



**CENTRO DE INVESTIGACIÓN
EN QUÍMICA APLICADA**

Aprendiendo de las plantas desde la estadística clásica a la inteligencia artificial

Autores:
Francisco Marcelo Lara Viveros
Marco Antonio Castillo Campohermoso
Nadia Landero Valenzuela

**PRIMERA EDICIÓN
2025**



Aprendiendo de las plantas

Desde la estadística clásica a la inteligencia artificial



Francisco Marcelo Lara Viveros

Marco Antonio Castillo Campohermoso

Nadia Landero Valenzuela

PRIMERA EDICIÓN

2025

La agronomía en tiempos modernos: Como aprendimos de las plantas y caímos en la trampa de los grandes números.

Una serie de planteamientos acerca de los métodos que se usan en la agronomía; cuyo principal objetivo es ofrecer respuestas ante los cambios tecnológicos que se presentan, pero sobre todo pretende dejar preguntas en la mente del lector que permitan la construcción de un futuro mejor.

**El aspecto más triste de la sociedad actual es que la ciencia
acumula conocimientos más rápido de lo que la sociedad
acumula sabiduría**

Isaac Asimov

Prologo a la primera edición

El desarrollo de la humanidad siempre ha estado marcado por la evolución de sus herramientas. Desde la invención de la rueda hasta la de hoy en día que es la revolución digital, cada avance ha redefinido nuestra relación con el mundo. Hoy, nos encontramos en una nueva era; la era de la Inteligencia Artificial (IA), una tecnología que no solo está transformando la manera en que trabajamos y producimos, sino también la forma en que comprendemos la realidad.

Este libro busca divulgar y abordar de manera coloquial y amena el impacto de la IA en el análisis de datos dentro del campo agronómico, comparándolo con el método tradicional de la estadística clásica. La transición entre estos enfoques no es solo una evolución técnica, sino un cambio de paradigma que nos invita a repensar cómo interactuamos con la información y cómo optimizamos la toma de decisiones en la agricultura.

Lejos de ser una moda pasajera, la IA ha llegado para quedarse. No se detendrá en su desarrollo, y su implementación en la agronomía es ya una imperiosa necesidad para mejorar la interpretación de datos con un nivel de interconexión y profundidad sin precedentes. La posibilidad de analizar simultáneamente múltiples variables interrelacionadas permite a los investigadores y agricultores obtener conclusiones más rápidas, precisas y acertadas. En definitiva, la IA no solo está redefiniendo la forma en que producimos alimentos, sino también nuestra percepción sobre el papel del ser humano en un mundo donde las máquinas ya no son meras herramientas, sino podrían ser “socios estratégicos” en la búsqueda del conocimiento.

La idea de este libro nació de numerosas conversaciones entre mis queridos amigos y colegas, Dra. Nadia Landeros Valenzuela,

reconocida fitopatóloga, especialista en el manejo de microorganismos benéficos para la agricultura, contribuyendo al desarrollo de estrategias sustentables para el manejo de cultivos; Dr. Marco Antonio Castillo Campohermoso, agrónomo con experiencia en agricultura orgánica y cultivos agroindustriales del semidesierto mexicano, ha trabajado en el análisis de sistemas de producción con enfoques innovadores, y un servidor Dr. Francisco Marcelo Lara Viveros agrónomo especialista en fisiología vegetal, ha dedicado los últimos años de su trayectoria a la aplicación de inteligencia artificial en la interpretación de datos agronómicos. A lo largo de nuestras charlas, discutimos cómo la IA está revolucionando la investigación agronómica, transformando el análisis de datos y redefiniendo la metodología de los experimentos agrícolas.

La estadística clásica ha sido una piedra angular en la investigación agronómica durante décadas y sin ella no sabríamos lo que sabemos hoy en día sobre todo en el ámbito agrícola y producción de alimentos. Sin embargo, el volumen y la complejidad de los datos generados en la actualidad exigen otro tipo de herramientas más sofisticadas. La IA ofrece la posibilidad de modelar fenómenos con una profundidad sin precedentes, permitiendo no solo describir tendencias, sino también predecir comportamientos con alta precisión.

Este libro surge como un esfuerzo por compartir nuestras ideas con un público amplio, desde investigadores y estudiantes hasta productores y entusiastas de la agricultura. Nuestro objetivo es explicar, de manera clara y accesible, el papel que desempeña la IA en la interpretación de datos agrícolas y su potencial para transformar la manera en que cultivamos y entendemos la tierra.

Mirar hacia el futuro de la agricultura implica adoptar un nuevo enfoque en la gestión de datos. El uso de la IA en el análisis de información agronómica no es una opción, sino una necesidad imperiosa para mejorar la eficiencia, la sostenibilidad y la productividad.

Hoy en día, los agrónomos, científicos y agricultores se enfrentan a desafíos que requieren respuestas rápidas y precisas. La IA permite integrar y analizar grandes volúmenes de información incluso para generar modelos predictivos que facilitan la toma de decisiones informadas. Esto no solo optimiza los procesos de producción, sino que también impulsa un conocimiento más profundo de los ecosistemas agrícolas.

El impacto de esta tecnología no solo se limita al sector académico-agrícola. Su implementación redefine cómo comprendemos la relación entre la tecnología y la vida, ampliando los límites de la ciencia y la filosofía. Este libro es una invitación a reflexionar sobre cómo la inteligencia artificial está dando forma a una nueva era del conocimiento.

El presente libro cuenta con el respaldo y experiencia de los investigadores en cuestión mencionados anteriormente expertos comprometidos con la divulgación del conocimiento científico en un lenguaje accesible y atractivo para todos los lectores.

Recalcar que este libro es el resultado de nuestra pasión por la ciencia y el deseo de compartir con la comunidad agrícola y académica y público en general interesado en una visión renovada sobre el futuro de la investigación agronómica. Con un estilo ameno y accesible, queremos invitar a los lectores a descubrir el fascinante mundo de la

inteligencia artificial y su impacto en la agricultura, desde sus fundamentos hasta sus aplicaciones más innovadoras.

Les damos la bienvenida a este recorrido por el pasado, presente y futuro del análisis de datos, donde la IA no es solo una herramienta, sino una revolución en marcha.

Nadia Landeros Valenzuela.

Marco Antonio Castillo Campohermoso.

Francisco Marcelo Lara viveros.

No sé cómo puedo parecer al mundo; pero, en cuanto a mí, me parece que he sido sólo como un niño jugando en la orilla del mar, y divirtiéndome de vez en cuando al encontrar un guijarro más liso o una concha más bonita de lo normal, mientras que el gran océano de la verdad yacía todo descubierto ante mí.

Isaac Newton

Capítulo I

Las plantas y el hombre

Comenzamos a sembrar y la vida cambio.

El descubrimiento de la agricultura hace más de 10,000 años marcó un punto de inflexión en la historia de la humanidad, provocando cambios profundos no solo en las estructuras sociales, sino también en el medio ambiente. La agricultura permitió alimentar a un número creciente de personas, lo que derivó en un incremento sustancial de la población. Por primera vez, las pequeñas comunidades de cazadores y recolectores pudieron transformarse en vastos imperios con una población cada vez mayor.

En este contexto surgieron algunas de las civilizaciones más emblemáticas del planeta. Los alimentos cultivados en diferentes regiones comenzaron a desempeñar un papel fundamental en la configuración de estas sociedades. Por ejemplo, en los Andes peruanos, la domesticación de la papa sentó las bases del imperio Inca; en Mesoamérica, el maíz se convirtió en el eje de numerosas culturas, como los aztecas y los mayas; y en Asia, el arroz fue crucial para el desarrollo del imperio chino. Cada sistema agrícola representaba no solo una fuente de alimento, sino también un pilar cultural y económico.

Intercambio de cultivos

- A raíz de la llegada de los europeos a América, el maíz y la papa se introdujeron en Europa y Asia.
- En el siglo XVIII, se introdujeron otras especies del Viejo Mundo a la granja americana.
- Esto origina una transformación gastronómica y agrícola a escala global.

Maíz en Mesoamérica

El maíz silvestre teocintle, genético por la selección su ancestro, empieza a mostrar modificaciones genéticas por la selección proceso debió iniciarse siglos antes.



Expansión

Oriente Próximo, Asia, países del sur de Europa y del norte de África muestran evidencia arqueológica de comunidades agrícolas.



Arroz en china

En el valle del río Yangtsé (China) surgieron evidencias de cultivo selectivo de arroz.



Descubrimiento

La agricultura se descubrió en lo que hoy son los estados de Irak, Siria, Turquía, Irán, Líbano, Siria, Jordania y Egipto.



Papa en los andes

En la región andina (Perú y Bolivia principalmente), comenzaron a encontrarse evidencias de la selección y siembra de papa.



Agricultura 4.0

Se incorporan tecnologías digitales a los sistemas agrícolas.




Figura 1. Evolución de la agricultura desde su descubrimiento hace aproximadamente 10000 años, hasta la actualidad.

El progreso agrícola fue posible gracias a que, hace unos 10,000 años, los seres humanos comenzaron a comprender los principios básicos del crecimiento de las plantas. Descubrieron que sembrando una semilla podían obtener una planta que les proporcionaría más semillas y alimentos. A lo largo de miles de años, este conocimiento fue perfeccionado mediante la observación constante y un proceso continuo de prueba y error. Esta sabiduría empírica, transmitida de generación en generación, permitió a la humanidad diseñar herramientas y tecnologías para aumentar la producción de alimentos. Hasta el día de hoy, los sistemas agrícolas constituyen prácticamente la única fuente de alimentos para la población mundial.

¿Como aprendimos lo que sabemos de las plantas?

Esos seres tan extraños, las plantas

Aunque estamos familiarizados con las plantas desde una edad temprana, un breve análisis nos lleva a reconocer que son organismos profundamente diferentes de nosotros. Son seres que literalmente "comen luz", utilizando principalmente las longitudes de onda roja y azul. Absorben agua a través de sus raíces y obtienen del suelo elementos químicos que transforman en una inmensa variedad de compuestos orgánicos. Por si fuera poco, las plantas constituyen la base de toda la cadena trófica en nuestro planeta.

Su diversidad es asombrosa, ocupando casi todos los nichos ecológicos posibles en la Tierra. Comprenderlas y apreciar su papel en nuestro entorno ha llevado miles de años, y aún hoy científicos en todo el mundo continúan trabajando para llenar los vacíos en nuestro conocimiento.

El conocimiento empírico sobre las plantas fue esencial para el surgimiento de grandes civilizaciones, al proporcionar la base para prácticas agrícolas exitosas. Sin embargo, durante los siglos XVII y XVIII, se produjo un cambio trascendental en nuestra forma de aprender de las plantas. Por primera vez, las observaciones cualitativas comenzaron a complementarse con mediciones matemáticas precisas, marcando el inicio de una era científica en nuestra relación con el mundo vegetal.

Este nuevo enfoque permitió registrar sistemáticamente eventos fisiológicos clave, como la absorción de agua, la transpiración y el crecimiento. Comenzaron a responderse, de forma cuantitativa, preguntas básicas como:

- ¿Cuánta agua necesita una planta?
- ¿Cuánto tiempo tarda una especie en desarrollar flores y frutos?
- ¿Cuánto alimento puede producirse en una determinada superficie de terreno?

Estas respuestas no solo proporcionaron números comparables entre diferentes especies y condiciones, sino que también permitieron sentar las bases para estudios sistemáticos. Este cambio permitió codificar y almacenar conocimientos de forma que pudieran ser reutilizados y enriquecidos, fomentando una comprensión cada vez más profunda de los fenómenos que rigen la vida vegetal.

Por ejemplo:

- La medición de la cantidad de agua necesaria para un cultivo permitió optimizar los sistemas de riego.

- La observación del tiempo de floración y fructificación ayudó a planificar las cosechas en función del clima y las estaciones.
- Los cálculos sobre rendimientos agrícolas guiaron la selección de las especies más productivas en diferentes entornos.

Gracias a esta integración entre observación empírica y cuantificación matemática, la humanidad dio un gran paso, en la comprensión de seres tan increíblemente diferentes a nosotros, y que al mismo tiempo proporcionan alimentos y muchos otros productos sin los cuales nuestra supervivencia estaría seriamente comprometida.

Las Plantas y la Estadística

Imaginemos por un momento estar frente a un vasto campo lleno de plantas. Ahora, supongamos que decidimos medir una sola planta y, con base en esa única medida, extrapolar su información para describir el crecimiento de todas las demás. Suena arriesgado, ¿verdad? Pero este escenario no es tan diferente de lo que enfrentamos al estudiar sistemas agrícolas, donde miles o millones de individuos crecen en enormes extensiones de terreno.

La realidad es que cada planta es única, incluso si son de la misma especie y crecieron en condiciones similares. La variación es inevitable. Dos plantas vecinas pueden diferir en altura, desarrollo o rendimiento debido a pequeños factores, como diferencias en la composición del suelo, el acceso a la luz o la disponibilidad de agua. Ahora imaginemos la complejidad cuando hablamos de cientos o miles de plantas: lo que sucede en una pequeña parcela no siempre se refleja en el resto del campo.

Por ejemplo, considera un cultivo de 100 plantas de maíz. Aunque genéticamente sean casi idénticas, 10 de ellas podrían estar creciendo en una zona donde la inclinación del terreno acumula agua, mientras que el resto no tiene acceso a este recurso extra. Si solo medimos una planta al azar y resulta que elegimos una de las que está en la "zona húmeda", podríamos concluir erróneamente que todo el campo crece bajo condiciones ideales. Este sesgo, se ve amplificado por la variación natural entre individuos, lo que puede llevar a generalizaciones incorrectas.

Este dilema no es nuevo. En el siglo XVII, un científico belga llamado Jan Baptista van Helmont realizó un experimento que buscaba entender de dónde obtienen las plantas su biomasa. Plantó un brote de sauce, que pesaba 2.26 kg, en una maceta con 90.71 kg de tierra seca. Durante cinco años, solo agregó agua al brote. Al final del experimento, el árbol había crecido y ganado 74.38 kg de peso, mientras que el suelo había perdido apenas unos gramos. Van Helmont concluyó que las plantas crecían exclusivamente gracias al agua, pues el peso del suelo prácticamente no había cambiado.

Aunque su razonamiento fue innovador para su tiempo, sabemos hoy que estaba equivocado. El crecimiento de las plantas no depende solo del agua. La mayor parte de su biomasa proviene del carbono fijado durante la fotosíntesis, un proceso que utiliza dióxido de carbono del aire. Además, las plantas extraen del suelo nutrientes esenciales que transforman en compuestos orgánicos. Van Helmont ignoró estos factores, atribuyendo la mínima pérdida de peso del suelo a un error de medición.

Sin embargo, más allá de sus conclusiones erróneas, el experimento de Van Helmont marcó un hito en la historia de la ciencia. Introdujo

un enfoque cuantitativo en el estudio de la vida vegetal, utilizando un método controlado para llegar a sus resultados. Fue un primer paso hacia la comprensión científica de las plantas.

El gran aprendizaje aquí no solo es sobre las plantas, sino sobre la importancia de la estadística y el diseño experimental. Una medida aislada, aunque precisa, rara vez es suficiente para describir un fenómeno complejo. La variación y el contexto son claves para entender sistemas tan dinámicos como los agrícolas. Este es el legado que dejó Van Helmont: un recordatorio de que la ciencia avanza tanto por los aciertos como por los errores.

Frente a la complejidad de estudiar grandes poblaciones de plantas, surgió la necesidad de desarrollar métodos numéricos que permitieran manejar un número representativo de individuos. Estos métodos debían reducir el error causado por la variación natural que inevitablemente aparece cuando trabajamos con datos extensos y diversos. La solución a este problema llegó sorprendentemente tarde, apenas en el siglo pasado de la mano de Ronald A. Fisher. Antes de contar la siguiente parte de la historia pensemos en esto: la agricultura tiene una historia de más de 10,000 años, siendo la piedra angular de las sociedades humanas, tanto económica como socialmente. Durante milenios, acumulamos conocimiento sobre las plantas a través de la observación y la práctica, logrando un control notable de los cultivos. Pero la verdad es que, durante la mayor parte de ese tiempo, nuestro entendimiento estuvo plagado de errores metodológicos. A menudo, nuestras conclusiones dependían más de corazonadas que de datos precisos.

Lo sorprendente no es que nos equivocáramos, sino que lográramos tanto con tan poco. Esta afirmación no pretende menospreciar los

métodos tradicionales que nos permitieron progresar, sino destacar un punto clave: hasta hace relativamente poco tiempo, no teníamos herramientas estructuradas para estudiar científicamente el crecimiento y desarrollo de las plantas. El conocimiento era, en su mayoría, empírico.

