca las cuatro categorías principales de variables que los modelos de Machine Learning emplean para optimizar la predicción y el rendimiento agrícola. Estas variables representan una intersección crucial entre los datos climáticos, las propiedades del suelo, las características del cultivo y los avances tecnológicos en espectroscopía. A continuación, se analizan los puntos clave:

Variables Climáticas

Estas son esenciales, ya que determinan el contexto ambiental en el que se desarrollan los cultivos. Los modelos utilizan estos factores para anticipar rendimientos agrícolas basándose en patrones históricos y predicciones meteorológicas. Su importancia en la agricultura inteligente

radica en que son predictoras directas de estrés hídrico, fenología de cultivos y períodos de crecimiento.

Variables del Suelo

Las propiedades químicas y físicas son indicadores del potencial de fertilidad del suelo. Los modelos que incorporan estas variables permiten personalizar estrategias de manejo agrícola, optimizando la aplicación de fertilizantes y reduciendo costos.

Variables del Cultivo

Incluyen las características propias del cultivo, como el tipo, la variedad y la etapa de desarrollo. Estas variables permiten ajustar las predicciones a las necesidades específicas de cada especie agrícola, mejorando la precisión de los modelos en cultivos de alto valor comercial.

Variables Espectroscópicas

Las firmas espectrales, obtenidas mediante tecnologías avanzadas, complementan las demás categorías al proporcionar datos detallados sobre la salud y el estado de los cultivos. Estas variables son especialmente útiles en la detección temprana de enfermedades o deficiencias.

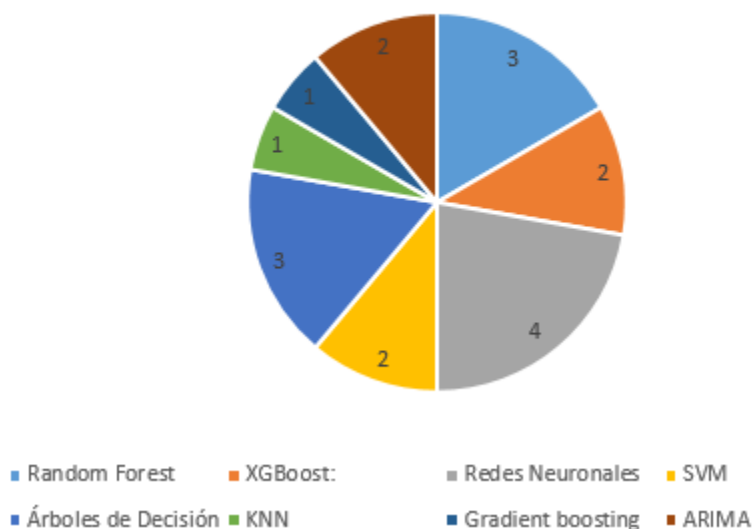
Finalizando el análisis de esta primera categoría, obtuvimos la siguiente tendencia de modelos de aprendizaje aplicados para la predicción de las variables meteorológicas:

Figura 6

Modelos de Aprendizaje Categoría Impacto del Machine Learning en la Predicción

Meteorológica

Modelo evidenciados en la primera categoría



Nota. El gráfico representa los modelos machine Learning utilizados y las veces que se usaron en los documentos de la categoría 1.

Observamos que los modelos basados en árboles y las Redes Neuronales dominan el panorama, probablemente porque ofrecen un equilibrio entre rendimiento, flexibilidad y capacidad de modelar datos complejos. Otros modelos clásicos, como ARIMA, aunque aún relevantes, están perdiendo protagonismo frente a técnicas más avanzadas como LSTM y XGBoost.

Finalmente, podemos observar que métodos más simples como los vecinos cercanos tienen menor presencia, lo que podría indicar que los investigadores prefieren métodos más sofisticados para abordar problemas complejos como la predicción meteorológica.

Monitoreo de Plagas y Enfermedades

En la segunda categoría, evidenciamos cuáles son las variables que se tuvieron en cuenta para obtener resultados positivos en la predicción del monitoreo de plagas y enfermedades. A continuación, evidenciaremos a través de un diagrama cuales fueron estas:

Figura 7

Variables Utilizadas en la Categoría Monitoreo de Plagas y Enfermedades



Nota. En el gráfico se evidencia la variable objetivo que estudiaban los modelos machine Learning en la categoría 2.