Si el lector me lo permite, volvamos a nuestra historia. En la década de 1920, Sir Ronald A. Fisher transformó la manera en que entendemos la agricultura, llevando los campos de cultivo al siguiente nivel. Desde la histórica *Rothamsted Experimental Station* en Inglaterra, Fisher no se limitó a observar las parcelas agrícolas; las convirtió en auténticos laboratorios estadísticos. Allí introdujo conceptos que hoy consideramos fundamentales pero que en su época rompieron paradigmas: la aleatorización y la replicación.

Fisher enfrentó un desafío que sigue vigente: cómo eliminar los sesgos que surgen de la variabilidad natural entre plantas o del terreno donde crecen. Su solución fue tan simple como elegante. Imaginemos nuevamente el ejemplo de las 100 plantas de maíz, de las cuales 10 crecen en una zona especialmente húmeda que les otorga una ventaja. Sin un diseño adecuado, podríamos seleccionar estas plantas de manera no representativa y concluir erróneamente que todas las plantas crecerán igual. Fisher propuso seleccionar al azar las plantas a medir, asegurando que cada una tuviera la misma probabilidad de ser elegida. Este simple paso reduce significativamente la probabilidad de obtener resultados sesgados.

Pero Fisher fue más allá. Reconoció que el error en nuestras observaciones no solo proviene del sesgo proveniente del medio ambiente, sino también de la varianza inherente de la población. Volvamos a nuestras 100 plantas: si provienen de líneas genéticas muy

diferentes, sus características serán altamente variables, y medir solo dos plantas probablemente producirá un error elevado (una varianza alta). En contraste, si las plantas son genéticamente similares, las medidas entre individuos serán más consistentes y el error será mucho menor (una varianza baja).

Para manejar esta variabilidad, Fisher propuso una solución brillante: incrementar el número de mediciones. Desde el punto de vista técnico el error que puede tener una medida cualquiera de un grupo de plantas está determinado por:

$$Error = \frac{\sigma}{\sqrt{n}}$$

σ = Desviación estándar de las observaciones

n = Número de replicas

De acuerdo con esta fórmula si aumentamos el número de replicas entonces el error disminuye por que el denominador se hace más grande y sabemos que entre más grande el denominador más pequeño el resultado.

Cuantas más observaciones hagamos, menor será el impacto de la variabilidad en nuestras conclusiones. Y si estas observaciones se aleatorizan, logramos minimizar tanto el sesgo medioambiental, como el error asociado a la varianza. En resumen, Fisher no solo nos enseñó a medir mejor, sino a pensar científicamente sobre cómo obtenemos y analizamos los datos.

Antes de Fisher, los experimentos agrícolas solían basarse más en la intuición que en la metodología. Él cambió eso al desarrollar

herramientas estadísticas como el Análisis de Varianza (ANOVA), un método que permitió a los científicos descomponer los datos y comprender cómo factores como el tipo de fertilizante, el riego o las condiciones del suelo influían en los rendimientos de los cultivos. Su enfoque transformó la agricultura en una ciencia basada en datos, donde cada decisión podía respaldarse con evidencia cuantitativa.

Imagina un campo dividido en parcelas aleatorias, donde cada área recibe un tratamiento diferente: fertilizantes, riegos controlados o técnicas de siembra variadas. Fisher demostró que, al aplicar un diseño experimental bien estructurado, era posible separar el "ruido" de la variabilidad natural y obtener conclusiones confiables. Gracias a sus aportaciones, los agricultores ya no tenían que adivinar cuál práctica daba los mejores resultados: podían medirlo.

El té de la Señora Muriel.

Cuando se diseña un experimento, se suelen construir dos hipótesis contrarias para probar supuestos sobre un conjunto de datos. A estas hipótesis se les llama “hipótesis nula” e “hipótesis alternativa”. Si quisiéramos probar estadísticamente que una variedad de maíz es mejor que otra las hipótesis serían;

“La variedad A, es Mejor que la variedad B” – Hipótesis alternativa-

“La variedad A es igual que la variedad B” –Hipótesis nula—

Fisher desarrollo todo un conjunto de procedimientos matemáticos para poder determinar cuál de las dos afirmaciones es la errónea. El enfoque de construir dos afirmaciones contarías entre sí, con la finalidad de comprobar una y refutar otra, fue propuesto en una Obra de Fisher publicada en 1935, llamada “*The design of experiments*” y se utiliza hasta nuestros días en los diseños de experimentos no solamente agrícolas sino de muchas otras disciplinas científicas.

Pero -- ¿Qué relación tiene esto con una taza de té y quien es Muriel? –

La bióloga Muriel Bristol, trabajó en la estación experimental de Rothamsted desde 1919 y era especialista en algas. Ella concentró sus estudios en la forma en que estos organismos adquieren sus nutrientes. Estando en la estación experimental, Fisher ofrece a su amiga una taza de té, que rechaza después de beber un pequeño sorbo. Muriel era capaz de reconocer el sabor del té cuando este había sido preparado de una forma específica. Si el té era puesto en la taza antes que la leche, entonces adquiriría un sabor que de acuerdo con la bióloga Muriel era desagradable.

Ante la incredulidad de semejante habilidad, Fisher piensa que se trata de una broma. Junto con ellos se encuentra el bioquímico William Roach, que además era esposo de Muriel y propone un experimento para demostrar que la bióloga, efectivamente es capaz de distinguir el sabor entre tazas de Té, en donde la leche y el té fueron servidos en diferente orden. Se preparan ocho tazas de té, cuatro de cada tipo (leche antes de té o viceversa) y se colocan de forma aleatoria. Ante el asombro de todos, Muriel distingue con mucha precisión el orden en el que se sirvió la leche en cada taza. Fisher admite la aplastante victoria de Muriel e inspirado en esto, desarrolló el método que calcula la probabilidad de que Muriel hubiera acertado por casualidad. Este método se conoce como la prueba exacta de Fisher y tiene como objetivo calcular la probabilidad exacta de observar una distribución, como la de los datos, bajo el supuesto que la hipótesis nula sea verdadera. Este método se sigue utilizando hoy día y su contribución a la generación y validación de conocimiento en la agricultura es invaluable. La bióloga Muriel, nunca tuvo la intención de generar un nuevo procedimiento matemático en el cerebro de Fisher y menos como consecuencia del orden en el que se prepara el té. Por otro lado, Fisher jamás se imaginó que la hora del té que compartió con sus compañeros de trabajo, sería suficiente para revolucionar la experimentación agrícola. La interacción con otras personas es lo que hace de la ciencia un tejido vivo y cada hilo de conocimiento, por más pequeño o aislado que parezca, puede entrelazarse con otros para formar patrones más grandes e inesperados.

Fisher no solo cambió la agricultura; cambió la ciencia. Su trabajo dio origen a la estadística experimental moderna, marcando un antes y un después en cómo se diseñan experimentos en todas las disciplinas. Lo que comenzó en los campos de Rothamsted impactó en la biología, la medicina y hasta las ciencias sociales. Fue un recordatorio poderoso de que, incluso en algo tan antiguo como cultivar la tierra, la innovación puede florecer cuando la curiosidad y el rigor científico se unen.

El Efecto Mariposa de la Ciencia: Cómo una Idea Cambia Todo

Uno de los aspectos más fascinantes de la ciencia es su capacidad para sorprendernos con conexiones que nunca imaginamos. Lo que comienza como una curiosidad en un área específica puede desencadenar descubrimientos transformadores en otra, a menudo de formas que parecen sacadas de una novela de ciencia ficción.

Imaginemos esto: un biólogo estudiando cómo crecen las plantas podría estar, sin saberlo, sentando las bases para algoritmos que más tarde se usarán en inteligencia artificial. O un físico investigando partículas subatómicas podría desarrollar una tecnología que revolucione la medicina. La ciencia es un tejido vivo, donde cada hilo de conocimiento, por más pequeño o aislado que parezca, puede entrelazarse con otros para formar patrones más grandes e inesperados.

Esta imprevisibilidad es lo que hace a la ciencia tan emocionante. Nunca sabemos cómo una idea aparentemente insignificante puede transformarse en una herramienta poderosa en un campo completamente diferente. Es el motivo por el cual cada pregunta que exploramos importa, porque el impacto de la curiosidad humana no tiene fronteras. La historia está llena de ejemplos: desde las

matemáticas puras que dieron lugar a internet, hasta la observación de bacterias que llevó al desarrollo de la edición genética.

El verdadero poder de la ciencia no radica solo en sus respuestas, sino en las infinitas conexiones que crea. Con cada descubrimiento, ampliamos un poco más ese mapa complejo e impredecible, recordándonos que el conocimiento, como la vida misma, siempre encuentra formas sorprendentes de florecer.

De la intuición a la precisión: El enfoque estadístico en la agricultura

Desde Fisher, el enfoque basado en la estadística para estudiar el crecimiento de las plantas no solo ha prevalecido, sino que ha evolucionado hasta convertirse en una herramienta fundamental para la agricultura moderna. Incluso hoy en día, un gran número de publicaciones científicas se basan en estos métodos para generar conocimiento que sigue transformando la manera en que cultivamos y alimentamos al mundo. En muchas ocasiones, fallas en los métodos matemáticos utilizados para el análisis estadístico de los datos, deriva en condenar al olvido absoluto, trabajos de investigación relacionados con la agricultura.

En diversos rincones del planeta, los llamados "paquetes tecnológicos" agrícolas —conjuntos de prácticas optimizadas para los cultivos— han sido diseñados con base en este enfoque. Como resultado, miles de millones de personas se benefician indirectamente de las "recetas" surgidas de los métodos estadísticos clásicos.

Pero ¿cómo funciona esta conexión entre las matemáticas y las plantas? Si queremos entender y optimizar su comportamiento, primero necesitamos tomar medidas suficientes de forma aleatoria

para garantizar que los resultados sean representativos. Por ejemplo, si queremos determinar la frecuencia ideal para regar un cultivo, o la cantidad óptima de fertilizante para maximizar la cosecha, necesitamos diseñar experimentos que nos permitan explorar esas relaciones. Esto implica tomar un número adecuado de plantas, aplicarles diferentes cantidades de agua o fertilizante, medir los resultados de forma sistemática y aleatoria, y analizar los datos con herramientas matemáticas apropiadas.

El análisis estadístico no solo nos permite encontrar patrones en los datos, sino también establecer conexiones claras entre las variables evaluadas (como la cantidad de agua o fertilizante) y las variables respuesta (como el rendimiento del cultivo). Estas conexiones son las que han permitido a la humanidad transformar la agricultura en una ciencia precisa, alimentando a poblaciones crecientes con una eficiencia que habría sido inimaginable hace siglos.

Durante miles de años, aprendimos de las plantas a través de la intuición y la experiencia empírica, confiando en lo que podíamos observar directamente. Sin embargo, a partir de la propuesta de Fisher, hemos llevado este aprendizaje a un nivel completamente nuevo: ahora entendemos a las plantas mediante datos precisos, recopilados y analizados con herramientas matemáticas que nos proporcionan una visión más objetiva de sus secretos.

Un principio fundamental en este enfoque es que, si un fenómeno se repite un número suficiente de veces en muchos individuos bajo las mismas condiciones, podemos concluir con alta probabilidad que estamos observando algo real, una regularidad. Por ejemplo, si un tratamiento de fertilizante mejora el rendimiento en 95 de cada 100

parcelas en condiciones similares, podemos afirmar que este efecto es consistente, aunque no sepamos aún por qué ocurre.

Sin embargo, aquí hay un detalle fascinante: el análisis matemático y estadístico nos dice qué ocurre, pero no necesariamente por qué ocurre. La estadística solo confirma patrones y regularidades, pero no establece causalidad. Para llegar a esa comprensión más profunda, es necesario dar un paso adicional: el razonamiento crítico, la reflexión cuidadosa no solo de nuestros datos, sino también de los datos de otras personas. Cada dato es como una pieza de un rompecabezas, y el desafío está en ensamblar esas piezas correctamente para revelar la imagen completa.

“x” contra “y”. La eterna batalla sin final, ni ganador.

En las ciencias agrícolas (y en muchas otras disciplinas también) se le conoce como variable independiente a aquel factor que ocasiona una respuesta sobre otra variable que se llama dependiente. La variable independiente se suele representar por una convención no escrita con la letra “x” mientras que la variable dependiente se suele representar con una letra “y”.

Regresemos a nuestro viejo confiable ejemplo de las 100 plantas de maíz. La cantidad de agua que se le aplica a las plantas podría ser nuestra “x” y el rendimiento podría ser nuestra “y”. Hoy en día sabemos que las plantas demandan una gran cantidad de agua para los fenómenos de transpiración y para su metabolismo, así que tenemos claro que la cantidad de agua que le aplicamos a una población de plantas ocasionará una respuesta en el rendimiento y obtendremos una mayor cosecha, claro, como todo sistema biológico, este fenómeno tendría un límite, no podemos agregar una cantidad infinita de agua y

esperar una cantidad infinita de granos de maíz. Si pusiéramos esa idea en un simple dibujo, se vería más o menos así.




Figura 2. Relación entre dos variables, una dependiente en el eje “y” y otra independiente en el eje “x”.

Si descartamos los valores numéricos, podremos observar fácilmente una tendencia clara. Por cada unidad de incremento en “x” la variable “y” también se incrementa, esta tendencia continua hasta que $x=50$; entonces la pendiente de la línea cambia y podemos asegurar que aun agregando más agua a las plantas el rendimiento no se incrementará.

En realidad, la tradición de representar a estas variables con estas letras se remonta a los trabajos de Rene Descartes quien introdujo el sistema de coordenadas cartesianas. Este sistema se ha utilizado ampliamente para visualizar de forma gráfica y humanamente comprensible la relación entre dos variables. En muchas instituciones es común poner gráficos como este para evaluar en los candidatos a realizar estudios de postgrado, su capacidad para encontrar relaciones

entre variables. Cualquier científico del mundo es capaz de formular hipótesis completas a partir de graficas simples como la que presentamos.

En una ocasión, mientras discutía con un colega sobre un experimento en el que utilicé una gráfica para mostrar un fenómeno relacionado con el crecimiento de las plantas, mi colega (cuyo campo de estudio no estaba relacionado con las ciencias biológicas) comentó con ironía: *“Solo a los agrónomos se les ocurre explicar un fenómeno tan complejo como el crecimiento de una planta con tres rayas”*. Las "tres rayas" a las que se refería eran los ejes “x” (la variable independiente), “y” (la variable respuesta), y la línea que representaba la relación entre ambas. Las risas fueron inevitables, pero su comentario contenía una verdad profunda que merece la siguiente reflexión.

Hoy sabemos que el crecimiento y desarrollo de una planta es un fenómeno extraordinariamente complejo y dinámico. Este proceso está influenciado por una red intrincada de variables, muchas de las cuales también son dinámicas y pueden interactuar de formas impredecibles. Por ejemplo, nuestras 100 plantas de maíz no solo crecerán en función de la cantidad de agua que reciban, sino también en respuesta a la cantidad y calidad de luz, las características físicas y químicas del suelo, el clima y hasta factores históricos, como las condiciones en las que crecieron sus progenitores y los genes que heredaron. Cada una de estas variables, a su vez, interactúa con otras, creando un sistema donde un cambio en un factor puede alterar profundamente el comportamiento de los demás.

Para un científico del siglo pasado (y para muchos aún hoy), abordar esta complejidad era una pesadilla metodológica. La estadística clásica ofrecía herramientas como la aleatorización y la replicación

para controlar el error en experimentos diseñados cuidadosamente, pero solo permitía estudiar unas pocas variables a la vez. Por ejemplo, en un experimento de campo con un número suficiente de plantas y regímenes de riego, se podía medir de forma aleatoria el efecto del agua sobre el rendimiento del cultivo, y así obtener conclusiones válidas. Sin embargo, incluir otras variables, como la temperatura, complica enormemente el diseño experimental. Para ello, sería necesario un experimento aún más grande, con más observaciones, y el análisis debería considerar también la interacción entre las variables: ahora sabemos que un incremento en la temperatura aumenta el consumo de agua, lo que modifica el efecto de ambos factores sobre el rendimiento.

Diseñar experimentos que consideren y midan la interacción de múltiples factores es, en la práctica, un desafío económico y logístico considerable para casi cualquier presupuesto científico. Aunque contamos con la capacidad computacional necesaria para procesar grandes volúmenes de datos, la obtención de estos sigue siendo un proceso costoso y complejo. Si tuviéramos los recursos humanos, materiales y logísticos suficientes para realizar un experimento de tal magnitud —sometiendo un número adecuado de plantas a diferentes combinaciones de condiciones—, es probable que las conclusiones obtenidas fueran válidas únicamente en la región específica donde se realizó el estudio. Incluso así, quedarían fuera muchos otros factores igualmente importantes.

A pesar de estas limitaciones, durante los últimos dos o tres siglos hemos aprovechado este enfoque para generar conocimiento valioso sobre las plantas. Muchas de las tecnologías agrícolas que usamos hoy, como los paquetes tecnológicos, se han desarrollado mediante la recopilación de datos provenientes de diversas fuentes. Los

científicos, con paciencia y rigor, han integrado estas observaciones en un conjunto de conclusiones que, aunque requieren ajustes para contextos específicos, han permitido optimizar la producción agrícola.