De manera más compleja, las variables aplicadas para el análisis de datos y su posterior implementación en modelos se revisan en 4 elementos: La detección de los colores a través de imágenes permitía evidenciar anomalías de los frutos, plantas o flores que a través de estrategias machine Learning determinaba si el crecimiento de esta o este era el adecuado o no era el adecuado. De igual manera, realizando procesos clasificatorios acorde a los distintos estados de las plantas permitían entender el nivel de salubridad de una planta y las razones por las que estaba en dicha situación.


Por otra parte, el estudio de las variables que influían en los pesticidas fue fundamental en estas investigaciones, entender que la cantidad de pesticida o el tipo de pesticida influye considerablemente en el crecimiento de la planta es sustancial y se evidencio en los distintos documentos mencionados anteriormente.

Ahora bien, sobre la tendencia de modelos de machine Learning aplicados en esta categoría obtenemos los siguientes:

Figura 8

Modelos de Aprendizaje Aplicados en la Categoría 2

Modelos evidenciados en la segunda categoría



Nota. El gráfico evidencia los modelos de aprendizaje utilizados por los ingenieros e investigadores en la categoría 2.

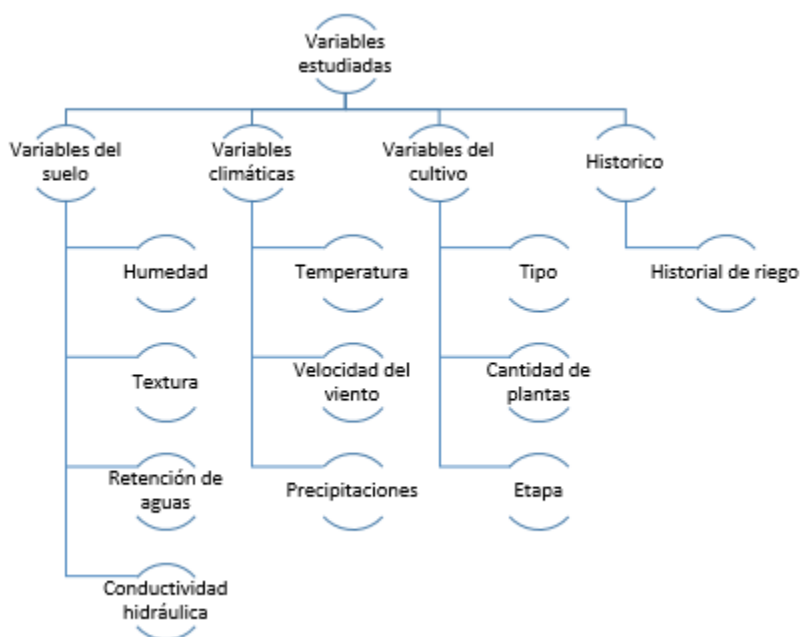
El análisis muestra que, los modelos que hacen referencia las redes neuronales están dominando la tendencia de uso. Esto se debe a su alta capacidad para procesar datos visuales y detectar plagas o enfermedades a través de imágenes de cultivos. Aunque modelos más tradicionales como los Árboles de Decisión y KNN, que se siguen siendo utilizados por su simplicidad y facilidad de implementación.

Optimización del Riego

En la tercera categoría, evidenciamos cuáles son las variables que se tuvieron en cuenta para obtener resultados positivos en la optimización del riego de los cultivos. A continuación, evidenciaremos a través de un diagrama cuáles fueron estas:

Figura 9

Variables que se Estudiaron en la Categoría Optimización del Riego



Nota. El gráfico anterior evidencia cuales fueron esas variables trabajadas por los ingenieros e investigadores en la categoría 3.

Variables del Suelo

La humedad y la textura del suelo son fundamentales para entender la capacidad de retención de agua y la efectividad del riego. La retención de agua y la conductividad hidráulica son factores clave que influyen en la disponibilidad de agua para las plantas. Estos datos son especialmente relevantes en climas áridos o cuando se busca optimizar el uso de agua en regiones donde este recurso es limitado.

Variables Climáticas

La temperatura y la velocidad del viento son factores climáticos que impactan significativamente el consumo de agua por parte de los cultivos. Las precipitaciones también son esenciales para el monitoreo del riego, ya que permiten ajustar la cantidad de agua proporcionada en función de las lluvias ocurridas, evitando el desperdicio.