El impacto de este enfoque es innegable: hasta ahora, hemos logrado producir alimentos suficientes para una población humana en constante crecimiento. De hecho, el ritmo actual de incremento poblacional sería insostenible si la oferta de alimentos no alcanzara para satisfacer las necesidades globales. Si bien el sistema agrícola mundial enfrenta retos, la capacidad de generar conocimiento útil a partir de experimentos cuidadosamente diseñados ha sido clave para sostener la estabilidad alimentaria y, con ello, el desarrollo de las sociedades.

El enfoque de múltiples observaciones y aleatorización de estas, unidas a la capacidad humana para analizar y aprender de los seres humanos, hizo posible que actualmente tengamos una basta comprensión acerca del funcionamiento de las plantas. De hecho, cualquier estudiante de agronomía en el mundo, cuando egresa de la universidad, está ampliamente formado en el uso de técnicas estadísticas avanzadas. Muchos libros sobre agronomía, botánica o fisiología vegetal son en realidad resúmenes de una gran cantidad de estudios sobre plantas con enfoque estadístico.

Esta manera de aprender acerca de las plantas tiene un problema asociado, que tiene implicaciones prácticas muy importantes y que es momento de poner sobre la mesa de discusión.

Cuando enfrentamos unas pocas "x" contra una "y", logramos avanzar en nuestro entendimiento sobre las plantas. Con análisis cuidadoso y razonamiento crítico, hemos desentrañado algunos de sus misterios, a

pesar de que las plantas son seres profundamente distintos a nosotros. Sin embargo, este enfoque tiene sus límites: predecir con exactitud el comportamiento de un grupo de plantas bajo condiciones específicas y únicas sigue siendo un desafío monumental.

A diferencia de un mecánico, que puede anticipar con precisión cómo responderá una máquina a ciertas condiciones, los ingenieros agrónomos no podemos jactarnos de tal exactitud. Los sistemas agrícolas son organismos vivos y complejos, llenos de interacciones dinámicas entre factores que parecen multiplicarse interminablemente. En el campo, cada día surgen nuevas "x" que demandan ser medidas y comprendidas, y nuevas "y" que anhelamos predecir con mayor claridad.

Es una batalla interminable, donde la relación entre causa y efecto se difumina ante la influencia de variables imprevistas. No hay un punto final ni un ganador absoluto, solo un progreso constante. Y aunque la lucha entre "X" y "Y" nunca parece terminar, es precisamente esta incertidumbre la que impulsa nuestra curiosidad y nos desafía a seguir explorando lo desconocido.

En esta batalla entre variables, nunca hay un ganador absoluto. Los científicos avanzamos en nuestra comprensión del mundo vegetal, pero seguimos lejos de ser capaces de simular con precisión fenómenos complejos que involucran múltiples variables dinámicas. En un sistema agrícola, un profesional puede predecir el rendimiento de un cultivo con relativa precisión, pero este logro no se debe a un control total de las interacciones naturales, sino a un esfuerzo constante por reducir la incertidumbre.

En realidad, gran parte del éxito en la agricultura moderna radica en mantener las condiciones del sistema lo más homogéneas posible.

Esto implica dedicar una enorme cantidad de recursos y energía para controlar variables clave, como el riego, los nutrientes del suelo, la exposición a la luz y la temperatura. Al limitar las sorpresas y minimizar la variabilidad, aseguramos una predictibilidad aceptable en las variables respuesta, como el rendimiento o la calidad del cultivo. Este enfoque ha sido uno de los pilares que nos ha permitido alimentar a una población global en constante crecimiento y mantener el hambre en gran medida bajo control.


El esfuerzo por mantener las variables lo más homogéneas posible en los sistemas agrícolas ha llevado, inevitablemente, a una búsqueda de plantas igualmente homogéneas. Se privilegian cultivos que crecen y producen de manera uniforme bajo condiciones controladas, lo que ha generado una disminución significativa en la diversidad genética de las especies cultivadas. Este enfoque, aunque práctico y eficiente en el corto plazo, va en dirección opuesta al camino que la evolución ha seguido durante millones de años, un proceso que tiende hacia una mayor diversidad como respuesta a las presiones ambientales.

La naturaleza es intrínsecamente diversa. Esa diversidad es lo que permite a las especies adaptarse y sobrevivir frente a cambios en el entorno, enfermedades o plagas. Sin embargo, al seleccionar plantas que se comportan de manera uniforme, estamos limitando la variabilidad genética que podría ser crucial para enfrentar desafíos futuros, como los efectos del cambio climático o el surgimiento de nuevas plagas resistentes.


El contraste es evidente: mientras la evolución promueve una mayor diversidad como mecanismo de resiliencia, nuestros sistemas agrícolas buscan minimizarla en aras de la predictibilidad y la eficiencia. Este enfoque plantea un dilema: ¿cómo equilibrar la

necesidad de cultivos homogéneos para alimentar a una población creciente, con la importancia de preservar la diversidad genética que asegura la sostenibilidad a largo plazo?

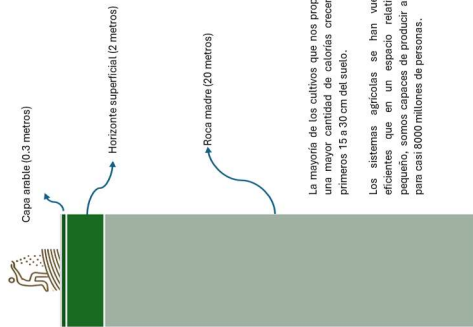
Uso del suelo



La superficie del planeta es de un poco más de 130 millones de kilómetros cuadrados. Aproximadamente el 19% de esa superficie está cubierta con vegetación natural (Bosques o selvas). El resto (22% aproximadamente), se utiliza como tierras del cultivo.



La mayor parte de la superficie agrícola cultivada es utilizada para la alimentación animal, de los cuales se obtiene carne o productos derivados como lácteos. La superficie dedicada a cultivos que se consumen directamente por los humanos es en realidad un porcentaje mínimo del total cultivado.



La mayoría de los cultivos que nos proporcionan una mayor cantidad de calorías crecen en los primeros 15 a 30 cm del suelo.

Los sistemas agrícolas se han vuelto tan eficientes que en un espacio relativamente pequeño, somos capaces de producir alimentos para casi 8000 millones de personas.

Figura 3. Usos del suelo para fines agrícolas en el mundo. Con datos de la FAO

Capitulo II

Con naranjas y manzanas

Estrenando tecnología

El conocimiento sobre inteligencia artificial es sorprendentemente reciente si lo comparamos con la historia de la humanidad. La agricultura, una práctica que transformó nuestra forma de vida, comenzó hace unos 10,000 años, mientras que los primeros intentos teóricos de desarrollar inteligencia artificial surgieron hace menos de 100 años, a mediados del siglo pasado. Esto significa que el 99% del tiempo hemos vivido sin siquiera imaginar la existencia de la IA.

Para hacerlo aún más interesante, las primeras aplicaciones significativas de la inteligencia artificial en la agricultura aparecieron apenas hacia finales del siglo XX, es decir, hace menos de 50 años. Esto nos lleva a una conclusión fascinante: el uso de la inteligencia artificial en la agricultura no solo es reciente, sino que representa una de las transformaciones tecnológicas más modernas en toda la historia de nuestra especie. Estamos viviendo el inicio de una revolución que está cambiando cómo producimos los alimentos que sustentan nuestras vidas.

Los sistemas de inteligencia artificial son el resultado del cruce de dos corrientes: la informática y la de las matemáticas. A mediados del siglo pasado el matemático Alan Turing se planteó una pregunta provocadora ¿Pueden las maquinas pensar? En realidad, el pensamiento humano es un fenómeno único que abarca varios aspectos. La capacidad de aplicar reglas generales a casos particulares, encontrar patrones a partir de datos específicos y, por si fuera poco, la conceptualización de ideas y objetos que no están presentes.

En sus inicios, los avances en inteligencia artificial fueron puramente teóricos, ya que construir una máquina capaz de realizar estas tareas

era técnicamente imposible con la tecnología de la época. Sin embargo, los primeros algoritmos que sentaron las bases de la IA, diseñados para resolver problemas básicos, han perdurado hasta nuestros días y siguen siendo utilizados con ligeras modificaciones, demostrando la solidez de los principios que dieron origen a esta disciplina.

Estamos ante un momento histórico que invita a reconsiderar el funcionamiento de humanidad con la coexistencia de entidades no humanas que poseen autonomía e "inteligencia" el cual plantea un debate crucial; ¿Cómo queda parado el ser humano, se tiene alguna responsabilidad, en un mundo donde las máquinas no solo emulan, sino que en algunos casos superan nuestras capacidades? Este cuestionamiento no se limita a la filosofía, sino que está afectando nuestras estructuras sociales, éticas y económicas.

En agricultura, por ejemplo, los sistemas autónomos actualmente pueden tomar decisiones informadas basadas en datos, reduciendo cada día más la necesidad de intervención humana directa. ¿Esto no solo redefine nuestra relación con el trabajo, sino también nuestra percepción de control y propósito? La dependencia de estas tecnologías podría llevarnos a un punto en el que nuestra identidad como seres creadores, capaces de transformar y dominar nuestro entorno, se vea alterada.

En este contexto, surge la necesidad de reconocer el valor de estas tecnologías sin perder de vista lo que nos define como humanos. Por ejemplo ¿Es nuestra humanidad algo intrínseco e inmutable, o está sujeta a transformaciones en función de nuestras interacciones con la tecnología? Estas son preguntas que deben guiar no solo el desarrollo de la IA, sino también su integración ética en nuestra sociedad.

En definitiva, el uso de la IA, especialmente en sectores críticos como la agricultura, no solo está cambiando cómo producimos alimentos, sino que también desafía las bases de nuestra existencia, invitándonos a reestructurar nuestra visión del ser humano y su lugar en un mundo donde las máquinas ya no son simples herramientas, sino potenciales coprotagonistas.

Manchas y rayas

El matemático Alan Turing es conocido por sus aportaciones en el campo de la computación en particular por la "prueba de Turing" que intenta determinar si una máquina es capaz de pensar. Sin embargo son menos conocidos sus aportes en el campo de la biología. En 1956, Alan Turing publica un artículo denominado "La Base Química de la Morfogénesis", en donde plantea cómo las sustancias químicas (o cualquier tipo de "cantidad") se distribuyen en el espacio y evolucionan con el tiempo debido a dos procesos fundamentales:

1. Reacción: Describe las interacciones químicas o biológicas entre las sustancias.


2. Difusión: Describe cómo las sustancias se dispersan en el espacio, siguiendo un gradiente de concentración.

Este modelo es utilizado ampliamente para explicar la formación de patrones en sistemas naturales, como las rayas de una cebra o las manchas de un leopardo.

La lógica detrás es sencilla pero muy útil. Turing describe el proceso mediante un sistema de ecuaciones diferenciales parciales: Su "u" es una sustancia que interactúa con otra sustancia "v", para formar algún patrón como por ejemplo las manchas de un leopardo, entonces esa reacción química podría describirse mediante la siguiente fórmula:

$$\left. \begin{aligned} \frac{\delta u}{\delta t} &= f(u, v) + D_u + \nabla^2 u \\ \frac{\delta v}{\delta t} &= g(u, v) + D_v + \nabla^2 v \end{aligned} \right\} \begin{aligned} u(x, t) &= \text{Concentración de la sustancia } u \text{ en el espacio } x \text{ en el tiempo } t \\ v(x, t) &= \text{Concentración de la sustancia } v \text{ en el espacio } x \text{ en el tiempo } t \\ f(u, v) &= \text{Término de reacción para } u, \text{ describe cómo } u \text{ interactúa con } v. \\ g(u, v) &= \text{Término de reacción para } v. \\ D_u, D_v &= \text{Coeficientes de difusión para } u \text{ y } v, \text{ respectivamente.} \\ \nabla^2: & \text{Operador laplaciano, que modela la difusión espacial.} \end{aligned}$$

Si asignamos valores arbitrarios a los valores de "u", "v" y "n", podríamos usar la ecuación de Turing y simular un patrón de manchas similar a los que podríamos encontrar en la naturaleza



Patrón de Turing - Manchas

Alan Turing falleció el 7 de Junio de 1954, su trabajo es reconocido como uno de los pioneros de la informática teórica. Su concepto de la **máquina de Turing** sentó las bases de lo que hoy conocemos como computadoras. Turing era un corredor talentoso. En 1948, intentó clasificar para el equipo olímpico británico y quedó muy cerca, con un tiempo de 2 horas y 46 minutos en una maratón, solo 11 minutos más lento que el ganador de la medalla de oro en ese momento!

Uno de los primeros algoritmos de lo que hoy se considera inteligencia artificial, fue desarrollado en 1958 por Frank Rosenblatt, quién curiosamente no era matemático sino psicólogo. Inspirado en el funcionamiento del cerebro humano propuso un algoritmo llamado “perceptrón” y se considera el precursor de las redes neuronales modernas

Dicho algoritmo propone una idea simple pero muy ingeniosa para resolver problemas. Imaginemos por un momento que intentamos enseñarle a una computadora a distinguir una manzana de una naranja, partiremos del hecho de que nosotros mismos somos capaces de hacer esa clasificación. La mayoría de nosotros somos capaces de saber en fracciones de segundos, si una fruta determinada tiene el aspecto de ser manzana o naranja. Para lograr esto, usamos las características inherentes a las manzanas y a las naranjas. Luego usamos esta información para generar un sistema de clasificación en donde valorando cada una de estas características concluimos que aquel objeto que nuestros ojos captan pertenece a una u otra clase de fruto. ¿Qué características usamos en este caso y cual es más importante para definir la clase de fruta?


En primer lugar, podemos usar el color, todos sabemos por experiencias previas que las manzanas suelen ser rojas y las naranjas de color anaranjado. En segundo lugar, sabemos que las naranjas son más pesadas que las manzanas. Sin embargo, para los seres humanos estas características son meramente cualitativas, ya que nuestros ojos son sensibles a la luz de colores, pero no podemos darle un valor exacto a ese color y nuestras manos definitivamente no tienen una báscula integrada como para saber con exactitud cuanto pesa una y otra fruta. Una computadora, sin embargo, funciona únicamente con datos cuantitativos, por lo que primero tenemos que generar un

conjunto de medidas numéricas que conviertan esas características cualitativas que nosotros percibimos, en un conjunto de números bien estructurados que permitan a la computadora tener la información relativa a todo lo que distingue a una manzana de una naranja. Hagamos un ejercicio mental y representemos al color en una escala del 1 al 10, donde 1 es muy rojo y 10 es muy naranja; por otro lado, asignaremos el número 0 a las manzanas y 1 a las naranjas. A este conjunto de medidas llamaremos datos de entrenamiento.


Clase





Color






Peso




150 gr



160 gr



200 gr



210 gr

Un sistema de machine learning que sea capaz de distinguir entre manzanas y naranjas podría consumir entre 5 y 15 wats por cada imagen procesada. El cerebro humano consume alrededor de 20 wats de energía total, pero solamente una fracción de esta energía esta dedicada al procesamiento visual. Esto hace que el cerebro sea más eficiente por varios ordenes de magnitud en relación con un sistema de computo. Sin duda alguna las fuentes de energía son el gran reto de los sistemas de IA en los próximos años.



| Peso (x1) | Color (x2) | Clase |
|-----------|------------|-------------|
| 150 | 3 | Manzana (0) |
| 160 | 2 | Manzana(0) |
| 200 | 8 | Naranja(1) |
| 210 | 9 | Naranja(1) |

De las dos características que disponemos definitivamente una será más importante que la otra, al momento de decidir, si aquello es una manzana o una naranja. Si están de acuerdo, podemos definir que, a la hora de clasificar ambas frutas, la característica más importante puede ser el color, sin embargo, una computadora aún no sabe eso y justamente lo que buscamos es encontrar una ruta para enseñarle las diferencias entre ambas frutas.

Rosenblatt propuso que la importancia de cada variable al principio del algoritmo debería ser la misma para ambas características. Así que asigno el mismo valor para cada una.

Así que la importancia inicial para el color de la fruta fue de “0” y para el peso fue de “0”.

Por lo tanto, la decisión de la clase a la que pertenece un fruto debe ser igual a:

Clase de fruta = (importancia del peso del fruto x el peso del fruto) + (importancia del color del fruto x el color del fruto)

Esta es una forma de escribir en una ecuación matemática la regla que le permitiría decidir a una maquina si una fruta desconocida pertenece a la clase “manzanas” o “naranjas”, pero hay que recordar que desde el año 1637, se suelen usar las ultimas letras del alfabeto para nombrar a las variables dependientes e independientes, así que, ajustándonos al viejo estilo de la estadística clásica podemos reescribir la fórmula de la manera siguiente:

$$y = x_1 w_1 + x_2 w_2$$

Donde:

y = Clase de fruta (manzana o naranja) que es la variable dependiente

x_1 = Peso del fruto

w_1 = Importancia de la variable “Peso”

x_2 = Color del fruto (Rojo o Naranja en la escala del 1 al 10 que propusimos)

w_2 = Importancia de la variable “Color”.

Para efectos de darle fácil seguimiento al ejemplo, llamaremos a esta fórmula “la famosa ecuación_1”

Al ser esta una fórmula matemática, el resultado de “ y ” será definitivamente un número. Ese número debe representar un valor según el cual podamos determinar la clase de fruto (manzanas o naranjas). Previamente habíamos asignado un “0” a las manzanas y un “1” a las naranjas, por lo tanto, el resultado después de aplicar la fórmula debe converger en cualquiera de los dos valores. Así que para iniciar con el “entrenamiento” de la computadora que va a distinguir entre estos dos frutos, podemos proponer la siguiente regla de decisión:

$$y = \begin{cases} 1, & \text{si } y \geq 0 \\ 0, & \text{si } y < 0 \end{cases}$$

Hasta este momento todo es solamente un planteamiento, pero si usamos esta regla de decisión en la “famosa_ecuación_1” para intentar clasificar a la fruta número 1 que de acuerdo con nuestra tabla es una Manzana que pesa 150 gramos y de “color 3” es decir rojo, entonces tendríamos:

$$y = x_1 w_1 + x_2 w_2 ; (0 * 150) + (0 * 0.3)$$

El resultado para la primera fruta sería $y=0$; porque cualquier número multiplicado por cero es igual a cero.

Tenemos un primer resultado, nuestra regla de decisión dice que, si “y” es menor o igual a cero, entonces “y” valdrá 1. ¿Como es posible que un valor calculado como “0” se convierta en “1”?, en realidad el proceso de “aprendizaje” empieza con un error muy alto, por este motivo, podemos decir que este proceso es similar a procesos de “aprendizaje” humanos, guardando las debidas distancias. En cualquier caso, para la primera fruta, “ $y_{\text{real}} = 0$ ” porque sabemos de antemano que el primer fruto es una manzana (ver tabla). Sin embargo, el valor para “ y_{estimado} ” que sería el resultado para “y” después de sustituir los valores correspondientes a la primera fruta, en la “famosa_ecuación_1” fue igual a 1: así que:

$$\text{“}y_{\text{real}} = 0\text{” es diferente de “}y_{\text{estimado}} = 1\text{”}$$

Por lo tanto, nuestra primera aproximación fue un error, eso podría indicar que la importancia que le dimos a alguna de las dos variables puede estar equivocada, por lo tanto deberemos ajustar ese valor, para lo cual Rosenblatt propone lo siguiente.

Designemos la letra “w” para la “importancia” de cada variable:

El ajuste para la variable “peso del fruto” se determina mediante:

$$w_1 = w_1 + n (y_{real} - y_{estimado})$$

Como vemos en esta fórmula se introduce un nuevo elemento (“n”), pero ¿Qué es ese nuevo elemento?

Con la letra “n” se define un valor conocido como tasa de aprendizaje. En realidad, es solamente un número arbitrario que nos ayuda a “ajustar” el valor de importancia que le damos a cada variable. Si “n” fuera igual a cero entonces “w₁” no sufriría ningún cambio, en contraste si “n” fuera un número grande, entonces “w₁” sufriría grandes cambios. En este caso sabemos que hay diferencia entre ($y_{real} - y_{estimado}$) por lo tanto podemos asignar un número, aunque sea pequeño, a “n”. Entonces de forma arbitraria podemos decidir que “n=0.1”, aunque en realidad puede ser cualquier valor, el iniciar con numero pequeños ofrece la ventaja de un mayor ajuste. En cualquier caso, con este valor ya definido podemos recalcular la importancia que cada variable tiene en la decisión final. Entonces, la importancia para la variable 1 que es el peso del fruto estaría definida por:

$$w_1 = w_1 + n (y_{real} - y_{pred}) * x_1 ; 0 + 0.1 (0 - 1) * 150 = -15$$

Y la importancia para la segunda variable que es el color del fruto estaría determinada por:

$$w_2 = w_2 + n (y_{real} - y_{pred}) * x_2 ; 0 + 0.1 (0 - 1) * 3 = -0.3$$

Perfecto!!! Ahora tenemos valores que podemos usar para intentar clasificar a los frutos (Manzanas o Naranjas). Hagamos un primer intento, ahora utilizando los datos del segundo fruto, que es una manzana que pesa 160 gramos y con un valor de color de dos (ver tabla).

Si aplicamos nuestra regla de decisión entonces $y_{pred} = 0$; y justamente cero, es el número que asignamos a las manzanas, por lo cual en este caso el sistema acertó y podemos decir que la segunda fruta fue clasificada correctamente usando los valores para la “importancia de las variables” que hemos calculado. Hagamos el mismo ejercicio con el tercer fruto que es una naranja que pesa 200 gramos y con un valor de color igual a ocho:

$$y = w_1 x_1 + w_2 x_2 ; (-15 * 200) + (-0.3 * 8) = -3000 - 2.4 = -3002.4$$

De acuerdo con nuestra de decisión “ $y_{pred} = 0$ ”; Como vemos nuestro sistema cometió un error y clasificó de forma incorrecta a los frutos.

Debido a que el fruto realmente se trata de una naranja, nosotros esperábamos un valor de “ $y_{pred}=1$ ”, esto indica que debemos de recalcular el valor que le estamos asignando a la importancia de cada variable, usando la fórmula que propusimos antes, por lo tanto:

$$w_1 = w_1 + n (y_{real} - y_{pred}) * x_1 ; -15 + 0.1 (1 - 0) * 200 = 5$$

La importancia para la variable “color del fruto” sería:

$$w_2 = w_2 + n (y_{real} - y_{pred}) * x_2 ; -0.3 + 0.1 (1 - 0) * 8 = 0.5$$

Excelente!!! Ahora tenemos nuevos valores que podremos usar para intentar clasificar el fruto número cuatro que es una naranja que pesa 210 gramos y con un valor de 9 para el color.

$$y = w_1 x_1 + w_2 x_2 ; (5 * 210) + (0.5 * 9) = 1050 + 4.5 \\ = 1054.5$$

Usando de nuevo nuestra regla de decisión “ $y_{pred}=1$); por lo tanto, el sistema clasificó de forma correcta al fruto.

Después de esta serie de iteraciones a través de los datos podemos decir que tenemos unos valores para la importancia de las variables (peso y color) que podrían servir para clasificar a todos los frutos que

tenemos en nuestra tabla, es decir tenemos un “modelo entrenado”. Así que a continuación lo vamos a usar en todos los casos que tenemos disponibles, considerando que “ $w_1 = 5$ ” y “ $w_2 = 0.5$ ”

Supongamos que tenemos una nueva fruta con peso 180 gramos y un valor de color igual a 6. ¿Usted de que fruta cree que se trate, de una manzana o una naranja? Veamos que dice nuestro sistema recién entrenado.

$$y = w_1 x_1 + w_2 x_2 ; (5 * 180) + (0.5 * 6) = 900 + 3 = 903$$

Usando nuestra regla de decisión que indica que, si “ y ” es mayor o igual a cero, entonces “ $y=1$ ”; por lo tanto, nuestro perceptrón ha clasificado al nuevo fruto como una naranja.

Si tuviéramos más datos en nuestra tabla de entrenamiento, podríamos ajustar cada vez, el valor de la “importancia” para cada variable. Además, podríamos tener más de dos variables y cada una de ellas tendría un valor de importancia que se podría ajustar cada vez más, con la finalidad de lograr sistemas de clasificación cada vez más confiables.

La intención de este trabajo no es ni de cerca, ser un libro estrictamente académico que sirva para aprender todos los procedimientos matemáticos de la inteligencia artificial. Si hemos dedicado estas páginas a profundizar en los primeros algoritmos creados para emular el pensamiento humano a través de un procedimiento que pudiera ser “instalado” en una máquina, es con el objetivo básico de comprender la lógica detrás de la inteligencia

artificial y poder analizar las implicaciones de esta forma de plantear problemas, en los estudios a los sistemas agrícolas. Además, vale la pena resaltar que estos algoritmos, son increíblemente simples en cuanto a su concepción original, pero en el momento en el que fueron creados era imposible su uso práctico.

En el caso que hemos estudiado, tenemos apenas, una base de datos de apenas cuatro ejemplos de frutas, dos manzanas y dos naranjas. En la práctica, las bases de datos modernas que se usan para entrenar sistemas de inteligencia artificial tienen millones de entradas, además no solamente usan dos variables (en nuestro caso hicimos una clasificación usando únicamente el peso y el color del fruto) sino cientos o a veces miles de características. Si analizamos bien el procedimiento que usamos para clasificar a nuestras cuatro frutas, podemos ver que solo se trata de sumas y restas, algo increíblemente simple y funcional. Sin embargo, si quisiéramos clasificar a cualquier manzana o cualquier naranja, nuestros cuatro ejemplos serían insuficientes para lograr estimar los valores para la importancia de las variables, además pronto aparecerían nuevas variables que integrar (posiblemente el estado de madurez, la firmeza del fruto, incluso el aroma). Pronto estaríamos ante una cantidad tal de sumas y restas, que serían imposibles de hacer por un ser humano.

Esta es la razón por la que, los sistemas de IA requieren de “maquinas” potentes, capaces de hacer millones de operaciones por segundo. También es la razón por la cual, la mayoría de estos algoritmos no tuvieron una utilidad práctica en los años en los que fueron creados. Insistimos en el hecho de que a mitad del siglo pasado las capacidades de cómputo eran muy inferiores en comparación con las capacidades con las que se cuenta actualmente, si tuviéramos una base de datos con unas cuantas decenas de manzanas y naranjas, tendríamos que

hacer una cantidad escandalosa de sumas y restas con la finalidad de ajustar los valores de “importancia” para cada una de las variables. En esos años, simplemente no había una maquina capaz de hacer semejante tarea.

En los años noventa del siglo pasado, se hicieron mejoras muy significativas en los algoritmos de lo que hoy son las redes neuronales, que permitieron que muchas limitaciones que presentaban los perceptrones fueran mejoradas. Hoy en día tenemos sistemas de inteligencia artificial que son capaces no solo de clasificar a los frutos por especie, sino que además determinan otros aspectos como estado de madurez, calidad, estiman la vida de anaquel e incluso hay sistemas de visión artificial capaces de detectar riesgos a la salud humana en alimentos y bebidas.

Para esto hoy día disponemos de procesadores capaces de hacer “sumas y restas” en números astronómicamente grandes, lo cual genera sistemas muy robustos capaces de clasificar o estimar una enorme cantidad de variables de mucha utilidad.

El modelo que aprendimos se llama perceptrón, y fue inspirado por el funcionamiento de las neuronas en el cerebro humano, este modelo se considera precursor de las redes neuronales modernas. La diferencia entre las redes neuronales modernas y el perceptrón no solamente es el número masivo de datos que se utilizan para su entrenamiento, sino mejoras en el algoritmo que se realizaron con el paso del tiempo.

El perceptrón, aunque increíblemente simple, fue la chispa que inició una revolución en la inteligencia artificial. Su lógica, basada en operaciones sencillas como sumas y restas, nos enseña que las ideas más transformadoras a menudo parten de conceptos básicos. Hoy, con el poder del cómputo moderno, hemos llevado estas ideas a niveles

que Rosenblatt nunca habría imaginado, clasificando no solo frutas, sino imágenes, textos y hasta anticipando necesidades humanas. ¿Hasta dónde nos llevará esta evolución? Esta pregunta no distingue entre edades, títulos o profesiones; su respuesta está en la creatividad y la imaginación, cualidades que cualquier ser humano puede poseer, ya sea un científico experimentado o un niño curioso. Aunque sus conocimientos sean diferentes, ambos tienen la misma capacidad de soñar y crear, porque la innovación no siempre nace del saber, sino de la capacidad de mirar el mundo con ojos nuevos y preguntarse: "¿Qué más es posible?".

Estadística clásica versus IA

Si has llegado hasta aquí, es el momento perfecto para reflexionar sobre las diferencias entre la estadística clásica y los sistemas de inteligencia artificial, cuyos orígenes se remontan al perceptrón y algoritmos similares. Para ello, es importante destacar algunas características clave.

La estadística clásica nos permite analizar la relación entre variables dependientes e independientes. En el caso de las plantas, estudiamos cómo responden a diferentes condiciones, pero generalmente considerando unas pocas variables a la vez. Esto es increíblemente útil, porque nos brinda una herramienta para aprender sobre la fisiología de las plantas, seres vivos con los que no podemos comunicarnos directamente. La única manera de entenderlas es mediante la observación en experimentos cuidadosamente diseñados, guiados por principios estadísticos.

A través de estos experimentos, hemos acumulado una valiosa colección de conocimientos sobre las plantas. Cada experimento suma una pequeña pieza al rompecabezas de su fisiología, ayudándonos a

entender cómo responden a distintas condiciones ambientales, prácticas de manejo y tratamientos específicos. Este conocimiento, desarrollado gracias a los métodos estadísticos, ha sido fundamental para establecer los criterios con los que manejamos los sistemas agrícolas, responsables de producir alimentos para una población en constante crecimiento.

El criterio agrícola que usamos hoy es el resultado de décadas de experimentación basada en técnicas estadísticas en diferentes partes del mundo. Sin estos métodos, nuestra capacidad para entender y optimizar los sistemas agrícolas sería limitada. La estadística clásica sigue siendo una herramienta poderosa para desentrañar los secretos de las plantas y guiar decisiones que impactan la seguridad alimentaria global.

Los métodos estadísticos que usamos en la agricultura se basan en modificar unas pocas variables de interés mientras mantenemos constantes las demás. Este enfoque minimiza el error experimental y da cierta confiabilidad a los resultados. Sin embargo, plantea un problema crucial: en la naturaleza, las plantas no crecen en entornos controlados, sino en medio de un ambiente dinámico e impredecible, donde múltiples factores interactúan constantemente. Intentar considerar todas las variables que afectan el crecimiento de las plantas en un experimento es simplemente imposible.

Un agrónomo con experiencia podría advertir a un agricultor que una práctica inadecuada en su sistema agrícola podría reducir el rendimiento. Sin embargo, estimar con precisión cuántos kilogramos se perderán es una tarea complicada. Sus conclusiones dependerían de supuestos o de estudios previos reportados en la literatura

científica, muchas veces difícil de aplicar directamente al caso particular.

Por otro lado, el mismo agrónomo podría recomendar una práctica agrícola que ha demostrado buenos resultados en trabajos previos, y hasta aventurarse a ofrecer un rango aproximado de rendimientos, siempre basado en datos generados en condiciones similares. Después de muchos años de arduo estudio y de contrastar esos estudios con casos reales, un profesional del campo podría generar un criterio que le permitiera asesorar de la mejor forma posible a un agricultor.

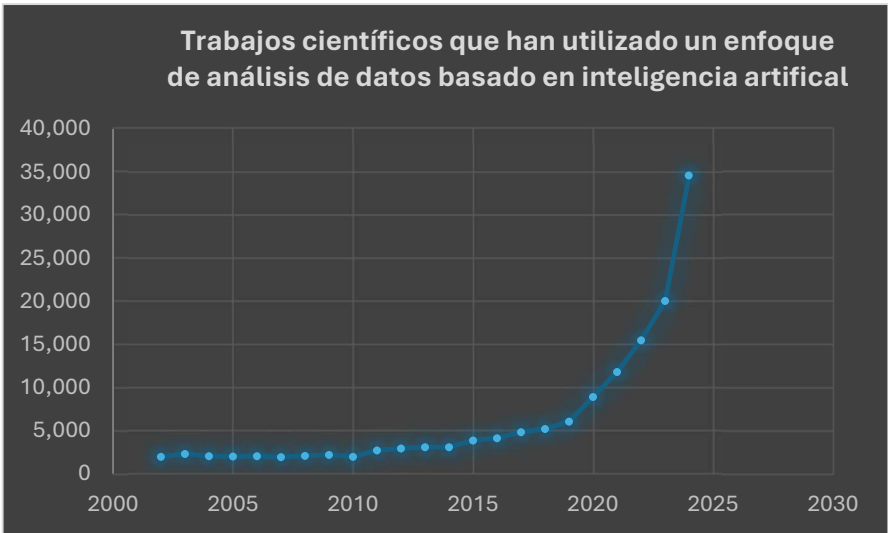
En este contexto, los datos se habrán convertido en verdadero conocimiento, pero al final del proceso terminamos dependiendo nuevamente del criterio de una persona. Paradójicamente, esto nos acerca a una dinámica similar a la era previa al surgimiento de la estadística, cuando la agricultura dependía casi exclusivamente del conocimiento empírico de los agricultores, basado en la observación y la experiencia personal acumulada a lo largo de los años.