Variables del Cultivo

El tipo de cultivo y la cantidad de plantas afectan las necesidades hídricas, ya que diferentes cultivos tienen diferentes requerimientos. Además, la etapa de desarrollo de los cultivos también influye en la cantidad de agua necesaria, ya que, durante el crecimiento y la maduración, los cultivos pueden tener diferentes tasas de transpiración.

Histórico

El historial de riego es una variable crucial para ajustar y predecir las futuras necesidades de agua. Analizar cómo ha sido el patrón de riego en el pasado puede ayudar a prever las cantidades adecuadas de agua y hacer ajustes en tiempo real.

Verificando ahora los modelos machine Learning que se utilizaron para lograr esta optimización en el riego, que se usaron los siguientes modelos de aprendizaje:

- Modelos de agrupamiento
- Árboles de decisiones
- Redes neuronales
- Aprendizaje por refuerzo

La posible razón por la que se utilizan estos modelos de aprendizaje automático en la optimización del riego radica en su capacidad para gestionar de manera eficaz los recursos hídricos en un entorno agrícola. Modelos como árboles de decisión, redes neuronales, y

aprendizaje por refuerzo permiten analizar grandes volúmenes de datos obtenidos de sensores en tiempo real sobre factores como la humedad del suelo, temperatura ambiental, y precipitaciones, proporcionando así predicciones precisas y personalizadas para cada cultivo. Estos modelos son particularmente valiosos porque pueden adaptarse a las variaciones dinámicas del entorno, optimizando la cantidad de agua aplicada, reduciendo el desperdicio de recursos y mejorando el rendimiento agrícola.

Impacto Económico y Medioambiental

La aplicación de modelos de aprendizaje en la agricultura ha aportado, no solo desde el momento del cuidado y crecimiento de la planta, sino también en cómo se puede aportar en el crecimiento económico y medioambiental a partir de distintas estrategias y propósito. Acorde a los documentos observados, evidenciamos estos aportes que hacen parte de la agricultura inteligente de la siguiente forma:

Predicción en el Volumen de los Cultivos

Al utilizar modelos de machine Learning que permitan gestionar de manera más eficiente sus plantaciones, se logra una planificación precisa de la cosecha, evitando pérdidas por estimaciones incorrectas y optimizando el tiempo de cosecha, lo que se traduce en mayores ingresos y ahorros en costos operativos.

Además, contribuye a la gestión sostenible de los bosques al optimizar el uso del espacio y la distribución de árboles, ayudando a reducir la deforestación y promoviendo un manejo más responsable de los recursos forestales.

Impacto en el Medio Ambiente

Al evitar el uso excesivo de pesticidas, estos modelos contribuyen a minimizar la contaminación del suelo y los cuerpos de agua cercanos. Esto también disminuye la exposición

de los trabajadores agrícolas a productos tóxicos, promoviendo un entorno más saludable tanto para las personas como para el ecosistema.

Conteos de Productos Obtenidos

Los modelos Machine Learning que permiten esta actividad facilitan la gestión y planificación de la oferta y demanda, optimizando la distribución y evitando pérdidas por exceso o escasez de productos. Además, reduce la dependencia de mano de obra para el conteo manual, disminuyendo los costos laborales.

Planificación de Personal

Al prever la cantidad de personal necesario para diferentes cultivos, los agricultores pueden optimizar la contratación de mano de obra según la producción esperada. Esto reduce los costos de personal no necesario y asegura que se tenga la cantidad adecuada de trabajadores durante los picos de trabajo, mejorando la eficiencia operativa y reduciendo el desperdicio de recursos humanos.

Oferta y Demanda Territorial

El uso de redes neuronales para predecir la demanda de banano permite a los agricultores y empresas ajustar la producción de acuerdo con las tendencias del mercado. Esto evita tanto el exceso de oferta como la falta de productos, mejorando los ingresos y reduciendo las pérdidas por productos no vendidos o descomposición.

A manera de cierre, se observa que los múltiples modelos de Machine Learning aplicados en la agricultura permiten optimizar recursos, aumentar la productividad y reducir costos, promoviendo una agricultura más sostenible. Al mejorar la gestión de cultivos, el uso de recursos naturales y la planificación operativa, se logra un equilibrio entre el rendimiento económico y la protección ambiental, contribuyendo al futuro de la agricultura de precisión.

Conclusiones

Se ha evidenciado que el Machine Learning se puede comenzar a denominar el causante de la “revolución en la agricultura”, esto al ofrecer herramientas capaces de abordar desafíos tradicionales y emergentes en América Latina. Según los distintos autores que hicieron parte de este análisis documentos, abordar los modelos de machine Learning que permitan analizar y procesar grandes volúmenes de datos lleva a mejorar la capacidad de predicción y toma de decisiones en procesos agrícolas, que en ocasiones son limitadas por suposiciones humanas. Mediante diversos enfoques de enseñanza se ha logrado simular acciones elaboradas, mejorar la utilización de materiales y simplificar tareas como la anticipación del clima, la vigilancia de plagas y enfermedades, y la administración del agua. Estos talentos no solo mejoran la eficiencia, sino que también promueven métodos agrícolas más amigables con el entorno y ajustados a las circunstancias ecológicas y financieras locales.

Así mismo, la habilidad del Machine Learning para descifrar esquemas a partir de información y ajustarse a situaciones nuevas lo posiciona como la herramienta clave en países de Latinoamérica para impulsar la agricultura, simplificando el cambio hacia una agricultura detallada que balancea la eficacia en la producción con el cuidado del medio ambiente. De esta forma, se refuerza su importancia como una respuesta a problemas significativos que enfrentamos en la actualidad como el aumento en la necesidad de alimentos y los impactos negativos del cambio climático, reafirmando su relevancia en el ámbito del crecimiento en el marco del desarrollo agrícola sostenible.

El Machine Learning ha demostrado ser un catalizador clave para optimizar procesos agrícolas, mejorando significativamente la eficiencia en el uso de recursos como el agua, fertilizantes y pesticidas. A través de modelos predictivos que se estudiaron y ejecutaron por

parte de los distintos investigadores, se logra predecir rendimientos de cultivos, necesidades hídricas y la aplicación precisa de insumos, esto lleva a que se logre una reducción sustancial de los costos operativos y a la vez contribuya en la lucha del impacto ambiental. Si comenzamos a incentivar e implementar el uso de esta tecnología de la industria 4.0, los principales beneficiados van a ser los agricultores que cambiarían esas prácticas de deducciones acorde a experiencias y posibilidades, convirtiéndose en lecturas científicas y precisas de la información de los cultivos que permitan a la población agrícola tomar decisiones en bases informadas y precisas, logrando una mayor sostenibilidad agrícola, aumento de ganancias en este sector y, por obvias razones, una mayor adquisición de recursos económicos hacia los países que se dedican a esta labor.

La integración del Machine Learning en la agricultura latinoamericana no solo contribuye a incrementar la productividad de los cultivos, sino que también tiene un impacto económico positivo al optimizar la relación entre inversión y retorno. Casos exitosos demuestran que su aplicación permite anticipar factores críticos como la aparición de plagas o enfermedades y el comportamiento de variables climáticas, lo que a su vez reduce pérdidas y asegura un rendimiento más estable. Estas capacidades potencian la competitividad del sector agrícola en la región, ya que estaría funcionando de forma protectora acorde a predicciones futuras comprobadas en bases claras y científicas, impulsando economías locales y favoreciendo al sector agrícola de los países latinoamericanos.

Aunque se observó en el análisis documental que la adopción de tecnologías de Machine Learning en la agricultura contribuye positivamente al cuidado de los cultivos, potenciación de su calidad y organización en la oferta y demanda de forma precisa, aún presenta importantes desafíos relacionados con la brecha tecnológica en áreas rurales, donde el acceso limitado a

infraestructura digital y la falta de formación técnica entre los agricultores dificultan su implementación. Roner (2005) nos indica que el problema de la tecnología en la agricultura es el alto costo que tiene su implementación frente a las pocas ganancias que habitualmente obtiene un agricultor por la venta de sus productos al mercado, y que es habitual ver solamente implementación de estas tecnologías en tierras de personas con recursos económicos alto. Adicionalmente, la resistencia al cambio por parte de agricultores que dependen de métodos tradicionales resalta la necesidad de programas de capacitación y sensibilización que promuevan el entendimiento de los beneficios prácticos y económicos de estas herramientas.

La falta de datos agrícolas estructurados y de calidad es otro obstáculo crítico para la implementación del Machine Learning en la región. Esto limita la capacidad de los modelos para ofrecer predicciones precisas y adaptadas a las condiciones locales. Sin embargo, la creciente disponibilidad de tecnologías como sensores, drones y satélites presenta una oportunidad para cerrar esta brecha. No obstante, nuevamente entramos a la controversia sobre los altos costos que tiene la adquisición de estas tecnologías para poder cumplir los objetivos de implementación de los modelos machine Learning. De ahí que la creación de políticas públicas que incentiven la recopilación y el intercambio de datos agrícolas, así como la inversión en infraestructuras tecnológicas, puede allanar el camino para la adopción masiva de estas soluciones innovadoras.