Aunque hoy en día contamos con herramientas estadísticas que respaldan las decisiones agrícolas, todavía existe una fuerte dependencia de la interpretación humana para traducir esos datos en acciones prácticas. Esto introduce una variabilidad importante: el éxito de las decisiones no solo depende de los datos, sino de quién los interpreta y de cómo se contextualizan en cada caso particular. Así, a pesar de los avances logrados, seguimos enfrentando el reto de minimizar la subjetividad en sistemas tan complejos como los agrícolas.

Los métodos estadísticos clásicos nos ofrecen herramientas valiosas para modelar sistemas agrícolas, aunque con una limitación importante: solo permiten analizar unas pocas variables a la vez. Esta

restricción nos ha obligado a comprender mejor a las plantas, lo que ha llevado al desarrollo de criterios generales que, hasta el día de hoy, han sido fundamentales para garantizar la producción de alimentos, tanto para una población humana creciente.

Pero eso, está cambiando a una velocidad, que parece sacada de un libro de ficción. En los últimos años, la cantidad de trabajos científicos que utilizan un enfoque de análisis de datos basado en la inteligencia artificial creció exponencialmente. Prácticamente de la noche a la mañana, las aplicaciones agrícolas de la inteligencia artificial comenzaron a multiplicarse a cada vez más productos y aplicaciones. En muchos casos, los propios agricultores no están del todo conscientes que están utilizando sistemas de inteligencia artificial en sus parcelas.



Las técnicas de análisis de datos basadas en inteligencia artificial han revolucionado la forma en que entendemos y manejamos sistemas agrícolas. Estos métodos permiten generar modelos que incorporan una cantidad enorme de variables, haciendo posible analizar sistemas altamente complejos sometidos a condiciones dinámicas, lo cual se parece más a lo que ocurre de forma natural. En los últimos años, han surgido estudios innovadores que utilizan técnicas de aprendizaje automático para predecir el comportamiento de diversos sistemas agrícolas. Estos modelos, con el tiempo, han mejorado su precisión y se están convirtiendo en herramientas cada vez más confiables.

A diferencia de los modelos estadísticos clásicos, los modelos basados en inteligencia artificial son capaces de operar con un número muy grande de variables simultáneamente. Esto significa que podemos simular, con una precisión considerable, el comportamiento completo de un sistema de producción agrícola, incluyendo todas las variables relevantes que puedan influir en el resultado. Además, estos modelos tienen una ventaja clave: no solo consideran las variables de manera individual, sino que también analizan las interacciones entre ellas. Esto les permite identificar y predecir cambios en el comportamiento del sistema, incluso cuando las interacciones entre variables parecen inicialmente poco evidentes o irrelevantes.

Considerando al menos hasta el día en que escribo estas líneas, la agricultura es la actividad humana que abastece a toda nuestra especie de alimentos, vale la pena preguntarse qué implicaciones puede tener el uso de sistemas de inteligencia artificial, sobre nuestro conocimiento de las plantas, cuáles son las ventajas más sobresalientes del uso de estos sistemas, pero también cuales son las desventajas e implicaciones.

Como primer punto a considerar, es necesario reconocer que los sistemas de inteligencia artificial pueden ofrecer simulaciones altamente precisas debido al número de variables que pueden incluir en los modelos. Bajo un enfoque estadístico clásico, el análisis de datos dependía en gran medida del criterio humano. Al poder manejar solo unas pocas variables a la vez, era imprescindible que el analista interpretara los resultados y estableciera conexiones basadas en su conocimiento y experiencia. En contraste, un sistema de inteligencia artificial no necesita del juicio humano en ese nivel. Esto no se debe a que la IA "comprenda" los fenómenos que explican el crecimiento de las plantas, sino a que sus modelos son capaces de integrar y analizar una enorme cantidad de variables simultáneamente. Los modelos de inteligencia artificial pueden capturar patrones complejos que permiten explicar esos fenómenos, incluso aquellos que podrían pasar desapercibidos para un ser humano.

Por primera vez en la historia de la humanidad, estamos frente a la posibilidad de manipular un proceso sin necesariamente comprenderlo en su totalidad. En este sentido, la inteligencia artificial se convierte en una herramienta fascinante para los profesionales de la agricultura. Actualmente, un ingeniero agrónomo dedica años de estudio para adquirir los conocimientos teóricos necesarios y, además, debe desarrollar un criterio sólido basado en la experiencia práctica y el aprendizaje constante. Sin embargo, incluso con esta preparación, no siempre puede ofrecer respuestas cuantitativas precisas a problemas prácticos.

En muchas ocasiones, el conocimiento empírico, acumulado a través de la experiencia directa, puede superar incluso los años de estudio formal. Esto genera una paradoja en la agricultura: combinar el saber académico con la intuición práctica. La inteligencia artificial promete

cerrar esta brecha, proporcionando análisis y predicciones que integran una cantidad masiva de datos, algo que ningún ser humano podría procesar por sí solo. Así, la IA no solo complementa, sino que amplifica las capacidades de los profesionales del campo, abriendo nuevas posibilidades en la toma de decisiones agrícolas.

Sin embargo, el riesgo es evidente. Nuestra capacidad para manipular y optimizar el crecimiento de las plantas ha sido posible porque comprendemos los procesos subyacentes. Aunque los métodos basados en estadística clásica no siempre permiten predecir con precisión el comportamiento de un cultivo bajo condiciones muy específicas, los años de experiencia han dado a los seres humanos la habilidad de establecer criterios y pautas generales que, hasta ahora, han permitido alimentar a una población en constante crecimiento.

La incorporación de los sistemas de inteligencia artificial, aunque revolucionaria, plantea un desafío: estos sistemas pueden ofrecer respuestas prácticas para situaciones específicas con un margen de confiabilidad relativamente elevado, pero a cambio de que el usuario no comprenda por completo el papel que desempeña cada variable en el comportamiento del sistema. Esto podría conducir a una desconexión entre las decisiones prácticas y el entendimiento de los procesos que sustentan dichas decisiones.

En nuestro ejemplo anterior, clasificamos manzanas y naranjas utilizando solo un par de variables. Sin embargo, los sistemas de inteligencia artificial modernos son capaces de manejar sin dificultad cientos de variables, cada una con miles o incluso millones de observaciones. Esto los convierte en herramientas increíblemente poderosas, pero también nos enfrenta al dilema de confiar en resultados que no necesariamente entendemos del todo, lo que podría

cambiar la forma en que tomamos decisiones agrícolas y científicas. Este fenómeno incluso tiene un nombre técnico; se les llama modelos de “caja negra” a aquellos que producen resultados a partir de un conjunto de variables de entrada, sin ofrecer una explicación clara o comprensible de cómo se llegó a ese resultado. Aunque estos modelos suelen ser muy precisos, su falta de transparencia dificulta entender las relaciones entre las variables o los procesos específicos que hacen que una variable sea o no importante en la decisión final. Los modelos de caja negra como lo son las redes neuronales modernas tienen muchos parámetros y algoritmos avanzados con estructuras complejas difíciles de interpretar para un ser humano y a menudo son más precisos que los modelos obtenidos mediante técnicas de estadística clásica, pero sacrificando la transparencia.

Un sistema de inteligencia artificial, basado en redes neuronales podría predecir el rendimiento de un cultivo analizando cientos de variables, como el tipo de suelo, la temperatura y la humedad. Aunque el sistema ofrece predicciones precisas, no es capaz de explicar cuáles variables fueron más importantes en el proceso, dejando al usuario sin una visión clara de las dinámicas que afectan el cultivo.

Tratándose de algo tan crucial como la producción de alimentos es esencial que los humanos no nos quedemos atrás. Debemos ser conscientes de que estos sistemas avanzados pueden convertirnos rápidamente en simples usuarios, relegándonos del control sobre los procesos agrícolas que hemos perfeccionado durante siglos. En los próximos años, será imprescindible formar profesionales capaces de entender no solo los procesos biológicos que ocurren en los sistemas

agrícolas, sino también los algoritmos y herramientas que pueden ayudarnos a optimizarlos y controlarlos.

Sin embargo, esta necesidad parece ir contracorriente con lo que está sucediendo actualmente. A medida que los sistemas de inteligencia artificial avanzan, incrementando su precisión y confiabilidad en un número cada vez mayor de cultivos y condiciones, los humanos estamos tomando un rol más pasivo. Nos estamos convirtiendo en usuarios que dependen de estos sistemas sin comprender plenamente su funcionamiento, mientras nos ocupamos en otros asuntos. Esta desconexión podría poner en riesgo nuestra capacidad de adaptarnos y tomar decisiones críticas en un ámbito tan vital como la producción de alimentos.

Este fenómeno no ha sido nuevo. Existen muchas tecnologías disruptivas que ocasionaron una pérdida en el conocimiento humano, pero una ganancia significativa en la precisión y rapidez con que se ejecutan algunos procesos. En 1940, la compañía Texas Instruments introdujo la primera calculadora electrónica portátil, marcando una verdadera revolución tecnológica. De repente, cualquier persona podía realizar sumas, restas, multiplicaciones y divisiones de números grandes al instante. Antes de la aparición de estos dispositivos, multiplicar números grandes requería un esfuerzo considerable, y resolver problemas complejos con cifras extensas implicaba largas horas de trabajo manual con lápiz y papel. Esta innovación no estuvo exenta de controversia; en su momento, hubo debates acalorados sobre si era adecuado permitir que los niños usaran calculadoras, al menos en los niveles básicos de educación.

A pesar de ello, los niños de hoy siguen aprendiendo a multiplicar y dividir manualmente, pero muchas personas adultas ya no recuerdan

cómo hacer una división larga con números de más de tres dígitos. Las calculadoras, que ahora están presentes incluso en los teléfonos celulares, resuelven con facilidad y precisión operaciones aritméticas, mientras nosotros nos enfocamos en "lo importante".

La calculadora nos brindó la capacidad de resolver problemas más rápido, liberándonos para centrarnos en el planteamiento y la resolución de problemas mientras delegábamos en la máquina el trabajo mecánico de sumar, restar, multiplicar o dividir. Sin embargo, este avance también tuvo un costo: perdimos la habilidad de realizar estas operaciones manualmente y, en muchos casos, dejamos de comprender algunos supuestos fundamentales de las matemáticas modernas.

Este fenómeno ilustra lo que mencionamos anteriormente: cómo la tecnología puede transformar nuestras capacidades. Pero, aunque significativo, no es comparable en escala con la llegada de la inteligencia artificial. A diferencia de una calculadora, que aún dependía de los humanos para plantear las operaciones necesarias para resolver problemas, los sistemas de inteligencia artificial funcionan sin descanso y sin intervención humana directa, automatizando tanto la formulación como la ejecución de soluciones complejas.

Nunca, desde hace 10,000 años que aparecieron los primeros agricultores, habíamos tenido en nuestras manos una herramienta tan poderosa. Las capacidades y aplicaciones de la inteligencia artificial en la agricultura sobrepasan por mucho a los métodos con los que cultivamos actualmente. Como especie, estamos ante una oportunidad sin precedentes en la historia de la humanidad para redefinir la forma en que producimos alimentos, logrando una agricultura más eficiente,

sostenible y capaz de satisfacer las necesidades de una población mundial en constante crecimiento. Esta oportunidad nos permite integrar tecnología avanzada para optimizar recursos, minimizar el impacto ambiental y enfrentar desafíos como el cambio climático. Con la inteligencia artificial, podemos transformar la agricultura en un motor de innovación que garantice la seguridad alimentaria y promueva el bienestar global. Tenemos la oportunidad de combinar el conocimiento ancestral con tecnología de punta, creando sistemas resilientes y preparados para los enormes retos que actualmente enfrentan los sistemas agrícolas.

Capitulo III

Sistemas de IA: grandes devoradores de datos

Datos y más datos.

Si recuerdas nuestro sencillo ejemplo de clasificación de manzanas y naranjas, notarás que utilizamos solo cuatro frutas como referencia. Como aprendimos, sería imposible extrapolar un sistema funcional a todas las manzanas y naranjas del mundo a partir de un conjunto de datos tan pequeño. Para construir un sistema de clasificación de frutas realmente efectivo, necesitaríamos información sobre una cantidad significativamente mayor de naranjas y manzanas.

Los sistemas de inteligencia artificial tienen una característica distintiva: requieren grandes volúmenes de datos para generar resultados precisos y confiables. Como mencionamos anteriormente, cuando se propuso el modelo del perceptrón, no solo existía la limitación de la capacidad de procesamiento de las máquinas de la época, sino también el problema de adquirir los datos necesarios para alimentar un modelo robusto desde el punto de vista matemático.

Actualmente, esta realidad está cambiando drásticamente. La tendencia emergente de generar datos, incluso por medios automatizados o sensores, está transformando radicalmente las dinámicas de desarrollo en diversas disciplinas, incluida la agricultura. Es interesante considerar el papel que podría jugar la propia IA al generar datos sintéticos: información creada mediante simulaciones o algoritmos avanzados para entrenar modelos de aprendizaje automático sin necesidad de depender exclusivamente de datos reales.

En un escenario hipotético, estas capacidades podrían integrarse con el Internet de las Cosas (IoT), ¿se imaginan un ecosistema autónomo donde las decisiones agrícolas sean gestionadas completamente por máquinas? Desde la monitorización de cultivos hasta la toma de decisiones de riego o fertilización, el ser humano podría quedar fuera

de la ecuación operativa, limitándose a supervisar resultados. Aunque este avance plantea preguntas éticas y estratégicas, indudablemente invita a reflexionar sobre el equilibrio entre la automatización total y el papel humano en la agricultura del futuro.

La llegada de los sensores electrónicos marcó un antes y un después en este aspecto. Durante mucho tiempo, variables fundamentales para los sistemas agrícolas, como la temperatura o la humedad, se medían manualmente con instrumentos que debían ser leídos por una persona. Estos datos eran luego registrados en papel, lo que añadía una etapa laboriosa y propensa a errores en el proceso de análisis. Sin métodos eficientes para capturar, almacenar y analizar grandes volúmenes de información, los datos recolectados apenas podían aprovecharse.

Hoy, con el avance de la tecnología, los sensores electrónicos permiten recopilar información de manera continua y automática, generando inmensas bases de datos que alimentan los sistemas de inteligencia artificial. Este cambio ha revolucionado disciplinas como la agricultura, donde los algoritmos modernos, alimentados por volúmenes de datos inimaginables hace décadas, producen predicciones y análisis con una precisión sin precedentes.

En agricultura, la temperatura ambiental es una variable clave para el crecimiento y desarrollo de las plantas. Determina procesos fisiológicos esenciales, ya que muchas enzimas vegetales funcionan de manera óptima dentro de rangos específicos de temperatura. Por esta razón, la temperatura se utiliza frecuentemente como indicador del estado de los cultivos, y es crucial monitorear cómo esta variable fluctúa a lo largo de las estaciones o según la región geográfica.

Hoy podemos consultar la temperatura desde nuestros teléfonos celulares, pero los primeros intentos de medirla datan del siglo XVII.

Galileo Galilei, célebre por su apoyo al modelo heliocéntrico que le valió la persecución de la Iglesia, diseñó un instrumento llamado termoscopio. Este dispositivo solo indicaba cambios relativos en la temperatura, sin proporcionar una escala cuantitativa. En 1741, Gabriel Fahrenheit, un maestro vidriero, creó un termómetro de mercurio con una escala precisa, que más tarde sería perfeccionada por el sueco Anders Celsius. Hasta hace unas décadas, los termómetros de alcohol o mercurio eran herramientas comunes en campos e invernaderos para medir la temperatura. Sin embargo, su uso requería lecturas manuales y registros escritos, lo que limitaba el análisis práctico de los datos recopilados. Aún hoy, en invernaderos de baja tecnología, se encuentran hojas llenas de anotaciones diarias de temperaturas mínimas y máximas, que rara vez son procesadas para generar información útil.

La llegada de los sensores electrónicos cambió radicalmente esta realidad. Desde finales del siglo XX, los sensores de temperatura basados en semiconductores han ofrecido mediciones en tiempo real, convirtiendo la temperatura en datos digitales que pueden almacenarse localmente o transmitirse a distancia. Estos sensores no solo miden temperatura, sino que también alimentan sistemas de inteligencia artificial ávidos de datos para su entrenamiento. Además, la tecnología moderna ha introducido una amplia gama de sensores agrícolas que monitorean variables como humedad del suelo, humedad relativa, velocidad del viento, entre otros, todos capaces de transmitir información en tiempo real.

Recientemente, el desarrollo de tecnologías de teledetección ha ampliado aún más el horizonte de datos disponibles. Imágenes satelitales y cámaras digitales montadas en drones ahora permiten evaluar parámetros fisiológicos de las plantas a gran escala.