Recomendaciones de Investigación

Una de las recomendaciones que se proponen a manera de resultado y observación de esta monografía es la posibilidad de aplicar estos modelos de aprendizaje en la creación y monitorización de las huertas humanas, las cuales pueden llegar a contribuir en una era revolucionaria de agricultura desde los entornos ciudadanos proponiendo así ejercicio microempresarial para poblaciones de estos entornos. Esto se propone a través de la evidente baja práctica de esta actividad agrícola que normalmente se genera debido al desconocimiento del cuidado que debe tener los cultivos en momentos específicos y la necesidad constante de atención que solicitan los cultivos para cumplir con objetivos de productividad.

Para incentivar la adopción de estas prácticas en comunidades urbanas es fundamental incentivar en el campo investigativo que promuevan a la creación, mantenimiento y el cuidado de huertas inteligentes que logren facilitar el cuidado de "agricultores urbanos" que contribuya a un crecimiento económico con características microempresariales. De ahí que estas investigaciones deben proveer de capacitaciones rigurosas que contribuyan al aprendizaje para la instalación y operación de estas tecnologías. Lo anterior abre la posibilidad de que, al crear estas huertas inteligentes, grupo familiares logran una autosuficiencia alimentaria y a la vez una mejor educación ambiental.

Uno de los problemas que evidenciaron en los análisis de documentos es la deforestación causada por la expansión de campos agrícolas, de ahí que se recomienda investigar cómo las tecnologías basadas en Machine Learning y análisis geoespacial pueden contribuir a la planificación y optimización del uso de suelos agrícolas sin necesidad de ampliar la frontera agrícola. Las investigaciones que se desarrollen en estos proyectos deben enfocarse en la creación de modelos predictivos que reconozcan zonas de suelo subutilizadas o deterioradas con

posibilidades de ser restauradas y transformadas en tierras productivas. Además, el estudio debería investigar de qué manera la combinación de Machine Learning con tecnologías como drones y sensores IoT puede vigilar continuamente la condición del suelo y los cultivos en tiempo real. Esto podría facilitar la implementación de métodos agrícolas exactos que impulsen la productividad en áreas de cultivo sin la necesidad de ampliarlas. Tal idea podría representar un avance fundamental para conciliar la demanda de comida con la conservación de los bosques, fomentando una agricultura sostenible y respetuosa con el entorno natural.

Referencias Bibliográficas

- Aguirre, D. (2021). *Detección de enfermedades de la fresa en agricultura de precisión*.
<http://hdl.handle.net/10654/40519>
- Aldana Rodríguez, Y. (2021). *Pinus pinea: un reto para la agricultura de precisión*. *Indagare*, (9). <https://doi.org/10.35707/indagare/909>
- Alemán, B., Búcaro, A., Henríquez, C., Largaespada, K. (2019). *Mapeo Digital de Suelos Agrícolas en la Región Occidental del Valle Central de Costa Rica*. *Agronomía Costarricense*, 43(2). <https://doi.org/10.15517/rac.v43i2.38205>
- Almeyda, E. (2022). *Pronóstico de la demanda internacional del banano orgánico de Perú usando algoritmos de Machine Learning*. Universidad de Piura. Facultad de Ingeniería. Piura, Perú. <https://repositorioslatinoamericanos.uchile.cl/handle/2250/6504792>
- Alpaydin, E. (2020). *Introduction to machine learning*. MIT Press.
https://books.google.com.co/books?id=uZnSDwAAQBAJ&pg=PA1&source=gbs_toc_r&cad=1#v=onepage&q&f=false
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
<http://users.isr.ist.utl.pt/~wurmd/Livros/school/Bishop%20-%20Pattern%20Recognition%20And%20Machine%20Learning%20-%20Springer%20%202006.pdf>
- Brown, A., Green, B., White, C. (2019). *Machine learning applications for sustainable agriculture*. *Journal of Agricultural and Environmental Sciences*, 7(2), 45-58.
<https://www.ajol.info/index.php/jaes>

- Brown, R., & Miller, E. (2020). *Agricultura sostenible: desafíos y perspectivas*. Revista Internacional de Agricultura Sostenible, 12(2), 45-58.
<https://www.andi.com.co/Uploads/AgriculturaSostenible%20MAD.pdf>
- Bustamante, M., García, María. (2021). *Implementación de Modelos Machine Learning aplicados al Estudio de Enfermedades del Theobroma cacao para huertas agroecológicas del Cantón la Maná, Provincia de Cotopaxi*. UTC. La Maná. 125 p.
<https://catalogo.utc.edu.ec/cgi-bin/koha/opac-detail.pl?biblionumber=17215>
- Carrillo, G., López, S., Govaerts, B. (2020). *Strategies for sustainable intensification of maize-based cropping systems in Latin America*. Agronomy, 10(7), 997.
<https://www.mdpi.com/2073-4395/10/7/997>
- Castillo, F., Giraldo, M. (2022). *Fortalecimiento del proceso de la siembra y cuidado de la planta del aguacate hass en los invernaderos a través de la implementación de un dispositivo inteligente basado en las tecnologías internet de las cosas – IoT, cloud computing y machine learning*. EIEI ACOFI.
<https://acofipapers.org/index.php/eiei/article/view/2625>
- Castro, A., López, J., & Pérez, M. (2020). *Aplicaciones de inteligencia artificial en la agricultura: un enfoque hacia la eficiencia y sostenibilidad*. Revista de Agricultura Sostenible, 15(2), 45-63. https://issuu.com/danmont2004/docs/revista_agroinfo
- Castro, C., Carrillo, I. (2022). *Agricultura de precisión aplicada en el departamento de Cundinamarca con el uso de tecnologías Deep Learning*. EIEI ACOFI.
<https://acofipapers.org/index.php/eiei/article/view/2642>

- Chanchí, G., Gabriel, E., Ospina, A., Manuel, A., Saba, M. (2022). *Sistema IoT para el monitoreo de variables climatológicas en cultivos de agricultura urbana*. Revista científica, (44), 257-271. Epub July 08, 2022. <https://doi.org/10.14483/23448350.18470>
- Díaz, J. (2021). *Aprendizaje automático y aprendizaje profundo*. *Ingeniare*. Revista chilena de ingeniería, 29(2), 180-181. <https://www.scielo.cl/pdf/ingeniare/v29n2/0718-3305-ingeniare-29-02-180.pdf>
- Díaz, M., Navarro, P., Egea, M. (2022). *Desarrollo de ground truth dataset con análisis de datos fenotípicos y su aplicación en agricultura e investigación*. En: Proceedings of the 10th Workshop on Agri-Food Research for Young Researchers. WIA.2021. Cartagena: Universidad Politécnica de Cartagena, 2022, pp. 95-97. ISBN: 978-84-17853-47-1. <https://repositorio.upct.es/handle/10317/10765>
- FAO. (2019). *El estado mundial de la agricultura y la alimentación 2019. Nuestras acciones son nuestro futuro*. Organización de las Naciones Unidas para la Alimentación y la Agricultura. <https://doi.org/10.4060/ca6030es>
- Forcén, M., Pavón, N., López, J. (2021). *Diseño y desarrollo de técnicas basadas en ordenador para ayudar en la investigación agronómica y en la agricultura de precisión*. En Proceedings of the 9th Workshop on Agri-Food Research for Young Researchers. WIA.2020. Cartagena: Universidad Politécnica de Cartagena, 65-68. ISBN: 978-84-17853-29-7
- García, D., González, E., Rodríguez, F. (2021). *Impacto de la adopción de tecnologías de Machine Learning en la agricultura: Eficiencia y sostenibilidad*. Revista de Desarrollo Rural, 18(2), 56-71. <https://ruralager.org/espanol-ager-18-2015/>