Estas herramientas son fundamentales para satisfacer la necesidad de datos masivos que requieren los sistemas de inteligencia artificial, ajustando los "pesos" de las variables en sus modelos para lograr predicciones cada vez más precisas. En 1882, el biólogo alemán Theodor Engelmann realizó un experimento considerado un clásico en el campo de la fisiología vegetal. Armado con unas cajas de Petri y mucha creatividad, demostró que la fotosíntesis es más intensa en las longitudes de onda azul y roja. Utilizando luz separada en diferentes longitudes de onda mediante un prisma, iluminó filamentos de algas del género *Spirogyra* y observó que bacterias aerobias crecían más en las zonas iluminadas con luz azul o roja. Esto demostraba que esas longitudes de onda generaban una mayor producción de oxígeno, consecuencia de tasas fotosintéticas elevadas.

Con los avances en años posteriores, este conocimiento permitió desarrollar sensores capaces de detectar las cantidades de luz reflejadas por las plantas. Utilizando cámaras altamente sensibles a diferentes longitudes de onda, es posible detectar cambios en los patrones de absorción y reflexión de la luz en las hojas. Cada imagen proveniente de estas cámaras es una matriz de números, en donde cada uno de los datos (píxeles) representa un sitio específico del campo bajo estudio. Además, la misma imagen es capaz de proporcionar datos acerca de la ubicación geográfica de la imagen, con lo cual se pueden construir mapas de alta resolución de grandes superficies. Cada imagen generada por estas cámaras es una matriz de números donde cada dato (píxel) representa un punto específico del campo bajo estudio.

Además, estas imágenes proporcionan datos geospaciales, permitiendo construir mapas de alta resolución de grandes superficies. Cada imagen puede contener millones de datos y, al combinarlos con

información de otros sensores, es posible alimentar sistemas de inteligencia artificial altamente confiables y robustos.

Cuando las plantas reciben luz solar, esta es absorbida, reflejada o transmitida por los compuestos presentes en las hojas como las clorofilas. La cantidad de luz que las plantas reflejan es el resultado de la interacción entre los fotones y las moléculas presentes en las hojas. Esta interacción genera patrones ópticos que corresponden con muchos estados de la fisiología de las plantas y es útil para saber cuando las plantas pasan por distintos procesos biológicos, como sequía o enfermedades. Esta información es capturada mediante cámaras que se encuentran a bordo de vehículos aéreos no tripulados y se utiliza para alimentar a sistemas de inteligencia artificial que permiten detectar distintos procesos fisiológicos que ocurren en las plantas y son de gran utilidad para definir diversas labores agrícolas.



Actualmente las cámaras instaladas a bordo de vehículos aéreos no tripulados sirven como fuente de datos para entrenar sistemas de inteligencia artificial de mucha utilidad en la toma de decisiones en los sistemas agrícolas. Estas cámaras cuentan con sensores de luz que almacenan imágenes de las plantas tomadas a diferentes longitudes de onda con una precisión muy alta (la resolución de estas cámaras en un vuelo suele ser mayor a 5 cm por píxel).

Las redes neuronales modernas incluyen parámetros adicionales a los que se contemplan en los perceptrones. Las letras "B" indican el sesgo que tiene cada de las capas de la red. El sesgo ay mejora ayuda a "ajustar" patrones más flexibles y mejora la capacidad para generalizar el modelo. Matemáticamente el sesgo de una neurona se define como:

$$z = \sum (w \cdot x) + b$$

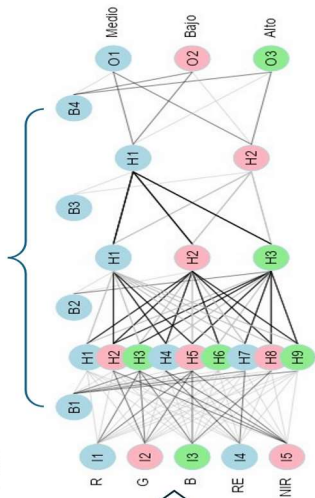
Donde:

z = Salida de la neurona antes de la activación.

w = Pesos de las conexiones.

x = Valores de las entradas.

b = sesgo.



En esta red neuronal se toma la información proveniente de imágenes obtenidas mediante vehículos aéreos no tripulados para obtener información acerca del grado de estrés hídrico de plantas de maíz. Las letras "I" representan los datos de entrada que necesita el modelo para operar. Las letras "H" representan las distintas capas de la red neuronal (en este caso tiene tres capas) y las letras "O" representan los datos de salida, en este caso estrés, alto, medio o bajo.

Hoy, como nunca en la historia de la agricultura, somos capaces de generar volúmenes de información gigantescos, abriendo un nuevo capítulo en la interacción entre tecnología y producción agrícola.

Si los sistemas de inteligencia artificial están teniendo éxito, en parte se debe a que los seres humanos somos capaces de alimentarlos con la cantidad de datos necesarios. En las últimas décadas, la capacidad para generar, recopilar y procesar datos ha crecido exponencialmente gracias al avance de la tecnología en sensores, dispositivos de almacenamiento y conectividad. Cada interacción, cada medición y cada registro que producimos contribuye a formar un vasto ecosistema de información que nutre estos sistemas.

Sin embargo, este éxito también plantea desafíos éticos y técnicos. La dependencia de datos requiere garantizar su calidad, representatividad y privacidad. Los sesgos en los datos o la falta de diversidad en las muestras pueden generar resultados poco confiables o incluso perjudiciales.

Consideremos de nuevo el ejemplo de clasificación de manzanas y naranjas. Como recordaremos, el éxito de nuestro sistema consistió en que nosotros mismos éramos capaces de hacer esa clasificación inicial y de etiquetar cada fruta como perteneciente a la clase "manzana" o "naranja". En otras palabras, nosotros proporcionamos las etiquetas que sirvieron como base para que el sistema ajustara sus valores y aprendiera a diferenciar entre las dos clases. Este proceso, donde los datos de entrada están acompañados de las respuestas correctas para que el modelo pueda aprender, se conoce como "aprendizaje supervisado".

En el contexto agrícola, esta técnica tiene aplicaciones muy valiosas. Por ejemplo, se puede utilizar para entrenar modelos que detecten

enfermedades en hojas, clasifiquen frutos según su calidad o predigan rendimientos de cultivos basándose en imágenes satelitales. Sin embargo, el éxito de estos modelos depende en gran medida de la calidad y relevancia de los datos proporcionados durante el entrenamiento.

Un aspecto crítico de este proceso es el potencial de introducir sesgos en el sistema. Un sesgo en los valores iniciales, es decir, en las etiquetas o en las características utilizadas para entrenar el modelo, puede llevar a resultados erróneos o poco útiles. Por ejemplo, imaginemos que, en lugar de usar los pesos reales de las manzanas para entrenar un modelo, se utilizan los pesos de sandías. Esto haría que el sistema asuma que las manzanas deben ser mucho más pesadas de lo que son en realidad. Como consecuencia, el modelo intentaría clasificar como "manzanas" únicamente a frutos muy pesados, ignorando todas las manzanas reales y convirtiéndose en un sistema inútil para la tarea deseada.

Este ejemplo hipotético ilustra la importancia de los datos en el entrenamiento de los sistemas de inteligencia artificial. Para que un modelo sea efectivo, los datos deben ser representativos del problema real que se desea resolver. Si los datos están sesgados o son irrelevantes, el modelo no solo fallará en su desempeño, sino que también podría generar conclusiones erróneas con consecuencias significativas, especialmente en sectores como la agricultura, donde las decisiones pueden afectar tanto la economía como la sostenibilidad ambiental.

Por lo tanto, al desarrollar sistemas basados en aprendizaje supervisado, es crucial que los seres humanos desempeñemos un rol activo en garantizar que los datos sean precisos, representativos y

relevantes. Esto incluye revisar las etiquetas iniciales, asegurarse de que las características seleccionadas para el modelo sean apropiadas y monitorear continuamente su desempeño para corregir posibles errores o sesgos que puedan surgir durante el entrenamiento o en su aplicación práctica.

En esencia, la efectividad de los modelos de aprendizaje supervisado en la agricultura no solo depende de los algoritmos, sino también de nuestra capacidad para comprender el problema y proporcionar los datos correctos. Sin esta supervisión humana, incluso el sistema más sofisticado sería incapaz de ofrecer soluciones útiles o confiables.

La abundancia de datos y la necesidad de análisis

La pinza casi está cerrada, establecimos que la necesidad de datos de los sistemas de IA, está siendo solventada mediante la combinación de sensores electrónicos que además son capaces de transmitir esa información en tiempo real. Sin embargo, los datos por sí mismos no son valiosos, de nada nos sirven miles de terabytes de información si no se transforma en un conocimiento. Hagamos un esfuerzo y distingamos la diferencia.

Imagina a una persona con una memoria privilegiada, capaz de recordar un número de datos ilimitados acerca de cualquier tema, pensemos por ejemplo en nuestro sistema de clasificación de manzanas y naranjas. Este “superhumano” hipotético, tendría la capacidad de almacenar millones y millones de datos provenientes de millones y millones de naranjas y manzanas. Mientras esa persona no llegue a la conclusión de que la mayoría de las manzanas son rojas, y que la mayoría de las naranjas son color “naranja” y además, ocupe esa información para hacer inferencias acerca de un fruto o bien para relacionar esa información con otra información de distinta

naturaleza, entonces no podemos hablar de que ese superhumano tenga ningún conocimiento.

Aunque esta analogía utiliza un evento hipotético poco probable (por que la mayoría de las personas no son capaces de almacenar en sus cerebros tanta información de forma consciente), es un fenómeno parecido al que ocurre si a una persona normal, le regalamos una computadora con una capacidad de varios gigabytes, para fines prácticos podemos decir que esa persona se convirtió de pronto en un superhumano, sin embargo de nada servirán todos esos datos si no se procesan para convertirse en conocimiento útil.

La capacidad de transformar datos en elementos que nos permitan tomar decisiones es fundamental para nuestra supervivencia y evolución como especie. El conocimiento es la habilidad de organizar, comprender y aplicar la información: nos permite no solo distinguir entre “manzanas” y “naranjas”, sino también asignarles nombres y categorizarlas mediante símbolos que almacenamos en nuestro cerebro de manera estructurada. Este proceso nos da una base para interpretar el mundo que nos rodea.

Sin embargo, la sabiduría va más allá del conocimiento. No se trata solo de recopilar información o de entenderla, sino de utilizarla de manera prudente y contextualizada para resolver problemas complejos o tomar decisiones éticas. La sabiduría implica perspectiva, juicio y la capacidad de priorizar lo que realmente importa en una situación dada, un atributo que la inteligencia artificial todavía no posee.

Mientras que nosotros, los humanos, somos capaces de generar conocimiento a partir de unos pocos casos y adaptarlo con base en nueva información, los sistemas de inteligencia artificial requieren

volúmenes inmensos de datos para lograr algo similar. Incluso con esa ventaja en datos, la IA carece de la capacidad inherente de transformar conocimiento en sabiduría, porque no tiene un contexto ético, emocional o cultural que guíe sus decisiones.

Así, la tarea no solo es analizar datos para convertirlos en conocimiento, sino también reflexionar sobre ese conocimiento para alcanzar la sabiduría. Esta gran diferencia es lo que nos hace únicos y subraya el papel del juicio humano en un mundo cada vez más impulsado por la tecnología.

En los últimos años, los sensores electrónicos, junto con los algoritmos instalados en equipos de cómputo cada vez más potentes hacen la ecuación perfecta para que como nunca, tengamos acceso a datos. Sin embargo, tenemos el reto de procesar analizar y convertir esos datos en conocimientos. Ante esa situación el mundo se vio invadido de una demanda de personas capaces de analizar esos datos mediante herramientas matemáticas e informáticas.

En un mundo en donde los datos son generados a un ritmo jamás visto, se hicieron necesarias personas con los conocimientos para utilizar las herramientas disponibles y procesar los datos para tomar decisiones.

En este sentido, vale mucho la pena reflexionar en un detalle que comúnmente pasa desapercibido. ¿Qué características debería tener una persona que, con acceso a datos, se planteara la tarea de analizar dichos datos y generar conocimiento nuevo?

En primer lugar, debería tener conocimientos en herramientas matemáticas, porque desde hace algunos pocos siglos, se utilizan métodos numéricos en cualquier área de la ciencia. Además, haría falta que esa persona pueda usar un equipo de cómputo y las

herramientas que actualmente se utilizan para aplicar esos métodos matemáticos en un conjunto muy grande de datos. Estas dos condiciones ya representan toda una oportunidad de desarrollo que está siendo ampliamente explotada por muchas personas actualmente. Hoy uno de los empleos mejor pagados en el mundo es el de “científico de datos” cuya tarea es justamente generar conocimientos nuevos y aplicables en algún contexto específico.

Actualmente las empresas más grandes del mundo cuentan en su nómina de uno o más científicos de datos que generan reportes utilizados por los altos directivos como una herramienta indispensable en el rumbo de las empresas. Mucho se habla en estos tiempos acerca de las decisiones basadas en datos y la importancia en el éxito de las empresas.

Hay un tercer elemento a considerar. Quien analiza datos y genera o valida conocimiento nuevo, también debe de partir de un conocimiento previo del fenómeno a analizar. Este aspecto es de suma importancia y en el caso de la agricultura representa un punto crítico que como sociedad debemos de considerar. Posiblemente este sea uno de los aspectos más importantes a resaltar en este libro.

Imaginemos que un analista de datos recibe acceso a toda una base de datos acerca de los helados. ¿Cuántos sabores hay?, ¿de qué colores se pueden encontrar y que ingredientes contiene?, que edad y quienes los consumen?, ¿Cuál es el momento del día en que se venden más helados?, estas y otras preguntas pueden plantearse y responderse por cualquier persona que sepa de estadística y computo. En este caso el conocimiento relativo al fenómeno que es necesario para poder analizar este conjunto de datos está implícito. Cualquier persona que haya comido un helado tendrá un conocimiento previo acerca del

fenómeno bajo estudio. Esa persona no tendrá que asistir a una universidad de “helados” para poder obtener conclusiones valiosas a partir de los datos presentes en la base de datos.

En el caso de la agricultura la situación es muy diferente, alguien que tenga acceso a un número de datos agrícolas tendría que saber, no solamente métodos matemáticos e informáticos útiles en los análisis de información, también debería tener conocimientos relativamente avanzados acerca de la fisiología de las plantas, saber que procesos son afectados en mayor o menor medida por determinadas variables, que aparentemente no tienen conexión. ¿Como afecta la velocidad del viento a la cantidad de algún nutriente?, ¿cómo afecta la radiación solar a la cantidad de agua necesaria? Al igual que con fenómenos relacionados con la vida cotidiana, cuyo análisis requiere de un conocimiento previo, aquellos análisis realizados sobre sistemas agrícolas también requieren de conocimiento previo, pero en este caso no todas las personas tienen la experiencia de manejar un sistema agrícola.

A diferencia de comer un helado, lo cierto es que, a pesar de que todas las personas del mundo somos usuarios indirectos de sistemas agrícolas, la mayoría de las personas nunca han visto de cerca todo el ciclo productivo de su fruta favorita, nunca han visto la planta que toman en forma de té todas las mañanas.

El café que es una de las bebidas más consumidas en el mundo, goza sin embargo de un anonimato espectacular, ya que la mayoría de las personas (en comparación con las personas que consumen esta bebida) jamás han visto en vivo una planta de café, tampoco saben acerca de la terrible lucha que se libra en los campos en contra de

enfermedades como la roya, tampoco saben la temperatura y condiciones en las cuales la semilla debe de secarse.

Por este motivo una persona que intente analizar un conjunto de millones de datos de café y que no conozca los principios fundamentales de fisiología vegetal, podría llegar fácilmente a conclusiones absurdas o por lo menos poco aplicables en la realidad.

Esto no solo es una oportunidad de crecimiento, sino una necesidad de reenfocar a las ciencias agrícolas hacia nuevos y desconocidos horizontes, en los cuales, los profesionales del campo, no solo deberán ser lo suficientemente preparados en cuestiones agronómicas y tener al mismo tiempo la capacidad de interpretar conocimiento empírico que muchos agricultores del mundo poseen, además deben tener la herramientas matemáticas, de cómputo y de análisis de datos masivos que los científicos de datos poseen. Deben ser profesionales con una visión completamente diferente de la agricultura, en la que el conocimiento empírico de las plantas adquirido durante miles de años deberá combinarse con los conocimientos generados en la época de la estadística clásica y adelantarnos un poco al futuro para comenzar a usar sistemas de inteligencia artificial con un enfoque ético, responsable e incluyente.

En las condiciones actuales es todo un reto para las instituciones de educación superior, porque los sistemas educativos permanecen separados. Las personas dedicadas a la inteligencia artificial poco saben de plantas, al mismo tiempo, pocos agrónomos saben de inteligencia artificial, sin embargo, los agrónomos tienen conocimientos previos sobre el fenómeno mientras que los otros tienen las herramientas para construir nuevos sistemas. ¿Qué pasaría

si formáramos a los agrónomos con un nuevo enfoque? Posiblemente esté delante de nuestros ojos un nuevo paradigma tecnológico en la producción, control y administración de los alimentos en el mundo.

“Divide et impera”

Esta frase en latín significa “divide y vencerás” se atribuye al emperador romano julio Cesar. El principio subyacente de esta frase es simple. Es más fácil resolver un problema si este se divide y estudia por partes. A pesar de que esta frase fue pensada en el contexto de un conflicto bélico, este método parece haberse aplicado a las ciencias agrícolas.

Durante el siglo XVII, la ciencia no estaba tan especializada como lo está el día de hoy, muchos científicos realizaban contribuciones en muchas áreas de las ciencias, Isaac Newton, por poner un ejemplo, a pesar de que es conocido por sus aportaciones en física con las leyes del movimiento, también realizó contribuciones en óptica, matemáticas y áreas como la teología y la alquimia (disciplinas que eran parte de la ciencia en ese momento). Actualmente cualquier investigador que intente aportar en varias áreas del conocimiento simultáneamente, sería duramente juzgado por la comunidad científica, porque la mayoría de los estándares aplicados a la ciencia tienen métricas de evaluación pensadas hacia favorecer la hiperespecialización. Esto también tienen una razón de peso; la cantidad de información con potencial para generar conocimiento se expandió exponencialmente, en los siglos XX y XXI, de pronto, nos encontramos ante una cantidad de datos, que fue imposible de manejar para un ser humano, poco a poco se fueron creando divisiones que facilitaron una comprensión cada vez más profunda de los fenómenos bajo estudio. Esta forma de manejar el conocimiento se fue

generalizando a todas las áreas y disciplinas, incluso se fue generalizando a la educación. En los sistemas educativos de muchos lugares del mundo se comenzaron a enseñar por separado matemáticas, ciencias naturales, física y química. Aunque en la vida real, los problemas de física se resuelven generalmente con matemáticas y los de las ciencias naturales con química, física y matemáticas.

Para facilitar la comprensión profunda de los fenómenos que nos rodean, dividimos el conocimiento. Pero en el mundo natural, es imposible hacer esa distinción sin terminar en un callejón sin salida. La agricultura, no es una excepción. Un profesional de la agricultura debe tener conocimientos en biología, química, matemáticas, física y por si fuera poco tener el tacto para usar ese conocimiento y generar criterios que les permitan tomar decisiones en un sistema capaz de producir nada más y nada menos que los alimentos necesarios para una población creciente.

El conocimiento fue dividido, eso nos permitió lograr una comprensión profunda de fenómenos cada vez más pequeños, a cambio, perdimos la capacidad de interrelacionar esos fenómenos con fines prácticos.

La agricultura, en los tiempos modernos es definitivamente un fenómeno multidisciplinario. En la mayoría de las escuelas de agricultura del mundo se han diseñado planes de estudio que enseñan a los estudiantes aspectos relacionados con el suelo (medio en donde las plantas crecen), fisiología de las plantas, enfermedades de las plantas, plagas que afectan a las plantas, aspectos relacionados con la ingeniería y suministro del agua de riego, aspectos relacionados con la mecanización de los sistemas agrícolas y podemos continuar en una

interminable lista. A su vez, cada uno de los diferentes aspectos que acabamos de mencionar, esta nutrido con conocimientos provenientes de diferentes ciencias, física, química, matemáticas.

Por si esto fuera poco, en el mundo se cultivan una enorme variedad de especies vegetales, cada una de las cuales tiene hábitos de crecimiento diferentes y por lo tanto necesidades de manejo y logística diferentes. Además, en los últimos años hemos acumulado tal cantidad de conocimiento que ningún estudiante, recién egresado de la facultad de agronomía que este en su sano juicio, podría tener todos los conocimientos necesarios para manejar un sistema agrícola complejo a la perfección. Ese profesional en desventura, deberá manejar no solo los aspectos técnico-biológicos que acabamos de mencionar, sino que además tendrá que tomar en cuenta aspectos de comercialización, logística de transporte y distribución e incluso tendrá que considerar aspectos sociales que giran alrededor de la producción agrícola.

Supongamos que un agricultor, desea determinar la cantidad de fertilizante que necesita poner a su cultivo para alcanzar el máximo rendimiento. Actualmente sabemos que, sin importar la especie de la que se trate, las plantas necesitan 17 elementos de la tabla periódica para completar su ciclo de vida, que asimilan del suelo, agua o aire. Sabemos, además, debido a múltiples experimentos conducidos en los campos y laboratorios, como crece ese cultivo, en función de cada uno de esos elementos químicos necesarios para su supervivencia e incluso podemos establecer las cantidades necesarias de cada nutriente para alcanzar máximos rendimientos. Sin embargo, el crecimiento de una planta en la naturaleza no solo depende de la cantidad de fertilizantes, depende de un gran número de variables muchas veces no controladas. Podemos calcular la cantidad de

nutrientes que se necesitan y aplicarlos, pero difícilmente podremos controlar la cantidad de lluvia, o la presencia de insectos plaga o el precio del petróleo que afecta a la producción de los fertilizantes y ocasionan grandes cambios en la rentabilidad del cultivo.

La agronomía ha logrado reunir un gran cúmulo de conocimientos que benefician a la humanidad. Lo hemos logrado “dividiendo y venciendo”; pero esa información suele dispersarse entre distintas personas y publicaciones, y rara vez se concentra por completo en una sola mente. Por otro lado, los agricultores con años de experiencia en su propia región conocen a fondo sus campos y manejan los cultivos de manera integral, aunque quizá no posean una visión tan detallada de cada variable.

En este punto surge el choque entre el agricultor, con una perspectiva holística basada en la práctica y el entorno, y el profesionalista especializado en distintas áreas, cuya formación le permite analizar variables concretas a fondo. Cada uno ve el problema desde ángulos diferentes: el productor capta la complejidad total del sistema, mientras que el agrónomo identifica las variables clave y propone acciones para mejorar aspectos concretos. Solo combinando ambas perspectivas se pueden encontrar soluciones óptimas para la agricultura moderna.

Coniunge et triumphabis

Esta frase en latín, que significa “une y triunfarás”, no se atribuye a ningún general famoso ni forma parte de corrientes filosóficas clásicas. Sin embargo, sirve como contrapunto a “divide y vencerás”, resaltando la importancia de la unidad sobre la división. Al final, solemos alcanzar metas más ambiciosas cuando nos unimos y combinamos esfuerzos, en lugar de separarlos. Unamos nuestras fuerzas individuales, para ser más fuertes en colectivo, en lugar de dividir al enemigo para hacerlo más débil.

Llevando esta idea al ámbito de la agricultura moderna, descubrimos una mezcla enormemente prometedora: la experiencia especializada de los agrónomos y la potencia de la inteligencia artificial. Por un lado, tenemos especialistas en agricultura con un conocimiento profundo y en constante mejora derivado de años de estudio usando métodos estadísticos clásicos y dividiendo el conocimiento en aras de profundizar en la comprensión. Por otro lado, tenemos poderosos sistemas de inteligencia artificial, capaces de encontrar patrones matemáticos en millones de datos y contemplando cientos de variables distintas. ¿No es esta una poderosa combinación de habilidades?

Nunca en la historia del ser humano habíamos tenido la oportunidad de utilizar un “arma” tecnológica como esta. En el pasado un profesional del campo después de años de experiencia desarrollaba un criterio que era de utilidad para tomar decisiones. Incluso es posible, predecir las variables que podían impactar en mayor medida sobre un sistema de producción agrícola, con cierto margen de error.

Con los métodos basados en la IA moderna se pueden generar simulaciones relativamente precisas del crecimiento y desarrollo de

las plantas en función de una gran número de variables que se pueden estudiar por separado y analizar la interacción con las demás variables.

El futuro de la agricultura en el mediano plazo depende en gran medida de profesionales que, además de dominar las bases científicas, sepan diseñar, implementar y gestionar soluciones tecnológicas cada vez más sofisticadas. Solo así lograremos optimizar los recursos, aumentar la eficiencia y anticipar los desafíos que se avecinan en la producción de alimentos. Por otro lado, la democratización de la tecnología puede contribuir en gran medida a disminuir los riesgos asociados a su uso exclusivo por actores cuyo objetivo sea distinto al de producir alimentos para una población en crecimiento.

Es momento de repensar la agronomía clásica y considerar la incorporación de conocimientos de avanzada en los planes de estudio. Los retos actuales que la humanidad enfrenta y que están asociados a la producción de alimentos en un mundo en constante crecimiento poblacional en medio de un cambio climático, hacen que el esfuerzo que suponga el cambiar paradigmas tecnológicos y en muchos casos sociales e incluso económicos valga la pena.

El riesgo de la no democratización del conocimiento de avanzada en los sistemas agrícolas es enorme. Imagine que solo un pequeño y selecto grupo de agrónomos tenga acceso a sistemas avanzados de inteligencia artificial. Ese grupo selecto tendría de pronto la posibilidad de optimizar sus cosechas en función de las condiciones dinámicas del ambiente, lo cual le daría una competitividad estratégica en el mercado de los productos agrícolas. Podrían además generar soluciones personalizadas para los problemas que ese sistema en particular presente y la solución propuesta podrá ser generada

únicamente para ese sistema y ninguno otro. Estos sistemas pueden rápidamente tomar enorme ventaja contra los sistemas tradicionales, en los cuales se tiene que lidiar todos los días con condiciones cambiantes e inciertas, que no da margen de acción ante errores por falta de planeación o por no contar con la información por anticipado que los modelos de simulación que ofrece la inteligencia artificial. Esta brecha tecnológica no haría más que aumentar la desigualdad en la producción agrícola y, en última instancia, pondría en juego la seguridad alimentaria global.

La poderosa métrica del error.

Como ya mencionamos, los sistemas de inteligencia artificial son una caja negra, en la que no podemos ver al interior y saber exactamente cómo funciona; no podemos saber, por ejemplo, que variables se están considerando y como afectan estas variables a las demás en el resultado final del modelo. Si no podemos saber nada de esto, entonces ¿cómo sabemos que el resultado es el correcto? Para solventar este problema se han diseñado algunas métricas que por cierto tienen su origen en la estadística clásica.

Los modelos de predicción de una o dos variables que se desarrollan utilizando estadística clásica, también se enfrentan al mismo problema que los modelos más avanzados de inteligencia artificial. ¿Cómo sabemos que el resultado de nuestra predicción es el correcto?

En general en la ciencia estamos muy acostumbrados a lidiar con el error, ese maestro implacable que nos enseña cual no es el camino correcto en lugar de indicarnos hacia a donde ir. La mayoría de los trabajos científicos antes de ser publicados no son otra cosa que una increíble colección de errores, si un científico no se equivoca, es porque alguien más ya lo hizo por él. Un científico promedio, pasa la

mayor parte de su carrera equivocándose de una manera estrepitosa. En general cuando un avance científico relevante se logra, es porque detrás existió un largo camino de equivocaciones y callejones sin salida. En la actualidad, las revistas científicas más prestigiosas del mundo suelen publicar aquellos trabajos que impliquen avances en alguna parte del conocimiento, pero nunca publican el arduo camino necesario para llegar a él. Ese valioso conocimiento, y si me permite, insistiré en lo valioso, se reserva para las pláticas de café entre los investigadores que muchas veces agotados expresan las dificultades del trabajo diario frente a otros colegas, que al borde casi de la frustración y el desánimo encuentran, sin embargo, un camino apasionante en la ciencia. Es difícil ver a un grupo de personas tan felices por cometer errores utilizando presupuesto público, pero esta es la única forma de avanzar en el conocimiento en beneficio de la sociedad. La ciencia es, si me permiten el atrevimiento, el máximo símbolo de poder y opulencia en una sociedad.

Sin embargo, lo realmente difícil, es darse cuenta de que se está equivocado y que tan equivocado se está en algo. La medida del error es algo fundamental en las ciencias. Para esta medida se usan métodos matemáticos que se basan en una solución tan simple y elegante que incluso puede verse como obvia para cualquier ser humano. La diferencia entre un resultado esperado y uno observado.

A continuación, analizaremos un ejemplo, que como siempre, no pretende ser un tratado académico de las métricas del error, sino que tiene el objetivo de comprender la lógica fundamental con la cual los sistemas de IA cuantifican el error.

¿Regresemos a nuestro ejemplo de manzanas y naranjas?

En este caso tendremos diez frutas, que nosotros hemos identificado con una etiqueta “real” con la letra “A” si son manzanas o “B” si son naranjas. Además, construimos un modelo de inteligencia artificial que, basándose en las características de cada fruta, las clasifica. El resultado de esa clasificación que realizó el modelo lo tendremos en la columna llamada “Predicción del modelo”.

| Fruta | Etiqueta real | Predicción del modelo |
|--------------|----------------------|------------------------------|
| 1 | Manzana (A) | Manzana (A) |
| 2 | Manzana (A) | Manzana (A) |
| 3 | Manzana (A) | Manzana (A) |
| 4 | Manzana (A) | Manzana (A) |
| 5 | Manzana (A) | Manzana (A) |
| 6 | Manzana (A) | Naranja (B) |
| 7 | Naranja (B) | Manzana (A) |
| 8 | Naranja (B) | Naranja (B) |
| 9 | Naranja (B) | Naranja (B) |
| 10 | Manzana (A) | Manzana (A) |

Como podremos observar en este ejemplo hipotético existe una discrepancia entre lo que el modelo arroja y lo que es en realidad. Como partimos del hecho de que nosotros somos perfectamente capaces de distinguir una manzana y una naranja, entonces concluimos que el modelo se equivocó. En el caso de la fruta número seis, que era una manzana, el modelo la clasifico incorrectamente como una naranja y en el caso de la fruta número siete, que era una

naranja, el modelo la clasifico como manzana. En ambos casos se trata de un error de clasificación, porque, en la práctica, ningún modelo matemático es perfecto. Este pequeño error en muchas ocasiones es deseable, pero este tema lo abordaremos un poco más adelante, ya que tiene implicaciones importantes. Por lo pronto hemos detectado que dos de los diez frutos están mal clasificados. Es decir, tenemos una discrepancia entre la realidad y aquello que el modelo predijo.

A partir de esta información podemos tener cuatro posibles casos:

Caso 1

Verdaderos positivos: Número de frutos de manzanas, clasificadas como manzanas.

Caso 2

Verdaderos negativos: Número de frutos de naranjas, clasificadas como naranjas.

Caso 3

Falsos positivos: Número de frutos de naranjas, clasificadas como manzanas.

Caso 4

Falsos negativos: Numero de frutos de manzanas, clasificadas como naranjas.

Como podremos ver, todos los frutos caen en cualquiera de estos supuestos, además podremos notar que los casos 1 y 2 (casos verdaderos) son deseables en el sistema de clasificación, debido a que

se trata de frutos correctamente clasificados, en contraste los casos 3 y 4 (casos falsos) son no deseables, porque en realidad se trata de frutos que fueron clasificados de forma incorrecta por el sistema.

Con esta información podemos construir algo que se llama matriz de confusión, que no es otra cosa más que colocar en forma de una matriz los cuatro casos anteriormente expuestos para obtener algo como esto:

| Real / Estimado | Manzanas | Naranjas |
|-----------------|------------------------|------------------------|
| Manzanas | Verdadero positivo = 6 | Falso negativo = 1 |
| Naranjas | Falso positivo = 1 | Verdadero Negativo = 2 |

En la celda correspondiente a la segunda columna y a la segunda fila, tenemos el número seis, que corresponde con el número de frutos que son manzanas y que el sistema clasifico de forma correcta como manzanas (Verdaderos positivos), en la celda correspondiente a la tercera columna y segunda fila, tenemos al número uno, que corresponde con el número de manzanas que el sistema clasifico como naranjas de forma incorrecta. Con la misma lógica rellenamos las celdas faltantes con los números correspondientes.

Con este simple y elegante arreglo, podemos determinar qué tan exacto es nuestro sistema al momento de clasificar frutos. En este caso nuestro sistema acertó en 8 (6 verdaderos positivos + 2 verdaderos negativos) frutos de un total de 10, por lo que podemos decir que la exactitud es de 8 de cada 10, es decir un 80%. De hecho, la fórmula para calcular la exactitud es la siguiente:

$$\text{Exactitud} = \frac{\text{Calificaciones correctas}}{\text{Número total de muestras}}$$

En nuestro caso, el número de clasificaciones correctas estará determinado por la suma de los verdaderos positivos y los verdaderos negativos mientras que el número de muestras estará determinado por la suma de todos los posibles casos en nuestra matriz de validación; por lo tanto, la fórmula para calcular la exactitud sería;

$$\text{Exactitud} = \frac{\text{Verdaderos positivos} + \text{Verdaderos negativos}}{\text{Verdaderos positivos} + \text{Verdaderos negativos} + \text{Falsos positivos} + \text{Falsos negativos}}$$

Si sustituimos los valores en nuestra fórmula con los valores numéricos de nuestra matriz de confusión entonces;

$$\text{Exactitud} = \frac{6 + 2}{6 + 2 + 1 + 1} = \frac{8}{10} = 0.8$$

típicamente la exactitud se suele expresar en porcentaje, con la finalidad de hacerlo más entendible para cualquier persona, para lo cual únicamente multiplicamos por 100 el valor obtenido de la fórmula y para nuestro caso obtenemos un valor de exactitud del 80%.