- García, H. (2019). *Implementación de técnicas de machine learning para la predicción de variables meteorológicas y del suelo que afectan la agricultura*. Universidad de los Andes. <https://repositorio.uniandes.edu.co/entities/publication/ee3248e9-57a5-4fbb-a92a-57617962babf>
- García, J., Pérez, R., Martínez, M. (2019). *Aplicación de técnicas de aprendizaje automático en el análisis de suelos agrícolas*. Revista Latinoamericana de Ciencias del Suelo, 15(2), 123-135. http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2218-36202022000500029
- García, J., Zambrano, J., Alcivar, R., Zambrano, W. (2020). *Predicción del rendimiento de cultivos agrícolas usando aprendizaje automático*. Revista Arbitrada Interdisciplinaria Koinonía, 5, 144. <https://dialnet.unirioja.es/descarga/articulo/7672167.pdf>
- García, R., López, S., Martínez, E. (2020). *Aplicaciones del Machine Learning en la gestión agrícola: Una revisión de la literatura*. Journal of Agricultural Technology, 8(3), 112-125. https://www.researchgate.net/publication/356441811_APLICACION_DEL_MACHINE_LEARNING_EN_AGRICULTURA_DE_PRECISION_APPLICATION_OF_MACHINE_LEARNING_IN_PRECISION_AGRICULTURE
- García, R., Martínez, E. (2021). *Identificación de nichos de mercado en la agricultura mediante Machine Learning: Estudio de caso en una comunidad rural de América Latina*. Journal of Rural Development, 7(1), 89-102. https://repositorio.cepal.org/bitstream/handle/11362/45111/1/CEPAL-FAO2019-2020_es.pdf

Goodfellow, I., Bengio, Y., Courville, A. (2016). Deep Learning. *MIT Press*.

<https://mitpress.mit.edu/books/deep-learning>

Guailazaca, C., Hernandez, V. (2020). *Clasificador de Productos Agrícolas para Control de Calidad basado en Machine Learning e Industria 4.0: Array*. *Perspectivas*, 2(2), 21–28.

http://perspectivas.esPOCH.edu.ec/index.php/RCP_ESPOCH/article/view/80

Jiménez, A., Camargo, D., García, D. (2020). *Sistema inteligente para el manejo de malezas en el cultivo de piña con conceptos de agricultura de precisión*. *Ciencia y Agricultura*,

17(3). <https://dialnet.unirioja.es/servlet/articulo?codigo=7595664>

Klein, A. (2020). *Trends and drivers of agricultural productivity in Africa*. *Nature*

Communications, 11(1), 1-11. <https://www.nature.com/articles/s41467-020-18893-1>

Lamos, H., Puentes, D., Zarate-Caicedo, D. (2020). *Comparison Between Machine Learning Models for Yield Forecast in Cocoa Crops in Santander, Colombia*. *Revista Facultad De Ingeniería*,

29(54), e10853. <https://doi.org/10.19053/01211129.v29.n54.2020.10853>

Laureano, J., Mejía, M., Cárdenas, E., Flores, M., Gómez, C. (2019). *Técnica del árbol:*

aprendizajes en su utilización para problematizar necesidades de transformación social, Jalisco, México. *Hacia la Promoción de la Salud*, 24(1), 70-83.

<https://doi.org/10.17151/hpsal.2019.24.1.7>

López, A., Ramírez, E., González, F. (2021). *Optimización de la cadena de suministro de*

alimentos mediante el uso de algoritmos de machine learning. *Revista de Tecnología Agrícola*, 18(1), 45-56.

<https://repository.agrosavia.co/discover?scope=%2F&query=machine+learning&submit=>

López, D., Martínez, E., Rodríguez, F. (2019). *Detección temprana de plagas y enfermedades en cultivos utilizando algoritmos de aprendizaje automático*. *Agricultura Sostenible en*

América Latina, 10(3), 78-89.

http://sedici.unlp.edu.ar/bitstream/handle/10915/118496/Documento_completo.pdf?sequence=1&isAllowed=y

López, M., Hernández, J., & Fernández, G. (2018). *Aplicación de modelos de Machine Learning en la optimización de procesos agrícolas: Casos de éxito y recomendaciones*. Journal of Agricultural Innovation, 5(1), 23-38.

<https://revistas.pascualbravo.edu.co/index.php/cintex/article/download/356/327>

Lu, Y. (2017). *Big Data Analytics in Agriculture*. In *Data Analytics in Digital Humanities* (pp. 269-290). Springer, Cham. <https://link.springer.com/book/10.1007/978-3-319-54499-1>

Magrin, G. (2015). *Adaptación al cambio climático en América Latina y el Caribe*.