Acabamos de calcular una de las métricas más utilizadas en los sistemas de inteligencia artificial. Como podemos ver, el cálculo se basa en la diferencia entre un valor real y el valor estimado por el

modelo de clasificación creado mediante cualquier técnica de inteligencia artificial.

En este punto vale la pena preguntarse lo siguiente. ¿Por qué se podría equivocar el modelo?, las diferencias entre manzanas y naranjas son muy evidentes y un niño de diez años podría fácilmente tener una cantidad de aciertos mucho mayor que un 80% a la hora de distinguir entre una manzana y una naranja.

Las razones por las cuales un modelo de inteligencia artificial puede equivocarse, se encuentran en las distintas fases de la construcción del modelo y es algo digno de analizarse.

En nuestro ejemplo hipotético, nosotros “etiquetamos” a los frutos como manzanas o naranjas, el sistema lo único que hizo fue encontrar los patrones matemáticos de color, peso y cualquier otra característica, con la cual alimentemos a nuestra base de datos. Así que la primera fuente de error podría ser el etiquetado de los datos. Si cometemos un error de captura y nombramos a una manzana como naranja, entonces habrá un sesgo por que tendremos un caso de una manzana etiquetada incorrectamente que posea todas las características de una naranja. Cuando un sistema de inteligencia artificial se entrena con datos etiquetados por humanos, hablamos de aprendizaje supervisado. En este proceso, el modelo identifica patrones matemáticos que distinguen una clase de datos de otra. A menudo se utilizan millones de muestras, lo que también aumenta la probabilidad de encontrar errores en el etiquetado, los cuales pueden introducir sesgos al sistema.

Otra fuente común de error proviene de la calidad de los datos mismos. Tal como señalamos páginas atrás, muchos de ellos provienen de sensores que no son perfectos. Volviendo al ejemplo de manzanas y naranjas, podemos preguntarnos: ¿cómo medimos el color de estas frutas?, ¿qué dispositivo empleamos para hacerlo?, ¿de qué manera transmitimos esa información? y ¿cómo la procesamos después? Cada uno de estos pasos puede sumar inexactitudes que, acumuladas, influyen en la fiabilidad del conjunto de datos.

En los sistemas de aprendizaje supervisado, la cantidad y calidad de los datos de entrenamiento resultan fundamentales. La exactitud final del modelo depende directamente de lo representativos y precisos que sean los ejemplos con los que se entrena.

Un sistema de inteligencia artificial identifica patrones matemáticos que diferencian unas clases de otras y, más adelante, evalúa su propio desempeño midiendo el error. Para ello, compara las etiquetas que generó con las que fueron asignadas por los humanos, detectando las discrepancias entre ambas.

El problema de la perfección (sobreajuste)

Cuenta la leyenda que Arquímedes corrió desnudo por las calles de Siracusa, gritando ¡Eureka!, cuando la inspiración llegó y pudo determinar si la corona del rey Hierón estaba hecha de oro. La palabra significa literalmente “lo encontré”. Incluso hoy día, el “¡Eureka!” de Arquímedes sirve como símbolo de inspiración científica y de la alegría del descubrimiento.

Cuando se realiza un experimento utilizando métodos de estadística clásica, en los cuales se utilizan métricas de error similares a la

exactitud, ocurren gritos de Eureka con valores a partir de 70 u 80%. típicamente, y salvo contadas excepciones, un experimento de agronomía llevado con los protocolos más estrictos suele arrojar estos valores de exactitud.

Esto implica que nuestro modelo sería capaz de predecir correctamente 7 u 8 de cada 10 casos, entonces ¿Qué ocurre con el resto de los casos? En general se asumen que los datos clasificados incorrectamente, no indican una falla en el modelo, sino un error en la medición o bien, el efecto de alguna variable no contemplada. Cuando la exactitud es muy baja (fenómeno más frecuente de lo que pareciera) puede ser necesario repetir todo el experimento, modificando alguna variable en particular o bien utilizando cualquier estrategia que nos permita disminuir la variabilidad con la finalidad de que la mayor parte del efecto observado se deba a la causa que estamos intentado modelar.

Cuando se utilizan técnicas de inteligencia artificial, es muy común que pase exactamente el fenómeno opuesto. En lugar de obtener valores de exactitud bajos, se obtienen valores de exactitud muy altos, en ocasiones se obtienen valores del 100% de exactitud.

Este fenómeno se denomina sobreajuste y se presenta cuando un modelo de aprendizaje automático memoriza de forma excesiva los detalles y el ruido de los datos de entrenamiento. Esto lo lleva a describir a la perfección ese conjunto de datos particular, pero a costa de perder la capacidad de generalizar y hacer buenas predicciones en datos nuevos o nunca vistos. En otras palabras, el modelo deja de “entender” las pautas generales del problema, y en cambio se adapta demasiado a peculiaridades o casos aislados del conjunto de entrenamiento, que no necesariamente se repiten en otros contextos.

Este fenómeno suele ocurrir en especial en modelos de mucha complejidad en los cuales hay un número excesivo de variables de entrada, por ejemplo, en redes neuronales muy profundas, sin la configuración adecuada.

Para poder detectar este problema en los modelos de inteligencia artificial, existen varias técnicas, una de las cuales consiste en entrenar al modelo con solamente una parte del total de los datos (típicamente el 70% del total de los datos) mientras que el 30% de los datos restantes se “ocultan” a la computadora. De este modo, el modelo solo puede “ver” y “memorizar” los patrones que aparecen en ese 70% inicial, quedando el 30% reservado para verificar si el modelo realmente ha aprendido las pautas generales o si simplemente ha memorizado detalles irrelevantes del conjunto de entrenamiento.

En esta fase de validación, la métrica de error cobra gran relevancia al indicar si las predicciones que emite el modelo (basadas únicamente en el 70% de datos que conocía) coinciden con la realidad (reflejada en el 30% que no había visto). Aquí es donde el criterio humano mantiene un papel decisivo: interpretar los resultados, decidir si la exactitud obtenida refleja un conocimiento real del fenómeno o si se trata de un ajuste excesivo que no servirá en la práctica. La experiencia y el conocimiento experto ayudan a juzgar en qué medida los resultados son “demasiado perfectos” —un indicio de sobreajuste— o están en un rango razonable, coherente con la complejidad del problema y las condiciones reales de la agricultura o el campo de estudio en cuestión.

Los sistemas de IA en la automatización

Hasta ahora hemos explorado el enorme potencial de la IA como una técnica para generar simulaciones que nos permitan obtener conocimiento, sin embargo, existe otro uso a considerar que debemos de reflexionar y considerar debido a las implicaciones que tiene para la labor de los agrónomos.

Ya hemos hablamos sobre la importancia de los datos en la agricultura y la forma en que se han utilizado las matemáticas para obtener conocimiento que nos permita comprender como se comportan las plantas ante un conjunto de variables (clima, suelo, enfermedades etc.). El fin último de ese conocimiento es transformarlo en decisiones específicas que en la práctica permiten producir alimentos suficientes para las personas en el planeta. También proponemos la idea de que los sistemas de inteligencia artificial permiten realizar simulaciones complejas y son una herramienta poderosa en la toma de esas decisiones. Un agricultor que cuente con un modelo de IA para su cultivo puede en un momento dado, modificar las dosis de fertilizantes, la cantidad de agua de riego, o cualquier otro aspecto relacionado con el manejo de su cultivo con la finalidad de optimizar, recursos, ganancia o simplemente lograr un objetivo de producción en condiciones desfavorables como una temporada atípica de lluvias, temperaturas o incluso de condiciones de mercado.

Sin embargo, una cosa es tener la información que genera una decisión y otra cosa es ejecutar una acción en la realidad. Imaginemos que un modelo de inteligencia artificial recomienda la aplicación de un insecticida en algún sector específico de la parcela en donde sistemas de monitoreo automático, estiman la presencia de insectos plaga. En ese caso, el agricultor tendría que tomar un aspersor e ir el

mismo a aplicar el insecticida, por otro lado, si el sistema recomienda un riego adicional en alguna parte del cultivo que presente niveles de estrés hídrico elevados, el agricultor tendría que activar la bomba o hacer las acciones necesarias para que llegue al sitio deseado.

Para resolver este desafío, se han desarrollado mecanismos que automatizan parte de los procesos agrícolas. En la actualidad, existen actuadores capaces de encender bombas de agua, drones que transportan y aplican agroquímicos en áreas específicas, e incluso tractores equipados con GPS para realizar labores de manera autónoma. Además, los sistemas de comunicación modernos permiten que estos dispositivos se comuniquen sin intervención humana, lo que posibilita conectar la IA con los actuadores, incrementando de forma gradual la autonomía operativa y reduciendo la necesidad de participación humana directa.

En este contexto, los ingenieros agrónomos requerirán nuevas competencias que complementen su conocimiento tradicional. Deberán ser capaces de interpretar grandes volúmenes de datos, aplicar métodos estadísticos y de aprendizaje automático para validar y ajustar los modelos, y comprender cómo funcionan los dispositivos de automatización agrícola (sensores, drones, bombas, tractores autónomos, etc.). También se volverá imprescindible adquirir nociones de programación y uso de software especializado, dominar sistemas de comunicación y redes (por ejemplo, IoT agrícola), y manejar la seguridad de la información para proteger datos sensibles. Todo esto, sin dejar de lado la necesidad de un liderazgo basado en datos, habilidades de comunicación para explicar decisiones a productores o equipos de trabajo, y un fuerte compromiso con la sostenibilidad y la ética, dadas las implicaciones ambientales y sociales que conlleva la automatización. Finalmente, la capacidad de

adaptación será clave, pues la tecnología evoluciona rápidamente y el profesional agrónomo tendrá que mantenerse al día para aprovechar con éxito estas herramientas en un entorno cada vez más complejo y dinámico.

Sería difícil explicar la historia de las sociedades modernas sin mencionar la evolución de los sistemas agrícolas, y a la vez resulta complicado predecir con exactitud el futuro de la agricultura a la luz de los avances tecnológicos actuales. Lo que sí es claro es que, hasta el momento, no existe otra actividad capaz de producir alimentos para todos los habitantes del planeta, y al mismo tiempo, los sistemas agrícolas enfrentan desafíos sin precedentes.

Contamos, sin embargo, con tecnologías que nunca habíamos tenido a nuestro alcance para hacer frente a estos retos. El éxito de su implementación depende, en gran medida, de que estén disponibles para el mayor número posible de personas. De lo contrario, quienes tengan acceso a estas herramientas obtendrán una ventaja considerable frente a quienes carezcan de ellas, lo que podría poner en serio riesgo la producción de alimentos a nivel global.

Es necesario promover políticas que garanticen el acceso equitativo a estas herramientas, de modo que tanto pequeños como grandes productores puedan beneficiarse de la innovación. Esto implica, por un lado, facilitar la inversión en infraestructura tecnológica (conectividad, equipos, capacitación) y, por otro, establecer regulaciones y programas de apoyo que aseguren que los agricultores con menos recursos no queden al margen. Solo así se podrá reducir la brecha digital en el campo y lograr que la adopción de nuevas tecnologías contribuya realmente a la seguridad alimentaria y al desarrollo sostenible.

Los datos ocultos.

El pensador y escritor escocés Thomas Carlyle afirmaba que la historia de la humanidad se resume en la vida de los grandes hombres, sosteniendo que el rumbo del mundo está determinado por la influencia de individuos sobresalientes. De acuerdo con Carlyle, sin estos grandes hombres o mujeres presentes en los momentos determinantes de muchos hechos históricos, la humanidad sería completamente distinta.

El resumir la historia del mundo entero, basándose únicamente en la biografía de determinadas personas es algo que funciona muy bien para tener una historia que contar, un panorama general que nos permite obtener una secuencia lógica de eventos que explican al mundo moderno y permite además estimar un posible rumbo que la humanidad puede tomar.

Sin embargo, esta visión ofrece también un panorama injusto para aquellas personas que, sin ser personajes sobresalientes, contribuyeron de una forma que ni siquiera podemos cuantificar. Para explicar mejor el punto al que quiero referirme, pensemos en uno de los grandes científicos de la historia moderna. Issac Newton, que en páginas anteriores dedicamos algunas líneas mostrando los avances con los que contribuyó en varias áreas del conocimiento. Cuando una manzana cae sobre la cabeza de Newton, se comienzan a gestar sus ideas sobre la gravedad que hasta el día de hoy se utilizan con fines prácticos. Es mérito de Newton este descubrimiento, pero nadie se pone a pensar en la persona que sembró el árbol de manzana. Se nos olvida que, en un evento completamente fortuito, una persona dejó una semilla justo en ese lugar, para que años después una manzana cayera sobre la cabeza de Newton. No existe sin embargo en ningún

lugar de Inglaterra, una placa a aquel agricultor desconocido que sembró el árbol que diera origen a la mítica manzana de Newton.

Por supuesto que nuestro héroe desconocido nunca tuvo la intención de sembrar un árbol que sirviera de inspiración a uno de los descubrimientos en la física más importantes de la historia de la humanidad, pero también sería justo reconocer su participación. ¿Si no estuviera ese árbol en ese lugar, a Newton no se le hubiera ocurrido jamás las leyes de la gravitación? Seguramente si, pero no lo podremos saber, porque el árbol estaba ahí y la historia se escribió exactamente tal y como esta.

La angelota de Newton y la manzana, puede ser un completo mito, pero es innegable que aquellos hombres que se consideran referentes en la historia debieron tener una serie de eventos únicos, detonados por muchas personas que quedaran en el eterno anonimato, al igual que el agricultor desconocido que sembrara el árbol de manzano de Newton.

Para que un avance científico o tecnológico ocurra, se requieren muchos héroes anónimos, que colabora de forma inconsciente en el avance del conocimiento. ¿Quién preparo el almuerzo de Einstein durante los interminables días de reflexión alrededor de la teoría de la relatividad?, ¿Quién sembró las plantas que se convierten en alimento de aquellos grandes hombres?, detrás de todo hecho, de todo avance científico, de todo cambio social, de toda nueva idea, siempre hay agricultores, héroes anónimos que hacen posible que todo ocurra.

Ya mencionamos que los sistemas de inteligencia artificial demandan una gran cantidad de datos para poder encontrar patrones matemáticos funcionales que permitan estimar las variables de nuestro interés. En el caso de los sistemas agrícolas, esos datos deben ser generados con

ayuda de los agricultores, quedando de nuevo como los héroes anónimos que generan información para sistemas cada vez más eficientes y robustos. Sistemas que permitirán producir más alimentos con la cantidad óptima de recursos naturales y financieros. Pero ¿Qué beneficios podremos proporcionar a los agricultores que generen esta información?, ¿De qué forma podremos hacer coparticipes a los agricultores de los beneficios de la inteligencia artificial?

Estas preguntas deben de abordarse en el corto plazo, con el enfoque de asegurar la democratización del conocimiento necesario para asegurar el buen funcionamiento de los sistemas agrícolas.

No podemos permitir que ninguna persona, por humilde que sea su función en la sociedad, quede excluida de los beneficios de las nuevas tecnologías. Tampoco debemos dejar que la tecnología nos sobrepase, convirtiéndonos en esclavos de nuestra propia creación. Es fundamental que los profesionales de la agricultura unan esfuerzos en torno a las innovaciones que están marcando un nuevo precedente en la producción de alimentos, y que diseñemos mecanismos que hagan posible un desarrollo humano sostenible.

No podemos prever con certeza cómo será el futuro, pero sí podemos definir hoy la ruta que deseamos recorrer mañana. Nos encontramos en un viaje a través del tiempo, partiendo del presente con el futuro como único destino posible. Afrontemos el horizonte con la determinación que siempre ha caracterizado a nuestra especie y la fortaleza forjada en miles de años de lucha.



**Aprendiendo de las plantas:
desde la estadística clásica a la inteligencia artificial**

Centro de Investigación en Química Aplicada
Departamento de Biociencias y Agrotecnología
Boulevard. Enrique Reyna H. 140, San José de los Cerritos,
25294 Saltillo, Coah.

Contacto:

biociencias@ciqa.edu.mx
agrotecnologias@ciqa.edu.mx
comercializacion@ciqa.edu.mx
capacitacion@ciqa.edu.mx
Tel. (844) 438 98 30 ext. 1313/1347

ISBN Obra independiente
978-607-97394-5-4



Ciencia y Tecnología
Secretaría de Ciencia, Humanidades, Tecnología e Innovación