<https://www.cepal.org/es/publicaciones/39842-adaptacion-al-cambio-climatico-america-latina-caribe>

Medina, D. (2021). *Conteo de flores y frutos para el monitoreo del cultivo de aguacate Hass por medio de imágenes utilizando Machine Learning*. Universidad de los Andes.

https://redcol.minciencias.gov.co/Record/UNIANDES2_640f6eb01fa3b79f1a0d3bbfd7a30251

Mercado, R., García, W., Herrera, J. (2016). *Sistema de inteligencia artificial para la predicción temprana de heladas meteorológicas*. Acta Nova, 7(4), 483-495.

http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S1683-07892016000200007&lng=es&tlng=es

Moreno, A., Argemiro, J., Moreira, T., Bento, M., Averna, V., Robería, O., Bernardi, L.,

Louriegos, S., Thiersch, C. (2019). *Espacialidad volumétrica de madera en plantaciones*

- forestales usando redes neurales artificiales con imágenes de satélite. Acta Agronómica*, 68(2), 142-150. <https://doi.org/10.15446/acag.v68n2.78945>
- Moriasi, D., Gitau, M., Pai, N., Daggupati, P. (2019). *Big data analytics for predictive modeling in agriculture: A review. In Big Data Analytics in Intelligent Transportation Systems* (pp. 73-102). Springer, Cham. https://doi.org/10.1007/978-3-030-10844-2_5
- Murphy, K. (2012). *Machine Learning: A Probabilistic Perspective. MIT Press.*
<https://mitpress.mit.edu/books/machine-learning>
- Perret, J., Villalobos, L., Abdalla, B., Fuentes, F., Carol, L., Cuarezma, E., Katherine, M., Macas, A., Esteban, N., López, M., María, T., Drewry, D. (2020). *Desarrollo de métodos de análisis de espectroscopia y algoritmos de aprendizaje automático para la evaluación de algunas propiedades del suelo en Costa Rica. Agronomía Costarricense*, 44(2), 139-154.
<https://dx.doi.org/10.15517/rac.v44i2.43108>
- Ponte, D., Espinosa, A., Gibeaux, S., González, C. (2021). *Estado actual del aprendizaje automatizado aplicado al Internet de las cosas para automatizar procesos agrícolas.*
<https://revistas.unachi.ac.pa/index.php/pluseconomia/article/view/497>
- Rambauth, G. (2022). *Agricultura de Precisión: La integración de las TIC en la producción Agrícola. Computer and Electronic Sciences: Theory and Applications*, 3(1), 34–38.
<https://doi.org/10.17981/cesta.03.01.2022.04>
- Ramírez, C. (2020). *Aplicación del Machine Learning en agricultura de precisión. Revista CINTEX*, 25(2), 14–27. <https://doi.org/10.33131/24222208.356>
- Rönner, L. (2005). *La incorporación de nuevas tecnologías y algunos de sus componentes problemáticos en el modelo agrícola argentino del siglo XXI. Theomai.*
<https://www.redalyc.org/pdf/124/12420824006.pdf>

- Rubio, C. (2023). Identificación de anomalías mediante el uso del Machine Learning en imágenes de plantas de lulo. *EIEI ACOFI*, sep.
<https://acofipapers.org/index.php/eiei/article/view/3372>
- Ruíz, L. A., Jara-Rojas, R., Aguilar-Rivera, N. (2018). *Machine Learning Techniques for Precision Agriculture in Latin America*. In *Advances in Computer Vision* (pp. 115-125). Springer, Cham. <https://link.springer.com/search?new-search=true&query=Machine+Learning+Techniques+for+Precision+Agriculture+in+Latin+America>
- Russell, S., Norvig, P. (2022). *Artificial Intelligence: A Modern Approach*. Pearson.
https://people.engr.tamu.edu/guni/csce421/files/AI_Russell_Norvig.pdf
- Salas, P. (2022). *Técnicas de Machine Learning para determinar la producción de cultivos y personal requerido en las campañas de cosecha de la empresa Fundos Rejas SAC*. Repositorio Institucional Universidad ESAN. <https://hdl.handle.net/20.500.12640/3237>
- Smith, D., Pérez, L. (2019). *Perspectivas tecnológicas para la agricultura de precisión en América Latina: El papel del machine Learning*. *Revista Latinoamericana de Innovación Tecnológica*, 10(3), 24-39. <https://portal.issn.org/resource/ISSN/2395-972X>
- Tovar, D. (2023). *Agricultura 4.0: uso de tecnologías de precisión y aplicación para pequeños productores*. *Informador Técnico*, 87(2), 195–211.
<https://doi.org/10.23850/22565035.5536>
- Vite, C., Harry, C., Unda, S. (2020). *Aplicación de algoritmos de aprendizaje automático para clasificar la fertilidad de un suelo bananero*. *Conrado*, 16(72), 15-19. Epub 01 de febrero de 2020. Recuperado en 01 de abril de 2024, de

http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1990-86442020000100015&lng=es&tlng=es